

## 인공신경망과 축방향 변형률을 이용한 거더 교량의 동적 수직 변위 추정

옥수열\* · 문현수\*\* · 전방조\*\*\* · 임윤묵\*\*\*\*

Ok, Su Yeol\*, Moon, Hyun Su\*\*, Chun, Pang-jo\*\*\*, Lim, Yun Mook\*\*\*\*

### Estimation of Dynamic Vertical Displacement using Artificial Neural Network and Axial strain in Girder Bridge

#### ABSTRACT

Dynamic displacements of structures shows general behavior of structures. Generally, It is used to estimate structure condition and trustworthy physical quantity directly. Especially, measuring vertical displacement which is affected by moving load is very important part to find or identify a problem of bridge in advance. However directly measuring vertical displacement of the bridge is difficult because of test conditions and restriction of measuring equipment. In this study, Artificial Neural Network (ANN) is used to suggest estimation method of bridge displacement to overcome constrain conditions, restriction and so on. Horizontal strain and vertical displacement which are measured by applying random moving load on the bridge are applied for learning and verification of ANN. Measured horizontal strain is used to learn ANN to estimate vertical displacement of the bridge. Numerical analysis is used to acquire learning data for axis strain and vertical displacement for applying ANN. Moving load scenario which is made by vehicle type and vehicle distance time using Pearson Type III distribution is applied to analysis modeling to reflect real traffic situation. Estimated vertical displacement in respect of horizontal strain according to learning result using ANN is compared with vertical displacement of experiment and it presents vertical displacement of experiment well.

**Key words :** Bridge, Displacement, Strain, Moving load, Scenario

#### 초 록

구조물의 변위이력은 구조물의 전체적인 거동을 나타내는 인자의 시간에 대한 이력이므로 이를 추정하는 것은 매우 중요하며, 일반적으로 구조물의 상태를 평가하는데 있어 직관적으로 신뢰할 수 있는 물리량이다. 특히, 교량의 경우 차량 하중에 의해 발생하는 수직 변위를 알아내는 것은 교량에 발생할 수 있는 문제점을 미연에 확인할 수 있어 매우 중요한 부분이다. 하지만 시공된 교량의 수직 변위를 측정하는 것은 실험여건 및 장비의 제약조건 등으로 인해서 직접적으로 측정하는 것이 매우 힘든 실정이다. 본 연구에서는 대상 교량들에 대한 제약조건을 극복하고 변위응답을 추정할 수 있는 방안을 제시하기 위해 임의의 차량하중에 의해서 측정되는 변형률과 변위를 인공신경망에 적용하였다. 인공신경망에 적용하는 축방향 변형률과 수직방향 변위에 대한 학습 자료를 획득하기 위해서 수치해석을 수행하였으며, 실제 교통 상황을 반영하기 위해서 교량을 통과하는 차량의 종류와 차간 거리에 대한 차량이동하중 시나리오를 작성하여 시공된 교량의 실제 교통상황에 따른 차량 이동 하중이 가해지도록 모델링하였다. 인공신경망을 이용한 학습 결과에 따라 임의의 하중에 의해 발생하는 교량의 변형률에 대한 변위를 추정하였고, 인공신경망을 사용하여 추정된 변위 결과가 수치해석을 통한 변위를 잘 표현하는 것을 확인하였다.

**검색어 :** 교량, 수직 변위, 변형률, 차량이동하중, 시나리오

\* 현대건설 토목환경사업본부 토목환경기술개발실 사원 (Hyundai Engineering & Construction · [suyeol.ok@hdec.co.kr](mailto:suyeol.ok@hdec.co.kr))

\*\* 정회원 · 연세대학교 사회환경시스템공학부 통합과정 (Yonsei University · [smilefou@yonsei.ac.kr](mailto:smilefou@yonsei.ac.kr))

\*\*\* 에히메(Ehime)대학교 사회환경공학부 조교수 (Ehime University · [chun.pang-jo.mj@ehime-u.ac.jp](mailto:chun.pang-jo.mj@ehime-u.ac.jp))

\*\*\*\* 정회원 · 교신저자 · 연세대학교 사회환경시스템공학부 교수 (Corresponding Author · Yonsei University · [yunmook@yonsei.ac.kr](mailto:yunmook@yonsei.ac.kr))

