

머신러닝 기법과 계측 모니터링 데이터를 이용한 광안대교 신축거동 모델링

박지현 · 신성우** · 김수용**

부산시설공단 · *부경대학교 안전공학과 · **부경대학교 토목공학과
(2018. 9. 12. 접수 / 2018. 10. 1. 수정 / 2018. 10. 6. 채택)

Modeling on Expansion Behavior of Gwangan Bridge using Machine Learning Techniques and Structural Monitoring Data

Ji Hyun Park · Sung Woo Shin** · Soo Yong Kim**

Busan Infrastructure Corporation

*Department of Safety Engineering, Pukyong National University

**Department of Civil Engineering, Pukyong National University

(Received September 12, 2018 / Revised October 1, 2018 / Accepted October 6, 2018)

Abstract : In this study, we have developed a prediction model for expansion and contraction behaviors of expansion joint in Gwangan Bridge using machine learning techniques and bridge monitoring data. In the development of the prediction model, two famous machine learning techniques, multiple regression analysis (MRA) and artificial neural network (ANN), were employed. Structural monitoring data obtained from bridge monitoring system of Gwangan Bridge were used to train and validate the developed models. From the results, it was found that the expansion and contraction behaviors predicted by the developed models are matched well with actual expansion and contraction behaviors of Gwangan Bridge. Therefore, it can be concluded that both MRA and ANN models can be used to predict the expansion and contraction behaviors of Gwangan Bridge without actual measurements of those behaviors.

Key Words : bridge expansion joint, expansion behavior modeling, structural monitoring data, machine learning

1. 서론

교량의 부속장치중의 하나인 신축이음장치는 중요한 구성요소임에도 불구하고 설계, 시공 그리고 유지 관리에 있어서 다소 소홀히 다루어져 왔으나, 교량의 원활한 구조적 거동을 확보하기 위해서는 매우 중요한 부속장치로 점차 인식되고 있으며, 특히 교량의 신축 거동은 유지관리 분야에서 공용 중 교량 거동과 건전성을 쉽게 파악할 수 있는 중요한 지표로 많은 연구에 활용되고 있는 실정이다.

신축거동은 온도에 의한 교량의 신축거동과 콘크리트의 건조수축 및 크리프와 활하중 등에 의한 교량의 수평이동과 회전 등에 의해 발생된다. 설계에서 고려한 신축거동보다 과도하게 신장거동이 발생할 경우에는 Girder와 교대가 충돌 할 수 있고, 수축거동이 발생할

경우에는 낙교 등의 안전사고가 발생 할 수 있다. 교량 구조물의 이상 거동은 곧 교량의 기능을 상실하게 되고, 교통사고 등 2차 안전사고는 물론 사회적, 경제적 손실과 시민불편을 초래하게 된다.



Fig. 1. Expansion Joint Damage¹⁾.

* Corresponding Author : Sung Woo Shin, Tel : +82-51-629-6473, E-mail : shinsw@pknu.ac.kr

Department of Safety Engineering, Pukyong National University, 45 Yongso-ro, Nam-gu, Busan 48513, Korea

일례로 2018. 6. 24. 부산울산고속도로 만화교의 신축이음장치가 도로 노면 위로 15° 내지 30° 정도 솟아 올라 운행 중이던 차량 59대의 타이어에 구멍이 나고 극심한 교통정체가 발생하였을 뿐만 아니라 신축이음장치 보수에 따른 교통통제 등으로 인한 사회적/경제적 손실이 크게 발생한 바 있다. 따라서 교량의 신축거동이 정상범위에서 거동하는지를 예측하는 것은 교량 안전관리 측면에서 매우 중요한 요소라고 하겠다.

한편, 교량의 신축거동 예측과 관련한 많은 연구가 이루어져 왔으나 온도와 신축거동의 상관관계를 이용한 연구가 대부분이며^{2,3)} 온도하중, 교통하중, 풍하중 등 다양한 하중조합을 고려한 신축거동 예측에 대한 연구는 국내/외에서 거의 이루어지지 않은 실정이어서 이에 대한 연구가 필요하다.

일반적으로 교량의 신축 거동은 온도변화가 지배적인 것으로 알려져 있으나^{2,4)} 온도변화와 같은 환경작용 이외에도 하중작용에 의해서도 신축거동이 발생할 수 있다^{5,7)}. 따라서 신축거동을 정확하게 예측하기 위해서는 신축거동의 원인이 되는 변수를 이용한 이론적인 인과 모델이 필요하나 이러한 이론적 인과모델은 개발하기가 매우 까다로울 뿐만 아니라 개발에 드는 노력에 비해 정확도가 높지 않은 문제점이 있다. 한편, 최근에 교량 유지관리를 위한 예측 모델 개발 등에 교량 모니터링 시스템으로 계속한 데이터에 머신러닝 기법을 적용하는 연구가 많이 이루어지고 있다^{8,10)}. 머신러닝 기법을 이용한 예측 모델링의 장점은 입력과 출력 간의 이론적인 인과관계를 모르더라도 입력 데이터와 출력 데이터만으로 예측 모델을 구현할 수 있다는 것에 있다.

