

빅데이터 분석을 통한 중력식 항만시설 수정프로젝트 레벨의 상태변화 특성 분석

A Study on Condition Analysis of Revised Project Level of Gravity Port facility using Big Data

나용현¹ · 박미연^{2*} · 장신우³

Yong Hyoun Na¹, Mi Yeon Park^{2*}, Shinwoo Jang³

¹Chief Researcher, SH Tech & Policy Institute Co., Seongnam, Republic of Korea

²PH.D, SH Tech & Policy Institute Co., Seongnam, Republic of Korea

³Application Engineer, RaonX Solutions Inc., Seongnam, Republic of Korea

*Corresponding author: Mi Yeon Park, momo6238@hanmail.net

ABSTRACT

Purpose: Inspection and diagnosis on the performance and safety through domestic port facilities have been conducted for over 20 years. However, the long-term development strategies and directions for facility renewal and performance improvement using the diagnosis history and results are not working in realistically. In particular, in the case of port structures with a long service life, there are many problems in terms of safety and functionality due to increasing of the large-sized ships, of port use frequency, and the effects of natural disasters due to climate change. **Method:** In this study, the maintenance history data of the gravity type quay in element level were collected, defined as big data, and a predictive approximation model was derived to estimate the pattern of deterioration and aging of the facility of project level based on the data. In particular, we compared and proposed models suitable for the use of big data by examining the validity of the state-based deterioration pattern and deterioration approximation model generated through machine learning algorithms of GP and SGP techniques.

Result: As a result of reviewing the suitability of the proposed technique, it was considered that the RMSE and R^2 in GP technique were 0.9854 and 0.0721, and the SGP technique was 0.7246 and 0.2518.

Conclusion: This research through machine learning techniques is expected to play an important role in decision-making on investment in port facilities in the future if port facility data collection is continuously performed in the future.

Keywords: Big Data, Gaussian process, Condition evaluation, influence factor, Machine learning

요약

연구목적: 국내 항만시설의 진단을 통한 성능 및 안전에 대한 점검과 진단을 20년 넘게 진행되었지만 그 진단 이력과 결과를 활용한 중장기적인 시설개선과 성능개선을 위한 발전전략이나 방향이 현실적으로 작동하지 않고 있다. 특히, 사용년수가 오래된 항만구조물의 경우, 선박의 대형화와 사용빈도 증가, 기후변화로 인한 자연재해의 영향 등으로 안전성과 기능적 면에서 상당히 많은 문제점을 내포하고 있다. **연구방법:** 본 연구에서는 중력식 안벽에 대한 부재수준의 유지관리 이력 데이터를 수집하여 이를 빅데이터로써 정의하고 해당 데이터를 바탕으로 프로젝트 수준의 시설물의 노후화 패턴 및 열화를 추정하기 위한 예측근사모델을 도출하였다. 특히 GP 및 SGP 기법의 머신러닝 알고리즘을 통하여 생성된 상태기반 노후도 패턴 및 열화 근사모델에 대한 유효성 검토를 통해 빅데이터 활용에 적합한 모델을 상호 비교하고 제안하였다. **연구결과:** 제안된 기법의 적합성을 검토한 결과 GP기법은 RMSE 및 R^2 는 0.9854

Received | 19 March, 2021

Revised | 2 June, 2021

Accepted | 2 June, 2021

 OPEN ACCESS



This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0>) which permits unrestricted noncommercial use, distribution, and reproduction in anymedium, provided the original work is properly cited.

© Society of Disaster Information All rights reserved.

와 0.0721, SGP기법은 0.7246과 0.2518로 GP기법을 적용한 예측모델이 적합한 것으로 검토 되었다. 결론: 머신러닝 기법을 통해 이러한 연구는 향후 항만시설 데이터취합이 지속적으로 이루어진다면 향후 항만시설 투자 의사결정에 중요한 역할을 할 것으로 기대한다.

핵심용어: 빅데이터, 가우시안 프로세스, 상태평가, 영향인자, 머신러닝

서론

1980년 이후 늘어나는 태풍과 기상이변, 자연재해 등으로 인한 시설물의 손상 및 노후화가 급속도로 진행되고 있어 항만 시설물의 안전뿐만 아니라 사용성, 성능유지를 위한 더 많은 노력과 재원확보가 중요해지고 있다.

항만 시설의 경우 선박이 대형화 되어 감에 따라 기존에 구축된 시설에 대한 용량 문제 및 안정성에 대한 문제점이 부각되어 가고 있다. 이와 관련하여 정부에서는 항만 시설의 규모와 성장 수준에 맞도록 적합시설 확충과 서비스 수준 향상 고려가 필요함에 따라 관리자 및 사용자의 요구수준을 반영한 안전성, 사용성, 내구성으로 구분된 성능평가가 가능하도록 시설물의 안전 및 유지관리에 관한 특별법(약칭 ‘시설물 안전법’)을 개정하였고(2018.01.01.), 2018년 12월 지속가능한 기반시설관리법을 전격 공포하면서 관리주체로 하여금 기반관리시설에 대하여 최소한의 유지관리 기준을 수립하고 보수보강에 대한 개선 대책 등을 수립함으로써 시설물 유지관리 및 자산관리에 대한 중장기적 전략 수립이 필요하다(Port Association, 2010). 국내 항만시설등의 경우 주기적인 정밀안전진단을 수행하고 있으나, 보수보강에 대한 이력이 세부적으로 관리되고 있지 않는 실정이다. 이로 인하여 구조물 및 시설물별 보수보강 이력을 통한 상태 진단과 성능개선을 위한 판단이 어려운 실정이다.