Received December 20, 2011/ revised May 5, 2012/ accepted July 18, 2014

### 1. 연구배경 및 목적

구조물의 동적 응답들 중에서 변위이력은 극한 하중 시 구조물이 경험하는 손상의 크기와 밀접하게 관련되어 있으며, 전체적인 거동을 나타내는 인자의 장기적인 이력이므로 이에 대한 데이터를 확보하는 것은 매우 중요하다(Powell and Allahabadi, 1988; Jang and Kim, 2008). 또한 차량 하중에 의해 발생하는 교량의 변위응답 측정으로 차량 하중, 혹은 교량에 가해지는 하중의 특성을 예측할 수 있을 뿐만 아니라(Moses, 1979) 구조물의 상태를 평가하는데 직관적으로 사용될 수 있다. 신뢰할 수 있는 물리량이다. 또한 대상 교량의 변위 변화를 지속적으로 측정하는 것은 구조적인 성능 저하 및 노후도를 판단할 수 있는 중요한 근거를 제공하기 때문이다 (Cho and Kim, 2008).

하지만 구조물의 변위를 측정하는 수단과 방법은 존재하지만 현실적으로 실제 현장에서 교량의 변위를 측정하는 것은 어렵다. 변위를 직접 측정하는 데에는 변위 측정계의 기준좌표 설정 문제, 시간 해상도(샘플링) 문제, 비용문제 등 실제구조물의 적용에 한계가 있다(Hong, 2007). 실내 실험의 경우에는 접촉식 변위계를 사용하여 손쉽게 변위를 측정할 수 있는 반면, 현장 실험에서는 변위계를 고정시키는 부가장치의 설치 문제로 인해서 현장 적용이 용이하지 않다. 또한 비접촉식 방식인 광학식 변위계는 주로 근거리 측정에 적합한 용도이며 측량을 이용할 경우는 측량자의 능력에 좌우되는 문제로 인해서 측정의 일관성을 유지할 수 없다(Kim and Cho, 2002). 이와 달리 교량의 변형률을 측정하는 것은 비교적 용이하게 수행할 수 있다. 변형률은 변위계를 설치하는 것과는 달리 교량의 현장상황과는 상대적으로 무관하게 계측장치를 부착시킬 수 있으며, 실시간으로 교량에 대한 계측을 수행할 수 있는 장점을 가지고 있다.

그러나 축방향 변형률에 대해서 서로 다른 수직방향 변위를 산정해야 하는 문제를 가지고 있으며 계측지점들에서 측정된 변형률이 서로 유기적으로 연결되어 변위와 연관되어 있기에 축방향 변형률과 수직방향 변위를 직접적으로 비교하고 두 가지 변수 사이의 관계를 규정하기가 어렵다. 하지만 기하학적인 측면으로 접근하였을 때, 축방향의 변형률과 수직방향의 변위 사이의 관계를 추론할 수 있으며, 오일러빔 이론을 적용하면 축방향의 변형률은 거더의 곡률과 관계되는 식을 찾을 수 있다. 일반적으로 모든 구조물에서 작은 변형이 발생한다고 가정하면 곡률은 다시 수직방향의 변위와 관계되는 식을 찾아낼 수 있다. 하지만 실제적인 거더의 거동은 티모셴코프 이론에서 언급한 바와 같이 전단방향의 거동도 존재한다.

본 연구에서는 변위 계측에 대한 한계점을 극복하고 실제적인 구조물의 수직변위를 추정하기 위해서 인공신경망을 적용하려고

한다. 인공신경망은 여러 지점에서 측정된 축방향 변형률에 대한 계측값과 수직방향 변위 사이의 관계를 규명하기 위해서 사용된 가정사항과 한계점에 상관없이 수치적으로 결정할 수 있는 장점을 가지고 있다. 따라서 인공신경망의 장점을 이용하여 임의의 차량하중에 의해 발생하는 교량의 축방향 변형률에 대한 계측을 통해 실시간으로 교량의 수직방향 변위를 추정할 수 있는 방법을 제시하고자 한다.

### 2. 수치해석

본 연구에서는 특정 대상 교량에 대해서 특정 결과를 제시하고자 하는 것이 아니라 교량에 발생하는 수직 변위를 추정하는 방법을 제시하고자 하는 것이다. 그러므로 실제 교량에서 하나의 실험을 수행하는 것이 아니라 수치해석을 통한 다양한 종류의 하중에 대한 해석을 수행함으로써 특정위치에서의 축방향 변형률을 이용하여 전체적인 수직방향 변위를 추정할 수 있도록 수치해석 결과를 획득하도록 하였다.