본 연구에서는 교량 유지관리에 있어서 중요한 지표인 신축거동에 대한 예측 모델을, 교량 모니터링 데이터와 대표적인 머신러닝 기법인 인공신경망 기법과 다중회귀 모델링 기법을 이용하여 개발하고자 한다. 개발 대상 교량은 부산광역시 소재한 광안대교로 선정하였으며, 이는 광안대교가 계속 모니터링 시스템이 구축되어 교량의 교통량 및 구조거동 데이터 수집에 용이할 뿐만 아니라, 개통 이래 15년 이상의 모니터링 시스템 운영을 통해 매우 방대한 양의 계속 데이터가 누적되어 활용 가능한 데이터가 매우 풍부한 장점이 있기 때문이다.

2. 연구대상 및 자료수집

2.1 연구대상 및 교량 모니터링 시스템

광안대교는 부산광역시 교통난 해소와 급증하는 항만물동량의 원활한 처리를 위하여 1994년 12월에 착공

하여 2003년 2월에 준공되었으며, 국내 최대 해상 복층 교량으로 총 연장 7,420 m이다. 이중 900 m의 현수교 구간인 광안대교의 교량 모니터링 시스템(Structural Health Monitoring System ; SHMS)은 주탑, 보강형 트러스, 케이블, 앵커 블록, 신축이음 등 구조적 변위가 비교적 큰 주요부위에 총 9종 79개의 계속센서가 설치되어 교량상태를 평가하는데 필요한 거동정보를 제공한다. 계속 센서는 각종 외부하중 또는 거동·변화작용에 대한 응답신호를 측정하며, 각각의 센서로 부터 측정된 신호는 데이터로거(Data Logger)에 저장된다.

데이터로거는 센서에서 측정된 신호를 수집하고 전송하는 장비로 정적로거(Static Logger)와 동적로거(Dynamic Logger)로 구성되어 있다. 광안대교의 정적로거는 10분에 1개의 데이터가 저장되며, 동적로거는 저장 용량의 관계로 매 10분 동안 계속한 데이터의 평균값 및 최대, 최소값이 저장되고, 이와는 별도로 고유진동수 등 구조물의 동특성 분석을 위하여 매일 오전 3시 30분부터 3시 40분까지 10분 동안은 원 자료(Raw Data)를 저장하도록 구축되었다.

데이터 로거에 저장된 계속 자료는 정적데이터의 경우 Serial 통신인 RS-232 케이블로 전송하며, 동적데이터의 경우에는 Ethernet 통신인 UTP/IP 케이블로 전송한다. 각각의 계속 데이터는 신호 변환 장치, 스위칭 허브와 광케이블을 통하여 교량 관리사무소까지 전송되며, 전송된 데이터는 통합 서버에 자동 저장되어 필요시 구조 거동 분석, 안전성 평가 등에 활용하고 있다²⁾.

2.2 데이터 수집

데이터의 수집기간은 단절 없이 가장 낮고 연속성이 확보되는 2006년 1월 1일부터 2006년 12월 18일까지 매 10분 단위의 총 4종 데이터를 센서당 50,561개의 빅 데이터를 수집하였다. 첫 번째 신축거동(ℓ)은 현수교 주탑 1번 하로 1,200 mm 신축이음장치의 거동에 대한 계속 데이터이고, 두 번째 온도(t)는 현수교 중앙경간 보강형 트러스 1/2지점 상, 하, 좌, 우에 설치된 부재 온도계에 대한 평균 계속 데이터이고, 세 번째 교통량에 의한 처짐(d)은 현수교 중앙경간 1/2지점 하부 설치된 레이저 변위계에서(최댓값과 최소값의 차이) 추출된 계속 데이터이다 (Fig. 2 참조).

마지막으로 풍속(w)은 현수교 중앙경간 1/2지점 상로 노면에서 4.5 m 높이에서 수집된 풍속 값을 변수로 수집 적용하였다. 여기서 연직변위는 동적로거에 의해 수집되었으며, 신축거동, 온도, 풍속 등은 모두 정적로거에 의해 수집되었다.




Fig. 2. Measured displacement data and sensor.

2.3 수집데이터 기술통계

수집된 자료의 기술통계를 살펴보면 공용 중 대상기간 동안 신축거동은 116 mm로 최대 39.6 mm, 최소 -76.4 mm로 나타났으며, 온도변화는 37.1℃로 최저 -4.1℃, 최고 33.0℃로 나타났다. 여기서 온도계는 현수교 보강형 트러스 상, 하, 좌, 우에 설치된 4개 온도계의 평균값을 적용하였으며, 이 평균값은 보강형 트러스에 대한 온도변화의 열팽창계수와 대기온도를 가장 잘 표현하는 것으로 나타났다.