따라서 시설물별 세부 보수보상 이력과 그와 관련된 성능개선이력을 파악 및 분석하여 내재된 위험요인과 기능 및 성능저하 등을 조사, 평가를 통하여 향후 열화되거나 노후화되어 취약해지는 안전성능의 수준을 예측할 수 있는 기반 마련이 시급한 실정이다. 김성욱(2012)은 ‘열화요인을 고려한 항만구조물 잔교식의 상태등급 열화모델 개발’에서 생애주기 관리시스템 관점에 기초하여 항만시설물의 상태성능을 예측할 수 있는 항만시설물 열화모델에 대한 연구를 수행하였다. 대상항의 정밀안전진단 상태등급DB를 이용하여 부재별 단변수 회귀분석을 수행하고, 열화인자를 이용하여 다변수 회귀분석을 수행하여 전체 열화모델을 산출하였다. 충분한 DB를 이용하여 열화모델 산출이 가능했다면 더 정확한 열화모델 수립이 가능했을 것으로 보인다(Kim et al., 2012). 그러나 위 연구의 경우 특정변수들(습도, 환경, 파고 등)을 일정한 값으로 규정하여 분석이 진행되어 실제적인 적용 모델로는 제한적인 문제가 있다.

이에 본 연구에서는 항만시설 안전성능변화를 추정하고 예측 할 수 있는 빅데이터 기법을 통한 상태변화추이 예측모델을 개발하여 항만시설물의 선제적인 유지관리활동을 지원하고 필요한 재원을 확보할 수 있는 기반을 마련하는데 기여하고자 하였다. 빅데이터는 데이터를 수집 및 축적에 그치지 않고 다양한 데이터의 종류상에 내재된 패턴을 찾아내고 분석함으로써 이를 통해 변화 양상을 추측하는 것이 가능하다.

현재 항만 주요시설물에 대한 점검, 진단 및 보수, 보강 등에 대한 현황을 유지관리 이력정보로서 체계적으로 수집 관리하고 있다. 이와 같이 항만 시설물에 대한 유지관리 이력 데이터를 빅데이터 분석 기술을 활용하여 시설물의 기본정보, 점검 및 진단, 보수, 보강 정보 등 다양한 빅데이터를 기반으로 머신러닝 기법을 통해 노후화 패턴을 예측하는 모델을 연구하고자 한다. 빅데이터를 활용한 분석은 다양한 분야에서 의사결정을 하는 과정에서 비구조적이고 비정형적인 대규모 데이터에 대한 분석이 필요한 분야에 활용되고 있다. 즉 데이터간의 상관관계를 분석하고 목표로 하는 데이터의 추이와 양상을 분석하여 최적의 의사결정을 지원하기 위하여 정형화된 데이터로 변환하여 각각의 주요 인자간 상관관계를 파악 후 데이터의 패턴을 식

별하고 예측하기 위한 기법을 적용하여 복합적인 양상과 패턴을 찾아냄으로써 상황을 예측하는 것에 초점을 두고 있다(Kim et al., 2012).

먼저 빅데이터 분석을 위한 전처리 과정으로 수집, 축적된 데이터의 속성과 분포를 파악하여, 데이터간 상관관계를 분석하는 것에 있다. 또한 정형화 되어 있지 않은 데이터를 변수화하여 시설물의 노후화에 영향을 주는 인자를 파악하고 이를 통해 예측 모델에 주요 인자로 예상되는 요인을 유추해내게 된다(Song et al., 2013).

시설물의 유지관리 이력 데이터는 점검, 진단을 실시한 년차별 데이터로 시계열 데이터로 분류될 수 있으나 이는 전반적인 변동 양상을 파악하고 선형 회귀분석을 통해 추세검토에 활용될 수는 있으나, 다양한 구조형식과 운영환경에 따라 장기적 예측에 따른 불확실성으로 노후화를 예측하는데 제한적이다. 따라서, 시설물의 노후화 추세와 양상을 예측을 위하여 데이터 기반 머시러닝 기법인 가우시안 프로세스 분석 모델을 통해 예측된 추세의 오류와 불확실성을 동시에 검토함으로써 앞서 언급된 선형회귀분석 기법의 제안성을 극복하고자 한다.

항만 시설물의 노후화를 분석하기 위하여 이러한 빅데이터 및 인공지능 기술의 도입에 대한 이슈는 지속적으로 요구되어 왔으나 구체적인 방법론 및 적용사례는 미비한 실정이다. 빅데이터 기반의 인공지능 분석 기법 도입을 위하여 본 연구에서는 가우시안 프로세스(GP) 기법을 채택하여 시설물의 상태등급 변화에 따른 노후화 추세분석에 활용하였다(Rasmussen, 2004). 이와 같이 빅데이터 분석 기법을 통한 항만 시설물의 노후화 패턴 분석을 통해 다양한 시사점을 도출하고자 하였다.