#### 2.1 교량 모델

해석을 수행하기 위해서 일반적으로 많이 사용되는 교량 형식으로 단순지지 되어있는 슬래브-거더교량을 선정하였다. 바닥판 장지간의 길이는 36m의 교량으로 설정하였으며, 지간의 폭은 왕복 4차선으로 차량의 주행이 가능하도록 15m 바닥판 폭을 설정하였다(Chun, 2010). 그리고 해석 모델에 대한 신뢰도 검증은 수치해석결과를 바탕으로 수행하였다. 모델링은 AASHTO LRFD 설계 기준을 따라 설계 하중과 모멘트를 계산하고 거더간의 간격 및 다이아프

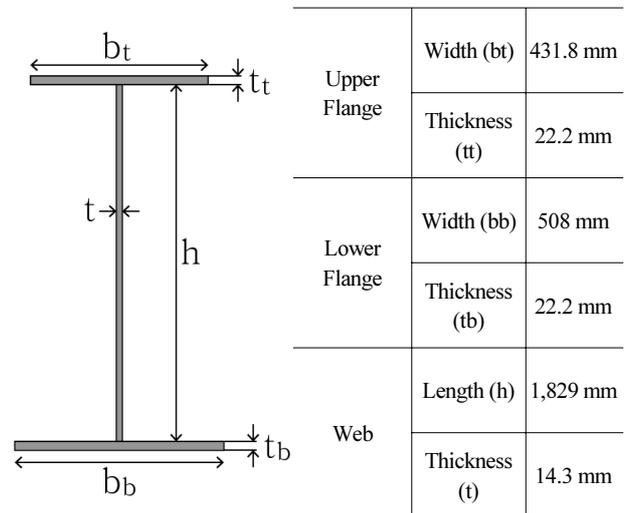
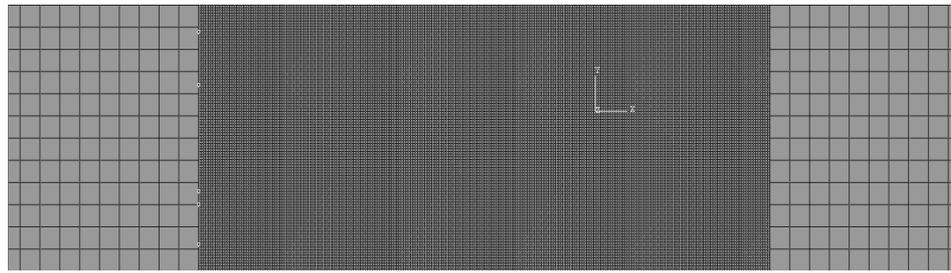
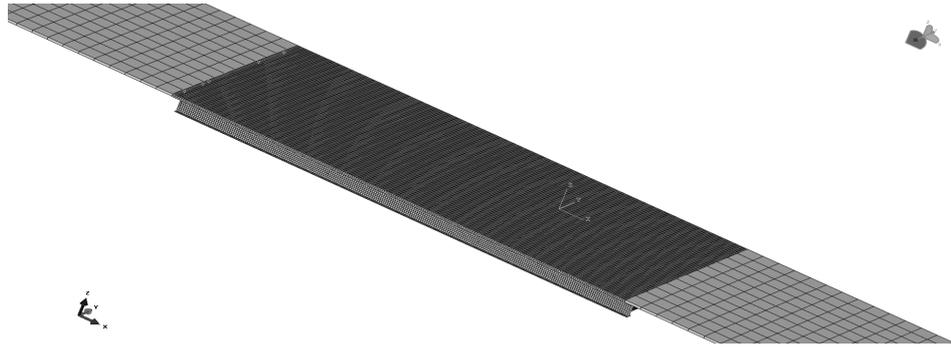