Table 1. Descriptive statistics

	Unit	Range	Minimum	Maximum	Mean
Exp.	mm	116.0	-76.4	39.6	-23.6
Temp.	℃	37.1	-4.1	33.0	16.7
Displ	mm	232.4	8.7	241.2	50.2
Wind	m/s	20.9	0.1	21.0	3.9

Valid N (listwise) = 50,561

교통량에 의한 처짐 값은 선행연구¹¹⁻¹²⁾에서 밝혀진 바와 같이 연직변위의 최댓값과 최솟값의 차이를 활하중에 의한 변위로 규정하여 적용하였다. 처짐 변위의 범위는 232.4 mm로 신축거동의 약 2배 값을 보였으며, 최소 8.7 mm, 최고 241.2 mm로 나타났다. 풍속의 범위는 20.9 m/s로 최소 0.1 m/s, 최대 21 m/s로 나타났다.

3. 예측 모델의 구성

3.1 입력변수

도로교 설계기준에 의한 교량 신축이음장치 신축거동 산정은 받침의 이동량 산정에 근거하여 상부구조의 온도변화, 처짐, 콘크리트의 크리프 및 건조수축, 프리스트레스에 의한 부재의 탄성변형 등에 의해 생기는 이동량을 고려하며 신축거동을 산정하는 방법은 Eq. (1)과 같다.

$$\Delta l = \Delta l_t + \Delta l_s + \Delta l_c + \Delta l_r + \text{여유량} \quad (1)$$

여기서 Δl 는 계산 이동량(mm)이고 Δl_t 는 온도변화에 의한 신축량(mm)이고 Δl_s 는 콘크리트의 건조수축에 의한 수축량(mm)이고 Δl_c 는 콘크리트 크리프에 의한 수축량(mm)이고 Δl_r 는 활하중에 의한 보의 처짐에 의한 이동량(mm)이다.

도로교 설계기준 해설⁵⁾ 내진설계에서는 신축이음의 이동량을 산정할 때에는 지진 시 신축이음장치의 이동량(변위)은 고려하지 않는다고 설명하고 있다. 내진설계에서 규정하는 지진변위는 지진시 상부구조와 하부구조 사이에서 발생하는 상대변위에 대하여 교량과 교대 혹은 인접하는 교량간의 충돌에 의한 주요구조부재의 손상을 방지하기 위한 여유간격이다. 그리고 태풍 등 풍하중에 의한 신축이음장치의 변위에 대해서는 별도의 규정을 두고 있지 않으며, 도로교설계기준-한계상태설계법⁵⁾에서는 발생가능한 모든 하중들의 조합들 중에서 가장 불리한 경우를 적용하도록 규정하고 있다. 도로설계편람 제5편 교량⁷⁾ 등에서는 예상하지 못하거나 확실하지 않은 계산에 대해 충분한 여유간격을 확보하기 위해 이동량의 계산에 신축 여유량과 설치 여유량을 포함하도록 규정하고 있다.

교량의 안전 및 유지관리 측면에서 신축거동의 가장 중요하고 지배적인 영향을 받는 변수는 온도이지만, 도로교설계기준⁶⁾에서 명시한 바와 같이 발생 가능한 모든 하중들을 변수로 조합해 보수적으로 신축거동을 예측하는 것이 안전측면에서 합리적이라고 하겠다.

본 연구에서는 광안대교가 강교이므로 신축거동의 예측에 있어 Eq. (1)에서 설명한 독립변수인 온도와 활하중에 의한 처짐을 적용하였으며, 선행연구^{2,13)}에서 태풍과 같이 강한 바람에 의한 영향이 신축거동에 영향을 미치는 것으로 밝혀져 독립변수에 추가하였다. 반면 콘크리트교에서 발생하는 크리프와 건조수축의 신축거동은 변수에서 제외하였고, 공용 중인 교량이 연구대상이므로 여유량은(신축, 설치) 변수에서 제외하였다.

한편, 본 연구의 모델링 방법론에 있어 첫 번째 방법은 다양한 변수를 이용하여 상관관계를 바탕으로 원인과 결과를 통계적 가정과 이론에 기반하여 예측하는 다중 회귀분석(Multiple Regression Analysis ; MRA)에 의한 모델링을 이용하였다. 다중회귀분석에 의한 모델링 기법은 가장 보편적인 통계학적 모델링 기법으로 모델링 과정에서 반복적인 계산 등이 필요하지 않아 모델링이 간편한 장점이 있으며 머신러닝의 초기 연구에서 많이 활용된 방법이다. 두 번째 방법은 모델의 구조가 매우 복잡하거나 단순회귀분석으로는 정확한 예측 모델의 구성이 어려운 경우에, 패턴인식에 기반하여 예측 모델을 구현할 수 있는 인공신경망(Artificial

Neural Network ; ANN) 기법을 이용하였다. 인공신경망 기법은 통계적 가정이 필요하지 않고, 인간의 두뇌와 같이 독립변수인 입력 값과 종속변수인 출력 값의 학습을 통해 예측 모델을 상대적으로 정확하게 구현할 수 있는 장점이 있어 딥러닝 등 최근 머신러닝 기법으로 많이 활용되고 있다¹⁴⁻¹⁵⁾.