빅데이터방법론을 적용한 항만시설 상태기반열화모델 개발

상태기반 노후도 패턴과 열화모델연구사례

시설물의 노후화를 예측하기 위한 방법으로는 유지관리 이력 정보를 통한 상태기반 열화모델 기술로 시간의 경과에 따라 상태 변화 추이를 평가하는 방법으로 통계학적 기법을 적용한 기술이다. Fig. 1과 같이 해당 기술은 시간 경과에 따른 열화를 도식화 함으로써 전체적인 경향성을 파악하는 것에 있어 효과적이거나 포괄적 경향으로 세부적이고 구체적인 문제점 판단이 어려운 단점을 가지고 있다.

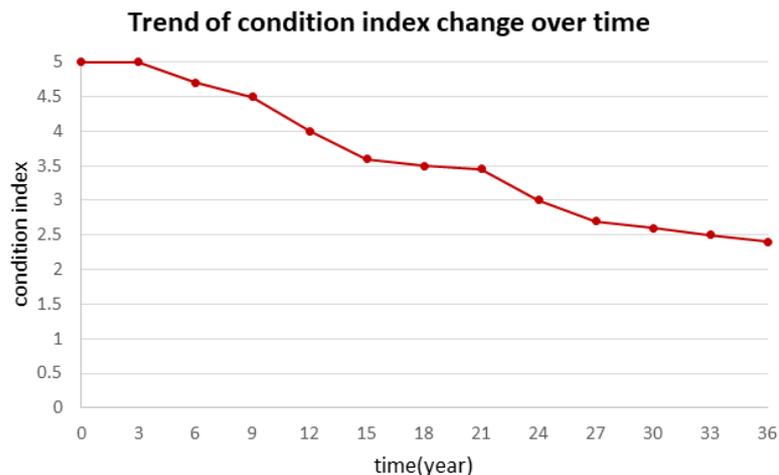


Fig. 1. The trend of condition index in change of the time

프로젝트 수준의 열화모델 패턴 또한 많은 유사구조형식의 정보를 조사분석하여 좀 더 일반화된 패턴을 만들어 가야 하기에 이 또한 기존 시설물에 대한 정보가 없다면 개발에 한계가 발생하게 된다. Fig. 2와 같이 부재단위수준(Element Level)의 열화모델 패턴을 연구한 사례가 있으며 이 또한 특성 부재에 대한 많은 과거이력 정보를 바탕으로 그 공통된 특성을 찾아 패턴을 분석할 수 있다. 차경화(2015)는 다중 회귀분석 및 Markov Chain을 통한 항만 시설물의 상태열화모델 개발 연구에서 동해안 비컨테이너 화물을 취급하며 유지관리 수준이 취약한 잔교식 구조물에 대하여 부재별 산출된 전이확률을 바탕으로 잔교식 구조물과 블록식 구조물의 부재별 상태열화모델을 개발하였다(Cha et al., 2015).

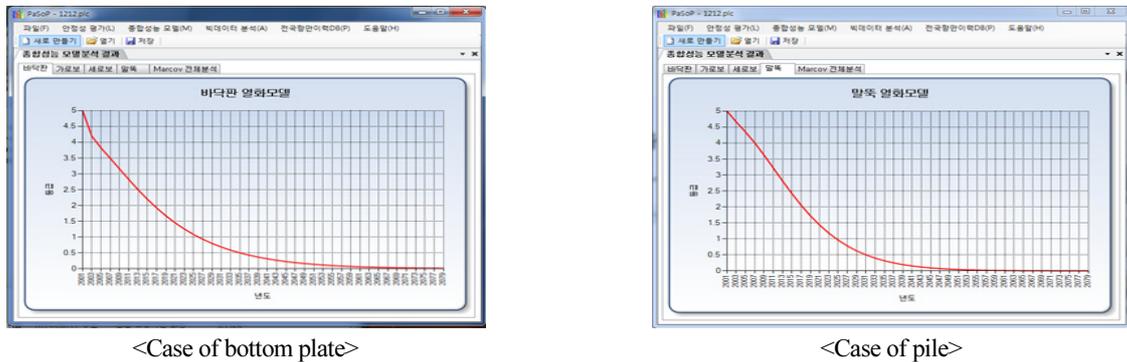


Fig. 2. Cases of deterioration model development by member unit

이러한 상태기반 열화모델을 개별시설 특성에 맞게 개발을 위해서는 정보의 확보 깊이가 매우 중요하다. 기본정보에서부터 그 개별시설이 가지고 있는 내적 특성과 외부환경특성, 즉, 구조물에 미치는 다양한 특성을 파악함으로써 개별시설물에 적합한 상태변화특성 분석이 가능하다. 그러나 위 사례와 같이 부재단위의 특성을 파악하여 좀 더 세부적인 열화모델패턴을 개발하기가 그리 쉽지는 않다. 그리고 어느 특정한 부재단위의 패턴이 동일 유형의 구조형식에 일반화하여 적용하기에는 더욱 어려운 실정이다.