3.2 다중 회귀 모델

회귀분석은 하나의 양적 변수(종속변수, 반응변수)와 여러 개의 양적 변수(독립변수, 설명변수)들 사이의 관계식을 추정해서 독립변수가 종속변수에 미치는 영향력을 설명하거나 새로운 독립변수 값에 대한 종속변수의 값을 예측하고자 할 때 사용하는 분석 기법이다¹⁶⁾.

단순 선형회귀 모형은 종속변수 Y 와 하나의 독립변수 X 의 선형관계식을 추정하는 것으로 두 변수 사이의 관계는 Eq. (2)과 같다.

$$Y = \beta_0 + \beta_1 X + \epsilon \quad (2)$$

독립변수 X 의 값이 동일한 개체들이라도 종속변수 Y 의 값이 모두 동일하지는 않을 것이기 때문에 개체에 따른 차이를 오차 ϵ 으로 표시하였다. 이때 ϵ 의 분포는 $N(0, \sigma^2)$ 를 따르고 오차 항은 서로 독립이라고 가정한다. β_0 와 β_1 의 추정치를 각각 b_0 와 b_1 이라고 하면 표본으로부터 추정한 회귀방정식은 Eq. (3)가 된다.

$$\hat{Y} = b_0 + b_1 X \quad (3)$$

위 단순회귀모형에서 독립변수가 $X_1, X_2, X_3, \dots, X_k$ 인 경우 다중회귀모형으로 확장하여 β_0 와 $\beta_1, \beta_2, \dots, \beta_k$ 의 추정치를 각각 $b_0, b_1, b_2, \dots, b_k$ 라고 하면 표본으로부터 추정한 회귀방정식은 Eq. (4)와 같다.

$$\hat{Y} = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_k X_k \quad (4)$$

강교의 신축거동은 이론적으로 여유량을 제외하고 온도과 활하중에 의한 처짐에 대한 신축거동의 합으로 산정할 수 있으므로, 실제 신축거동이 온도와 활하중에 의한 처짐(교통량에 의한 처짐)과 선행연구^{2,13)}에서 밝혀진 바와 같이 바람(풍속)에도 영향을 받는지에 대하여 검증하고자 하였다. 귀무가설(H_0)은 “독립변수(온도, 교통량에 의한 처짐, 풍속)가 신축거동에 영향을 미치지 않는다”이며 연구가설(H_1)은 “독립변수(온도, 교통량에 의한 처짐, 풍속)가 신축거동에 영향을

미칠 것이다”로 설정하고 회귀계수에 대한 귀무가설과 연구가설은 Eq. (5), (6)과 같다.

$$H_0 : b_i = 0 \quad (i=0, t, d, w) \quad (5)$$

$$H_1 : b_i \neq 0 \quad (i=0, t, d, w) \quad (6)$$

교량 신축거동(ℓ)을 종속변수로 교량 부재 온도(t), 교통량에 의한 처짐(d), 풍속(w)을 독립변수로 하여 다중회귀모델을 Eq. (7)와 같이 설정하였다.

$$\hat{Y}_\ell = b_0 + b_t X_t + b_d X_d + b_w X_w \quad (7)$$

3.3 인공 신경망 모델

인공신경망은 일반적으로 입력 층(Input Layer)과 출력 층(Output Layer) 사이에 하나 이상의 은닉 층(Hidden Layer)이 포함된 계층 구조의 형태이며, 각 층들은 뉴런에 해당하는 노드로 구성되고 각 노드들은 시냅스에 해당하는 연결망으로 구성한다. 인공신경망을 이용한 예측 모델링 과정은 각 뉴런의 입력 값에 연결강도(가중치)를 곱하고 여기서 산출된 값을 다시 활성화 함수(Activation Function)에 적용하여 출력 값을 결정하는 전방전파(Forward Propagation) 과정과 전방전파로 결정된 출력 값과 목적 값을 비교하여 오차를 계산하고, 이러한 오차를 역으로 전파하여 연결강도를 조정하는 과정인 오차 역전파 과정을 반복적으로 수행하여 출력 층의 오차 값이 목적 값에 근접하는 연결강도를 최종적으로 결정하는 오차 역전파(Error Back Propagation) 학습법이 많이 사용된다.

본 연구에서의 인공신경망 모델은 다중회귀모델과 같이 독립변수인 온도(X_t), 교통량에 의한 처짐(X_d), 풍속(X_w)을 인공신경망 모델에 입력변수로 적용하고 종속변수인 신축거동(Y)을 출력변수에 적용하여 앞서 기술한 오차 역전파 학습 방법으로 신축거동의 예측 값(\hat{Y}_ℓ)을 결정하도록 하였다(Fig 2). 한편, 인공신경망 모




Fig. 2. Artificial neural network model structure.