빅데이터분석을 위한 영향인자의 선정

시설물의 성능이나 열화패턴분석에서 중요한 것은 과거부터 현재까지 시설물에 관한 많은 정보를 아는 것이다. Fig. 3과 같이 해당 시설물의 기본정보뿐 아니라 다양한 상세 및 현황 정보, 과거 어떤 유지보수 및 보강이 있었고, 어느 부분이 문제가 되었으며, 지역적으로 환경적으로 지속적으로 문제가 되고 있는 것이 무엇인지를 아는 것은 매우 중요하다. 즉, 정보를 많이 가지고 있으면 있을수록 좀 더 정확한 예측을 수행할 수 있다.

안벽에 대한 상태변화의 영향인자들에 대한 연구는 지속적으로 이루어져 왔다. 우리나라의 경우, 해역특성별로 동일한 구조형식이어도 외부하중의 영향이 다르게 나타나는 것으로 파악되고 있다. 서해안에 설치된 케이슨의 경우, 조수간만의 차가 심하여 다른 지역에 비해 이격이나 에이프론의 침하가 심하게 나타나고 있는 것으로 평가되고 있다.

본 연구에서는 이러한 해역별, 구조형식별, 주변환경 등의 특성들을 조사분석하여 개별 항만시설과 관련된 정보의 수준에 따라 상태기반 열화모델을 생성할 수 있는 방안을 제시하였다. 즉, 빅데이터 분석을 통한 시설물의 상태기반 열화모델의 수준을 추정함으로써 이력 데이터가 빈약한 시설에 대해서도 어느 정도 추이를 파악할 수 있도록 하고자 하였다. 빅데이터를

활용한 상태기반 열화모델개발을 위한 영향 인자들의 대상은 주로 안벽과 관련된 특성을 나타낼 수 인자들로 대상은 다음과 같다.

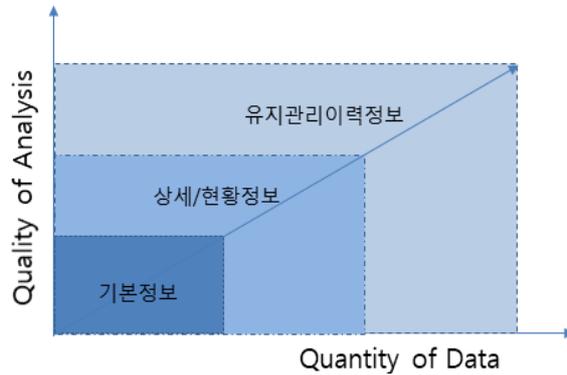


Fig. 3. The amount of information available and the level of big data analysis

Fig. 4에서 보듯이 기본정보수준에서 활용할 수 있는 인자가 있으며 상세이력정보수준에서 얻을 수 있는 데이터가 있다. 이러한 상세유지관리이력정보를 통해 시설물의 변화특성을 파악가능한 많은 정보들이 있으며 이러한 정보는 상태기반 열화 패턴 분석의 중요인자로 고려될 수 있어 이러한 기준을 근간으로 취합 가능한 정보를 기반으로한 빅데이터 분석 열화모델을 개발하였다.



Fig. 4. Factors influencing big data analysis of quay facilities

항만시설물 성능개선을 위한 빅데이터 분석

항만 시설물에 대한 유지관리 활동이 실효성을 가지다는 것은 점검을 통한 보수보강 조치가 구조물의 성능개선과 장수명화에 기여한다는 것을 간접적으로 증명하고 있다. 그러나, 유지관리 활동을 통해 시설에 대한 보수보강공사가 이루어진 이후 이로 인한 성능개선의 정보와 연계성을 확인하기 어려운 실정이다. 본 연구에서는 수집된 국내 항만 시설물에 대한 유지관리 이력 정보를 바탕으로 실제 진단 정보 데이터를 바탕으로 노후화 예측 근사모델을 검토함으로써 시설물의 노후화 패턴을 분석하고 시간의 경과에 따른 추이를 바탕으로 보수보강에 대한 의사결정을 지원하기 위한 기술 개발로써 연구를 진행하였다.

종합성능평가 대상시설 분석

빅데이터 분석을 위해 수집한 중력식 안벽 항만시설의 정보를 정리하면 다음과 같다. 국내 중력식 항만시설물에 대해 수집한 시설 목록은 Table 1과 같으며 해당 분석자료와 데이터 수준을 근거로 하여 빅데이터 분석을 위한 기계학습 방법론을 조사 분석하였으며 이를 실제 상태진단평가 결과와의 부합성을 검토하고 미래 상태변화추이 모델을 제시하였다.

Table 1. Gravity-type quay port facility data

해역명	항만명	부두명	시설타입	구조형식	사용년수('21)	진단년도	평가등급
서해	군산항	A부두	안벽	중력식	31	2003	C
		B부두			17	2018	B
		C부두			17	2018	B
동해	울산항	D부두			23	2017	B
		E부두			24	2017	B
		F부두			12	2018	A
		G부두			24	2018	B
남해	마산항	H부두			56	2003	C
		I부두			16	2011	A
	부산항	J부두			16	2016	B
		K부두	31	2011	A		
		L부두	31	2016	B		

상태기반 노후도 패턴과 열화 근사모델 검토

일반적으로 기계학습에 사용되는 데이터의 종류는 크게 3가지로 분류된다. 먼저 항만시설물의 노후화 패턴을 분석하여 열화를 예측하기 위한 근사모델을 생성하기 위해 필요한 트레이닝 데이터(Training Data)와 학습과정에서 과도한 학습이 수행되지 않도록 발생할 수 있는 오차를 감소시키기 위한 데이터로 생성된 근사모델을 확인 및 검토하는 평가 데이터(Validation Data)가 있으며 학습에 사용되지 않은 데이터를 바탕으로 근사모델의 예측결과를 검증하기 위한 테스트 데이터(Test Data)가 있다.

본 연구에서 사용된 머신러닝 기법은 GP(Gaussian Process)와 SGP(Sparse Gaussian Process) 기법으로 예측모델을 생성하였으며 항만시설물의 유지관리 이력데이터 중 안벽타입의 중력식 구조물의 데이터를 바탕으로 분석을 수행하였다.

가우시안 프로세스

GP 기법은 평균 함수와 분산 함수로 완전히 정의된 무한 차원 가우시안 분포 분석 이론으로 트레이닝 데이터를 샘플로 모델링하여 근사값을 구성하는 유연한 비선형 비파라메트릭 기법이다. 근사치는 실험적으로 선택된 분산함수를 사용하여 고려되는 가우시안 프로세서의 분석 후 평균을 기반으로 하며 GP는 일반적으로 중소 표본의 크기의 경우 분석이 정확한 경향을 가진다.

GP를 사용하면 제공된 학습 데이터와 정확히 일치하는 근사치를 구성할 수 있으며 해당 기술은 고려된 가우시안 프로세서의 사후 공분산을 기반으로 정확도 추정을 제공한다(Belyaev et al., 2015).

$$GPf(X) = cov(f(X), f(X^1)) = k(X, X^1) \quad (1)$$

$$k(X, X^1) = E[(f(X) - m(X))(f(X^1) - m(X^1))] \quad (2)$$

학습 데이터가 (X, Y) 라고 가정할 때 GP $f(X)$ 는 다음과 같다.

$$Y_i = y(X_i) = f(X_i) + \varepsilon_i, i = 1, 2, \dots, |S|, \quad (3)$$

이와 같이 정의될 수 있으며 여기서 ε 의 평균이 0이고 분산이 σ^2 인 가우스 함수로 모델링 되는 방식이다. GP의 매개 변수는 적응형 정규화를 사용하는 알고리즘에 의해 최적화되어 근사화의 일반화 분석이 향상되며(Belyaev et al., 2016), GP기법은 학습 데이터량에 따라 2 차적으로 확장되는 기법이다(Rasmussen et al., 2005). 본 연구에서 적용한 가우시안 프로세스의 특성은 다음과 같다. 가우시안 프로세스는 입력 데이터 x_i 집합에 대한 출력 데이터 $f(x_i)$ 의 집합 $f(X)$ 로 표현할 수 있으며, 출력 데이터들은 가우시안 분포(Gaussian distribution)의 형태를 지닌다. 이러한 가우시안 프로세스는 식(1)와 같이 평균 함수(mean function, $m(X)$)(식(2))와 공분산 함수(covariance function, $k(X, X^1)$)로 정의할 수 있다. 공분산 함수 $k(X, X^1)$ 는 입력 데이터와 출력 데이터 간의 상관관계를 나타내며, 공분산 함수를 나타내기 위한 다양한 커널 함수들이 있다.

스파스 가우시안 프로세스

본 논문에서 비교 검토되는 스파스 가우시안 프로세스(SGP) 기법은 적절하게 선택된 훈련 데이터의 하위 집합만 사용하여 해당 공분산 행렬을 근사화하고 이러한 제한을 해제하는 기법이다(Burnaev et al., 2015). SGP기법은 대량의 학습 데이터의 근사치를 분석하기 위한 방법으로 학습 데이터에서 기준점을 선택하고 해당 기준점으로 학습된 GP의 매개변수로 초기화하여 변수를 계산하는 방식이다. 단, SGP는 고정함수의 모델링을 위한 분석 기법으로 공간적으로 불균일한 함수, 불연속적인 함수 등의 모델링에서는 적합하지 않을 수 있다는 단점을 가지고 있다(Burnaev et al., 2016).

본 연구에서 분석하고자하는 대상은 항만시설물중 안벽타입의 중력식 구조물에 대한 성능평가를 통한 상태등급 데이터로써 GP 기법과 SGP 기법에 모두 적용가능한 데이터 특성을 가지고 있으나 실제 적용 및 테스트를 통해 보다 적합한 머신러닝 기법을 검토할 필요가 있다.

빅데이터방법론을 적용한 항만시설 상태기반 열화모델 테스트 및 결과

상태기반 노후도 패턴과 열화 근사모델 테스트

중력식 항만시설 유지관리 이력 데이터

중력식 항만시설의 유지관리 이력데이터인 정밀안전진단 보고서로 수집한 빅데이터를 기반으로 상태기반 열화 근사모델을 생성하기 위한 데이터의 수집 및 정의하였다. Table 2와 같이 항만시설에 대하여 형식, 규모, 연장, 준공년도, 진단년도에 따른 부재별(손상항목별) 상태등급 등의 데이터를 수집하였으며 분석을 위해 분류항목을 수치화 하였으며 시설물의 보수보강 조치에 따라 노후화 예측에 상반된 성향을 가지는 데이터를 범위에서 제외하는 과정을 통해 데이터를 수집 분류하였다.