Table 2. Design of artificial neural network model topology

Number of hidden layers	Number of nodes		RMSE (mm)	R ² (%)
	Hidden layer 1	Hidden layer 2		
1	2	-	8.210	86.816
	3	-	8.220	86.784
	4	-	8.257	86.666
2	2	2	8.234	86.741
		3	8.273	86.615
		4	8.317	86.647
	3	2	8.284	86.579
		3	8.286	86.573
		4	8.240	86.720
	4	2	8.248	86.695
		3	8.248	86.695
		4	8.351	86.360

델 개발 시에는 인공신경망 각 층의 노드 개수 및 은닉 층의 수와 같은 인공신경망 토폴로지(Topology)의 결정이 필요하다. 그러나 인공신경망 토폴로지 설계 시에 은닉 층의 수와 연결 노드의 수를 몇 개로 할 것 인지를 결정하는 이론적인 방법은 아직 없는 상태이며, 일반적으로 여러 토폴로지를 가정하고 각 토폴로지의 성능을 비교하여 가장 우수한 성능을 나타내는 토폴로지를 선정하는 방법이 많이 이용된다¹⁷⁾.

본 연구에서는 은닉 층의 수와 각 층의 노드 수를 결정하기 위하여, Table 2에 나타낸 바와 같이 은닉 층의 수와 노드의 수가 서로 다른 총 12개의 신경망 모델을 대상으로 성능 평가를 하였으며, 출력 오차가 RMSE 기준으로 가장 작은 1개의 은닉 층에 2개의 노드를 가진 Fig. 2와 같은 형태의 신경망을 예측 모델링에 적용하였다.

4. 모델의 검증 및 성능평가

총 4종의 변수 데이터를 이용하여 훈련용 데이터(Training Data Set) 80%, 검정용 데이터(Test Data Set) 20%를 난수생성기에 의해 무작위로 추출하였으며, 훈련용 데이터를 이용하여 교량 신축거동 예측을 위한 다중회귀모델(Multiple Regression Analysis Model : MRA)과 인공신경망모델(Artificial Neural Network Model : ANN)을 각각 개발하였다. 개발된 모델에 검정용 데이터를 적용하여 성능평가를 실시하였다.

여기서 MRA 모델은 도로교 설계기준⁵⁾에서 명시한 바와 같이 보수적 관점에서 공용중인 교량의 측정 가능한 온도, 교통량에 의한 처짐, 풍속 등 하중조합을 이용한 신축거동 예측 모델이며, ANN 모델은 이러한

통계모델(MRA) 변수들의 학습을 이용하여 교량 신축 거동의 예측모델이다. 여기서는 각 모델의 예측성능을 고찰하고자 하였다.

4.1 다중회귀분석을 이용한 예측 모델링

동시입력방식으로 다중회귀분석을 실시하였으며, 다중회귀 모델의 분석결과 분산분석(ANOVA)에서 F값은 85,244.000, 유의확률은 .000(p<0.01)으로 나타났고, 종속변수와 독립변수의 상관계수는 0.929로 높은 상관관계를 보였으며, 회귀식에 대한 R²는 .863로 높은 설명력을 보여주고 있다. 즉, 3개의 독립변수는 종속변수를 86.3% 설명하고 있다. 독립변수 온도(t = -498.89, p = .000)와 교통량에 의한 처짐(t = 13.753, p = .000), 풍속(t = 4.771, p = .000)이 종속변수인 신축거동에 대하여 통계적 유의수준 하에서 영향을 미치는 것으로 나타났다.

Table 3. Coefficients of multiple regression analysis model

		(Constant)	t	d	w
Unstd. coefficients	b	19.863	-2.705	.028	.093
	Std. Error	.171	.005	.002	.019
Std. coefficients	β		-.927	.025	.009
t-value		115.983	-498.890	13.753	4.771
p-value		.000	.000	.000	.000
Collinearity statistics	Tolerance		.977	.999	.976
	VIF		1.023	1.001	1.025
Model summary		R = .929, R ² = .863, Adjusted R ² = .863, F = 85,244.000, p = .000			

**p < 0.01

한편, 다중공선성에서 온도(VIFi = 1.023, Toli = 0.977)와 교통하중에 의한 처짐(VIFi = 1.001, Toli = 0.999), 풍속(VIFi = 1.025, Toli = 0.976)의 공차한계(Toli; Tolerance)가 0.1이상, 분산팽창요인(VIFi; Variance Inflation Factor)이 10이하로 나타나 다중공선성에 문제가 없는 것으로 확인 되었다(Table 3).