본 분석에 사용된 중력식 안벽의 개수는 총 12개이며, 부재별로는 본체부, 에이프론, 기초부등으로 구분하였으며, 총 데이터의 개수는 460여개를 활용하였다. 대부분의 자료는 1990년부터 2019년까지 파악된 정밀안전진단 이력을 사용하였다.

Table 2. Condition data by member damage type of gravity port facilities

Sample No.	시설별	구조 형식	해역	규모	선석	연장	준공 년도	수심	부재명	손상항목	진단 년도	공용 년수	상태등급		
													min	max	avg
#01	안벽	중력식	서해	25,000	3선석	551	1990	10	상부공 및 본체부	활동	2003	31	3	4	3.83
#02	안벽	중력식	서해	25,000	3선석	551	1990	10	상부공 및 본체부	파손	2003	31	2	3	2.79
#03	안벽	중력식	서해	25,000	3선석	551	1990	10	상부공 및 본체부	균열 (일반균열)	2003	31	3	4	3.92
#04	안벽	중력식	서해	25,000	3선석	551	1990	10	상부공 및 본체부	박리 (완전박리, 부분박리)	2003	31	2	3	2.64
#05	안벽	중력식	서해	25,000	3선석	551	1990	10	상부공 및 본체부	마모/침식	2003	31	3	3	3
#06	안벽	중력식	서해	25,000	3선석	551	1990	10	에이프론	침하	2003	31	3	5	3.63
#07	안벽	중력식	서해	25,000	3선석	551	1990	10	에이프론	포장의 손상	2003	31	3	5	3.9
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
#456	안벽	중력식	남해	30,000	1선석	240	1990	12	상부공 및 본체부	속채움재 유실	2016	31	5	5	5
#457	안벽	중력식	남해	30,000	1선석	240	1990	12	상부공 및 본체부	케이스 및 블록 이격	2016	31	4	5	4.60
#458	안벽	중력식	남해	30,000	1선석	240	1990	12	기초부	세굴	2016	31	5	5	5
#459	안벽	중력식	남해	30,000	1선석	240	1990	12	기초부	기초사석 교란	2016	31	5	5	5
#460	안벽	중력식	남해	30,000	1선석	240	1990	12	에이프론	침하	2016	31	3	5	3.40
#461	안벽	중력식	남해	30,000	1선석	240	1990	12	에이프론	포장의 손상	2016	31	3	5	3.80
#462	안벽	중력식	남해	30,000	1선석	240	1990	12	에이프론	공동 (콘크리트 포장하부)	2016	31	5	5	5

상태안전성능 평가 결과 계산식 활용 및 데이터 적용

중력식 안벽에 대한 상태평가 지수의 도출은 ‘시설물의 안전 및 유지관리 실시 세부지침(성능평가 편)-2019년’ 의 전체 구조물에 대한 상태안전성능 평가 결과 계산식을 준용하여 결과가 도출되도록 구성하였다. 즉, 조사대상 전체 구조물에 대한 상태안전성능 평가 결과는 각 조사단위의 상태지수를 이용하여 전체 구조물에 대한 상태지수를 구하고 그 값에 따라 결정한다.

$$\text{전체 구조물의 상태지수 } CI = L + 0.3(H - L) \frac{\sum_{n=1}^N (CI)_n \times l_n}{5 \sum_{n=1}^N l_n}$$

- 여기서, L = 포함된 조사단위의 상태지수 중 최솟값(가장 나쁜 결과에 해당)
 H = 포함된 조사단위의 상태지수 중 최댓값(가장 좋은 결과에 해당)
 N = 포함된 총 조사단위 수
 $(C = n$ 번째 조사단위의 상태지수
 $l_n = n$ 번째 조사단위의 길이

수정 프로젝트레벨의 열화패턴 추정모델은 개별 부재별(본체부, 에이프론, 기초부) 상태지수를 연도별로 분배하고, 이를 패턴 인식 학습을 통해 뿌려줌으로서 전체 구조물의 상태지수가 추출될 수 있도록 학습을 시켜 개발하였다.

중력식 항만시설 상태기반 열화 근사모델 생성

항만 시설물의 유지관리 이력데이터인 정밀안전진단 보고서로 수집한 빅데이터를 바탕으로 본 논문에서 검토된 GP 및 SGP 기법의 머신러닝 알고리즘으로 근사모델을 각각 생성하였다. 항만시설물 중 안벽타입의 중력식 구조물에 대한 빅데이터를 학습데이터로 활용하여 생성된 근사모델은 Fig. 5와 Fig.6과 같이 시설물의 사용년수별 상태등급을 나타낸 그래프로써 시간이 경과함에 따라 노후화가 진행되는 것을 확인할 수 있었다.