종속변수인 신축거동에 영향력을 나타내는 표준화 계수(β)에서 온도는 -.927, 교통하중에 의한 변위는 .025, 풍속은 .009로 나타나 독립변수 중에서는 신축거동에 대하여 온도가 가장 큰 영향력을 미치는 것으로 나타났고, 교통량에 의한 처짐과 풍속의 순서로 나타났다. 독립변수에서 표준화 계수가 말해주듯이 활하중에 의한 처짐과, 풍속은 온도에 비교하여 상대적으로 매우 낮은 영향력을 미친다는 것을 알 수 있었다. 다중회귀모델을 회귀식으로 나타내면 Eq. (9)과 같으며, 귀무가설(H₀)은 기각되고, 연구가설(H₁)이 채택되었다.

$$\hat{Y}_i = 19.863 - 2.705X_t + 0.028X_d + 0.093X_w \quad (9)$$

Table 4. Pearson's correlations

	ℓ	t	d	w
ℓ	1			
t	-.929**	1		
d	.029**	-.004	1	
w	.146**	-.148**	-.035**	1

** p<0.01

한편, Pearson의 상관관계 분석을 실시한 결과 신축 거동과 온도는 -.929로 음의 매우 높은 상관관계의 강도를 보였으며, 신축거동과 교통량에 의한 처짐은 .029, 신축거동과 풍속은 .146, 온도와 풍속은 -.148, 교통량에 의한 처짐과 풍속은 -.035로 유의수준(p<0.01) 하에서 매우 낮은 상관관계의 강도를 보였다. 그러나 온도와 교통량에 의한 처짐의 상관관계는 유의하지 않은 것으로 나타났다(Table 4).

즉 신축거동에 미치는 활하중의 영향이 교통하중 이외에도 풍하중을 고려하는 것이 적절하다는 것을 입증하는 것이며, 이는 온도영향을 배제한 처짐 값과 신축 거동에 대한 선행연구에서도 유사한 의미의 결과를 보여주고 있다¹⁸⁾.

4.2 인공신경망을 이용한 예측 모델링

공용 중 교량의 신축거동 사전 예측을 위한 인공신경망 모델 구축을 위해서는 기존의 신축거동, 온도, 교통하중에 의한 처짐, 풍속 등 계측데이터를 이용하여 모델의 학습과정이 선행되어야 한다. 본 연구에서는 인공신경망 모델 학습을 위해서 다중회귀모델링과 동일하게 총 데이터수의 80%를 신경 네트워크의 학습(Training Data Set)에 사용하였다.

훈련유형은 큰 크기의 자료에 적당한 온라인 타입(Online Type)을 적용하였고, 최적 알고리즘은 경사 하강법(Gradient Descent)이며, 활성화 함수(Activation Function)는 은닉 층에서 쌍곡 탄젠트 함수(Hyperbolic Tangent), 출력 층에서는 시그모이드(Sigmoid) 함수가 사용되었으며, 그밖에 훈련옵션은 Table 5와 같다.

Table 5. Training options

Parameter	Value
Initial Learning Rate	0.4
Lower Boundary of Learning Rate	0.001
Learning rate reduction, in Epochs	10
Momentum	0.9
Interval Center	0
Interval Offset	±0.5

Table 6. Independent variable importance

	Importance	Normalized importance
t	.829	100.0%
d	.131	15.8%
w	.040	4.8%

학습결과 은닉 층은 1개, 뉴런은 2개를 발생시켰으며, ANN 모델의 결과를 예측할 때 독립 변수의 중요도를 나타내고 있다. 중요도 수준은 100의 척도로 정규화되며, 신축거동에 미치는 영향력에 대한 중요도는 온도가 .829로 가장 높았고, 활하중에 의한 처짐은 .131, 풍속이 .04의 순으로 나타났다(Table 6). 이는 다중 회귀모델과 유사한 독립변수의 위계를 나타낸다.

4.3 각 모델의 예측 성능평가 및 비교분석

다중 회귀 분석으로 개발된 교량거동 예측모델과 인공 신경망 분석으로 개발된 모델의 예측성능을 비교 분석하기 위하여 성능평가를 수행하였다. 성능평가에 사용된 데이터(Test Data Set)는 난수생성기로 무작위 분류 생성된 총 데이터의 20%를 이용하였다.

실측 신축거동과 예측 신축거동을 시각화하기 위하여 산점도와 비교 그래프를 Fig. 3, 4와 같이 나타내었다. 시각화 도표는 총 데이터의 20%에 해당하는 10,122개의 검정용 데이터 중에서 약 1%에 해당하는 100개의 데이터를 이용하여 시각화 하였다. Fig. 3, 4에서 알 수 있듯이 각 모델로 예측한 신축거동은 세부적으로 차이가 있지만 전체적으로는 매우 유사한 신축거동 경향을 나타내는 것을 알 수 있다.

한편 Fig. 4에서 알 수 있듯이, 예측 값과 실제 값이 전체적으로 유사한 거동 양상을 보이지만, 정확하게 일치하지는 않는 것을 알 수 있다. 특히, 실제 값의 Peak 부근에서는 예측 값이 실제 값에 비해 다소 연화된(Smoothing) 거동을 보이는데, 이러한 차이는 머신러닝 모델이 과적합(Overfitting)되는 것을 방지하기 위해 급격한 변화나 이상치(Outlier) 등에 대해서는 둔감하도록 학습되기 때문에 나타나는 현상으로 사료된다. 또한, 일부 구간에서는 MRA 모델이 실제 값에 더 부합되고, 또 다른 일부 구간에서는 ANN 모델이 실제 값에 더 부합하는 것으로 나타나는데, 이는 MRA 모델과 ANN 모델의 구조적 차이에 기인하는 것으로 사료된다. 즉, MRA와 ANN은 모델의 수학적 형태나 구조가 근본적으로 다르기 때문에 동일한 데이터를 사용하여 학습하더라도 데이터의 특성에 따라 서로 다른 결과가 나타날 수 있다.