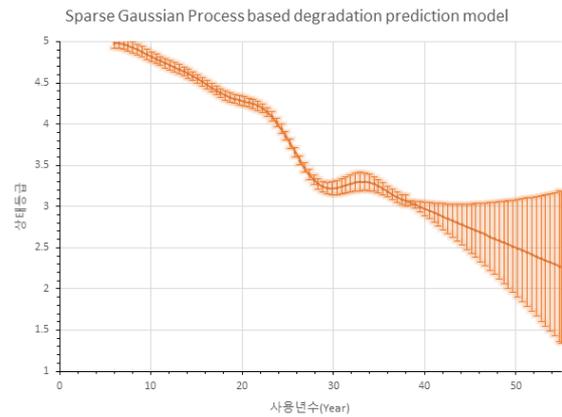
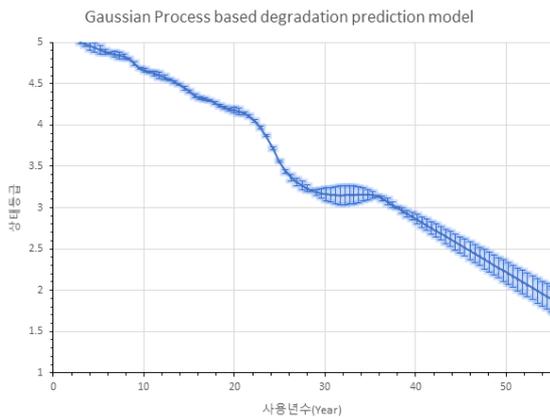


Fig. 5. Gaussian process based degradation prediction model **Fig. 6.** Sparse Gaussian process based degradation prediction model

기존의 다변수회귀 또는 Markov Chain 기법의 열화모델의 양상과는 다른 패턴의 노후화 추세를 나타내고 있다. 이와 같은 결과는 기존의 통계학적 수식을 바탕으로 분석되는 열화모델과는 다르게 실제 항만시설물의 정밀안전진단을 수행하면서 얻어진 상태등급데이터를 반영하여 생성된 근사모델로써 본 논문에서 검토된 안벽타입의 중력식 항만시설물과 동일한 타입의 시설물에 대해보다 구체적인 노후화 패턴을 분석하기 위한 방법으로 제안될 수 있다.

상태기반 노후도 패턴과 열화 근사모델 유효성 검증

항만 시설물의 상태기반 노후도 패턴 및 열화 근사모델을 생성하기 위하여 데이터 특성에 적합한 모델을 선택하기 위하여 다음 식 (4) and (5)와 같이 제공된 평균제곱오차(RMSE, Root Mean Squared Error)와 R^2 통계량(R^2 , 결정계수)를 바탕으로 생성된 모델에 대한 적합성 평가를 통해 근사모델의 예측정확성을 상호비교하였다.

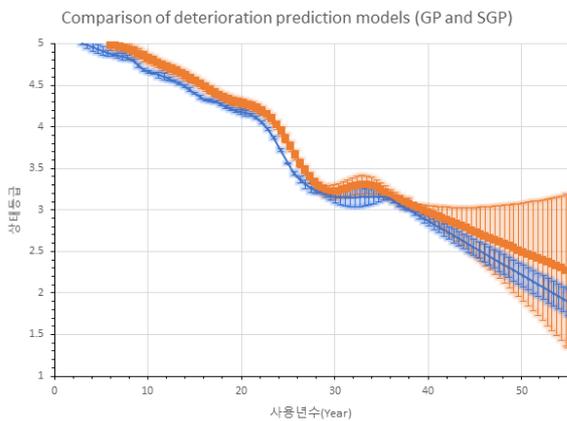
$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \tag{4}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \tag{5}$$

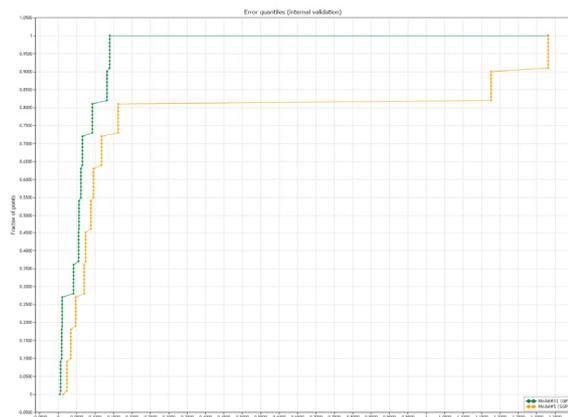
여기에서, y_i 는 테스트 데이터의 사용년수별 상태등급, \hat{y}_i 는 근사모델에 의한 상태등급 예측값, \bar{y}_i 는 테스트 데이터의 상태 등급값 평균을 의미한다. 본 논문에서 검토한 GP 및 SGP 기법을 적용하여 생성된 근사모델 예측결과를 테스트 데이터와 비교하여 각 모델의 예측 적합성을 분석을 수행하였다.

Table 3. Prediction accuracy of techniques

Tech	Accuracy		R^2
	GP	SGP	
	0.9854	0.7246	0.0721
			0.2518



<Comparison of deterioration prediction models>



<Comparison of Error quantiles>

Fig. 7. Comparison of models (GP and SGP)

Table 3은 항만시설물의 노후화 패턴 및 예측모델을 생성하기 위해 사용된 머신러닝 기법에 대한 적합도를 평가한 값으로 GP 기법이 RMSE는 0.98, R^2 는 0.07의 값으로 상당히 높은 정확도를 가지는 것을 알 수 있다. Fig. 7과 같이 GP 기법 대비 SGP 기법의 경우 주어진 데이터의 조건상에서의 적합성 검토에서는 상대적으로 낮은 정확도를 확인 할 수 있었다.

결론

본 연구는 중력식 항만시설의 구조형식별 상태변화이력과 관련 정보수준을 분석조사하여 이를 기반으로 빅데이터 분석을 수행하였다. 빅데이터분석의 핵심은 관련 영향인자의 데이터량이 많으면 많을수록 시설물의 성능과 상태를 분석할 수 있는 좋은 추정모델을 제시하게 된다. 본 연구에서는 이러한 분석을 위해 취합가능한 데이터를 정리하였고 이를 기반으로 영향인자의 정보수준별 제시가능한 상태기반 성능그래프를 도출하였다. 국내 항만시설의 진단을 통한 성능 및 안전에 대한 점검과 진단을 20년 넘게 진행되었지만 그 진단 이력과 결과를 활용한 중장기적인 시설개선과 성능개선을 위한 발전전략이나 방향이 현실적으로 작동하지 않고 있다. 특히, 사용년수가 오래된 항만구조물의 경우, 선박의 대형화와 사용빈도 증가, 기후변화로 인한 자연재해의 영향 등으로 안전성능과 기능적 면에서 상당히 많은 문제점을 내포하고 있다. 이와 같이 누적된 항만시설물의 유지관리 이력 데이터를 빅데이터로써 정의하고 해당 데이터를 바탕으로 시설물의 노후화 패턴 및 열화를 추정하기 위한 예측 근사모델을 도출하였다. 특히 GP 및 SGP 기법의 머신러닝 알고리즘을 통하여 생성된 상태기반 노후도 패턴 및 열화 근사모델에 대한 유효성 검토를 통해 빅데이터 활용에 적합한 모델을 상호비교하고 제안하였다. 제안된 기법의 적합성을 검토한 결과 GP기법은 RMSE 및 는 0.9854와 0.0721, SGP기법은 0.7246과 0.2518로 GP기법을 적용한 예측모델이 적합한 것으로 검토 되었으며 머신러닝 기법을 통해 이러한 연구는 향후 항만시설 데이터취합이 지속적으로 이루어진다면 향후 항만시설 투자 의사결정에 중요한 역할을 할 것으로 기대한다.

Acknowledgement

이 논문은 2021년 해양수산부 재원으로 해양수산과학기술진흥원의 지원을 받아 수행된 연구임(생애주기별 항만시설 통합 운영관리를 위한 BIM 기반기술 개발).

References

- [1] Belyaev, M., Burnaev, E., Kapushev, Y. (2015). "Gaussian process regression for structured data sets." Lecture Notes in Artificial Intelligence, International Symposium on Statistical Learning and Data Sciences, Vol. 9047, pp. 106-115.
- [2] Belyaev, M., Burnaev, E., Kapushev, Y. (2016). "Computationally efficient algorithm for Gaussian Process regression in case of structured samples." Computational Mathematics and Mathematical Physics, Vol. 56, No. 4, pp. 499-513.
- [3] Burnaev, E., Panov, M., Zaytsev, A. (2016). "Regression on the basis of non-stationary gaussian processes with bayesian regularization." Journal of Communications Technology and Electronics, Vol. 61, pp. 661-671.
- [4] Burnaev, E., Zaytsev, A. (2015). "Surrogate modeling of mutli-dimentionality data for large samples." Journal of Communications Technology & Electronics, Vol. 60, pp. 1348-1355.

- [5] Cha, K.H., Kim, S.W., Kim, J.H., Park, M.Y., Kong, J.S. (2015). “Development of the deterioration models for the port structures by the multiple regression analysis and Markov chain.” Computational Structural Engineering Institute of Korea, Vol. 28, No. 3, pp. 229-239.
- [6] Kim, H.J., Ju, G.N., Yun, C.H. (2012). “Science big data processing technology trend.” The Korea Institute of Information and Commucation Engineering, Vol. 29, No. 11, pp. 11-23.
- [7] Kim, S.W., Cha, K.H., Kim, J.H., Park, M.Y., Kong, J.S. (2012). “Development of condition state model for open type wharf considering deterioration factors.” Korean Society of Civil Engineers, Vol. 28, No.3, pp. 2138-2141.
- [8] Rasmussen, C.E. (2004). Gaussian Processes for Machine Learning. MIT Press, Massachusetts, USA, pp. 63-71.
- [9] Rasmussen, C.E., Williams, C.K.I. (2005). Gaussian Processes for Machine Learning (Adaptive Computation and Machine Learning), The MIT Press, Massachusetts, US.
- [10] Song, M.G., Kim, S.B. (2013). “A study of improving reliability on prediction model by analyzing method big data.” The Journal of Digital Policy & Management, Vol. 11, pp. 103-112.
- [11] Port Association (2010). Unit Model Development for LCC Analysis Program at Port Facility Design Stage, p. 40.