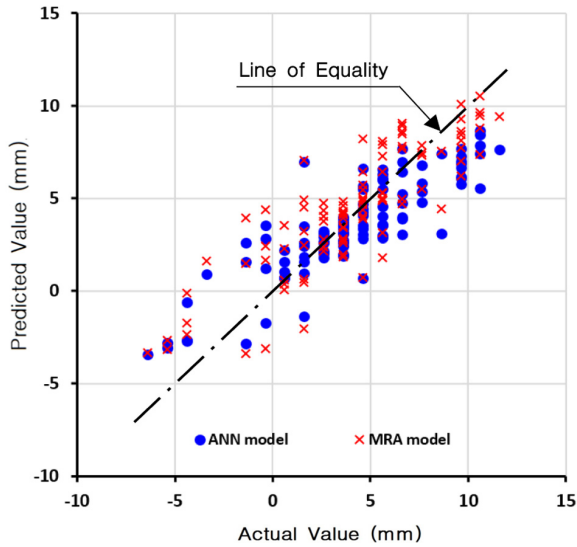


Fig. 3. Prediction performance.

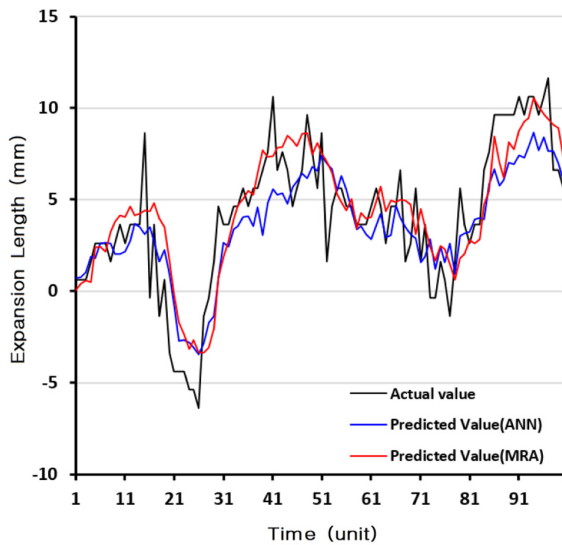


Fig. 4. Comparison of actual and predicted values.

한편, 실측 변위에 대한 다중회귀모델(MRA)의 평균 제곱근오차(Root Mean Square Error ; RMSE)는 8.290 mm, 인공신경망모델(ANN)의 RMSE는 8.210 mm로 나타났고, 결정계수(R^2)에서도 다중회귀모델은 .865, 인공신경망모델은 .868로 나타나는 등 ANN 모델이 1에 조금 더 가깝게 나타나 비교적 우수한 것으로 확인되었다. 그러나 두 모델이 신축거동의 예측 성능에 큰 차이가 없는 것으로 사료되며, 예측의 정확성 측면에서 어느 모델을 사용하더라도 신축거동에 대한 예측 성능에는 차이가 없을 것으로 판단할 수 있다(Table 7).

한편, 통계 모델인 MRA 모델은 각 독립변수가 종속변수에 미치는 영향을 분석할 수 있고 모델링 과정에서 반복 계산이 필요하지 않는 등의 장점이 있으나, 새

Table 7. Comparison of predictive model validation

	MRA model	ANN model
RMSE	8.290 mm	8.210 mm
R^2	86.5%	86.8%

로운 데이터에 대해 모델을 업데이트하고자 할 경우 새로운 데이터뿐만 아니라 과거의 데이터도 필요하기 때문에 데이터의 양이 방대할 경우에 모델 업데이트가 어려운 단점이 있다. 반면에, ANN 모델의 경우 각 입력변수가 출력변수에 미치는 영향을 분석하기 어려우며 모델링 과정에서 반복 계산 등이 필요한 단점이 있으나, 과거의 데이터 없이 새로운 데이터만으로 모델 업데이트가 가능한 장점이 있기 때문에 예측의 정확성을 향상하기 위한 업데이트가 수시로 필요한 경우에는 ANN 모델이 MRA 모델에 비해 효율성이 높을 것으로 판단된다.

5. 결론

본 연구에서는 공용 중 광안대교의 유지관리 빅데이터를 이용하여 신축거동 예측모델을 개발하였다. 예측모델의 개발 과정에서 다중회귀분석과 인공신경망기법에 기반한 모델링 방법이 적용되었으며, 각각의 방법으로 개발된 모델의 신축거동 예측 성능을 비교 분석하였다. 개발된 모델을 이용하여 예측된 신축거동은 실측 신축거동과 유사한 것으로 분석되었으며, 온도, 교통량에 의한 연직변위(처짐), 풍속을 변수로 교량의 신축거동을 예측 가능하다는 것을 알 수 있었다. 또한 두 모델에 의해 예측된 신축거동 값은 실제 값과 유사하였으며, 가장 예측력이 우수한 모델은 ANN으로 나타났다. 특히, ANN의 경우 모델 업데이트 시에 새로운 데이터만으로도 업데이트가 가능한 장점이 있으며, 모델의 정확성 향상을 위해 지속적인 업데이트가 필요한 경우에는 ANN 모델이 효율적일 것으로 사료된다. 마지막으로 본 연구에서 교량의 신축거동 예측 모델은 설계 단계에서는 교량 신축이음장치의 용량(규격)을 합리적으로 산정하고, 유지관리 단계에서는 신축이음장치의 예방적 보수·보강 시기 결정 등에 유용하게 활용할 수 있을 것으로 사료된다. 특히, 이러한 실무 활용 시에는 무엇보다 예측 모델의 정확성을 지속적으로 확보할 필요가 있으며, 이에 따라 예측 모델의 장기 신뢰성에 대한 연구가 현재 이루어지고 있다.

감사의 글: 이 논문은 부경대학교 자율창의학술연구비(2017년)에 의하여 연구되었음.

References

- 1) <http://www.yonhapnews.co.kr/photos/1990000000.html?cid=PYH20180716225000061&from=search>
- 2) J. H. Park, “The optimum design of expansion joints by long-term monitoring data for the Diamond Bridge”, Master Thesis, Pukyong National University, 2015.
- 3) J. C. Park, “Evaluation of Thermal Movements of a Cable-Stayed Bridge Using Temperatures and Displacements Data”, Journal of the Korean Society of Civil Engineers, Vol. 35, No. 4, pp.779-789, 2015.
- 4) J. S. Chung, and J. S. Lee, “Effects of Bridge Bearings by Structure-Track Interaction for Continuous Bridge applied CWR with Rail Expansion Joint under Temperature Load”, J. Korean Soc. Saf., Vol. 25, No. 5, pp. 54-61, 2010.
- 5) Korean Society of Civil Engineers, Explanations for highway bridge design code, pp.92-94, 2008.
- 6) Ministry of Land, Infrastructure and Transport, ‘Highway bridge design code-(Limit state design)’, 2016.
- 7) Ministry of Land·Transport and Maritime Affairs, ‘Highway design manual’, 2008.
- 8) J. Shu, Z. Zhang, I. Gonzalez, and R. Karoumi, “The Application of a Damage Detection Method using Artificial Neural Network and Train-induced Vibrations on a Simplified Railway Bridge Model”, Engineering Structures, Vol. 52, pp.408-421, 2013.
- 9) M. Mehrjoo, N. Khaji, H. Moharrami and A. Bahreininejad, “Damage Detection of Truss Bridge Joints using Artificial Neural Networks”, Expert Systems with Applications, Vol. 35, No. 3, pp.1122-1131, 2008.
- 10) T. H. Chan, Y. Q. Ni, and J. M. Ko, “Neural Network Novelty Filtering for Anomaly Detection of Tsing Ma Bridge Cables”, Proceedings of Structural Health Monitoring Conference, California: Stanford University, pp.430-439, 1999.
- 11) J. H. Park, S. W. Shin, and S. Y. Kim, “Traffic Volume Dependent Displacement Estimation Model for Gwangan Bridge Using Monitoring Big Data”, Journal of the Korean Society of Civil Engineers. Vol. 38, No. 2, pp.183-191, 2018.
- 12) J. H. Park, and S. Y. Kim, “Analysis of Suspension Bridge Reinforced Truss Strain by Traffic”, 2017 Proceedings of KSMI Annual Conference, pp.357-358, 2017.
- 13) S. R. Chen, and J. Wu, “Dynamic Performance Simulation under Combined Loads of Stochastic of Long-Span Bridge Traffic and Wind”, Journal of Bridge Engineering, Vol. 15, No. 3, pp. 219-230, 2009.
- 14) Y. C. Kim, W. S. Yoo, and Y. S. Shin, “Application of Artificial Neural Networks to Prediction of Construction Safety Accidents”, Journal of the Korean Society of Hazard Mitigation . Vol. 17, No. 1, pp.7-14, 2017.
- 15) S. W. Shin, “Construction Safety and Health Management Cost Prediction Model using Support Vector Machine”, J. Korean Soc. Saf., Vol. 32, No. 1, pp. 115-120, 2017.
- 16) Korea Statistics Training Institute, ‘Statistical Thesis Writing Process for Graduate Students’, 2016.
- 17) J. S. Lee and B. G. Cha, “Structure Design of Artificial Neural Networks using Genetic Algorithm”, Journal of the Korean Operations Research and Management Science, Vol. 24, No. 3, pp.49-62, 1999.
- 18) J. H. Park, C. S. Kim, S. W. Shin, and S. Y. Kim, “Partial Correlation Analysis Excluding Temperature Effects in Gwangan Bridge Girder Expansion and Vertical Displacement” 2018 Proceedings of KSMI Annual Conference, pp.337-338, 2018.