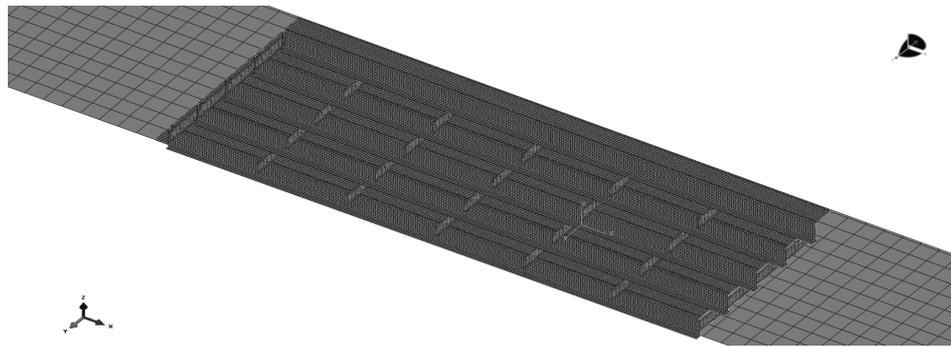
Fig. 1. Shape and Dimension of I-girder



(a) Front View of Analysis Model



(b) Front Air View of Analysis Model



(c) Back Air View of Analysis Model

Fig. 2. Bridge Model

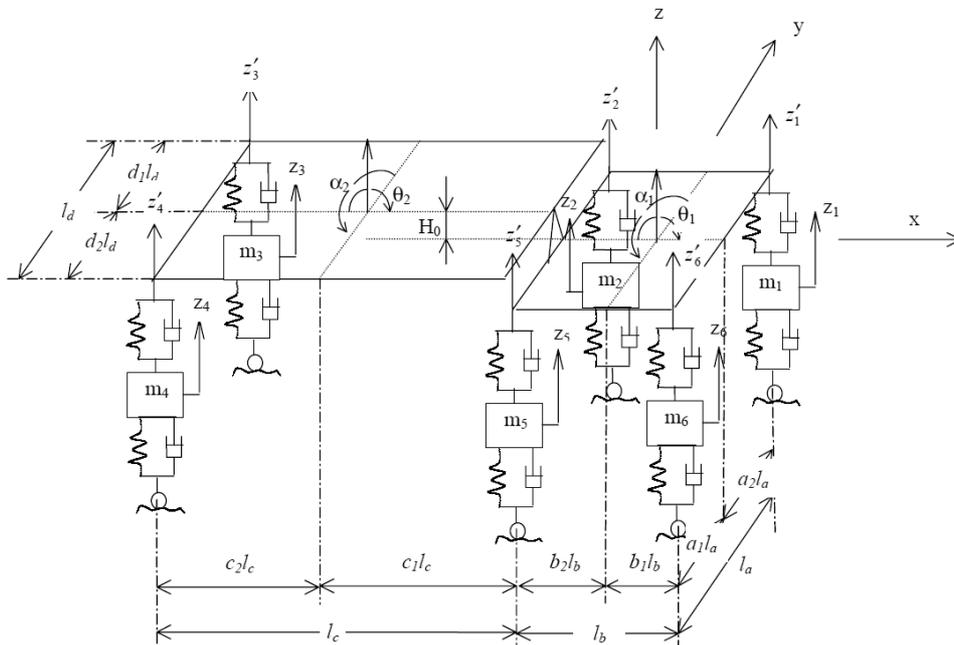
램 간의 간격을 설정하였다(AASHTO, 2002; AASHTO, 2007). 주형은 Fig. 1에서 확인할 수 있는 바와 같이 I 형 강거더를 사용하였으며, 교량 단면을 설계하는 데 있어서 정착장치에서의 활동에 의한 손실 및 릴렉세이션과 건조수축 등에 의한 영향은 적다고 가정하고 무시하였다. 교량에 가해지는 하중은 차량 모델의 하중만 고려하였으며 건조수축 및 충격하중 등 기타하중의 영향은 고려하지 않는다.

교량의 요소에 관한 사항으로 교량의 바닥판에 대한 요소는 3차원 솔리드 요소(Linear Hexahedral Element, C3D83)를 사용하였다. 거더는 3차원 셸 요소(Linear Quadrilateral Element, S4R)를 사용하였다. 솔리드 요소와 셸 요소의 경계 부분에서는 셸 요소의 수직방향에 대한 회전을 Tie-constant를 이용하여 회전 자유도를 구속시켰다. 교량 상부를 지나가는 차량 하중에 의한

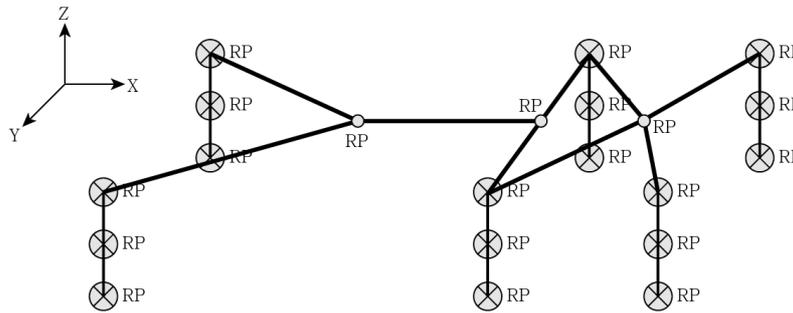
동적 거동을 확인하기 위해서 Fig. 2의 형태로 모델링하였다. 교량의 시작과 끝 부분에는 도입부분(Approach Slab)의 적용을 통해 차량이 교량에 진출입하면서 교량과 도입부분의 높이 차이에서 발생할 수 있는 측정값의 오차가 생기지 않도록 보정하였다.

## 2.2 차량 모델

교량은 차량의 중량, 길이, 현가장치, 고유주기와 같은 인자에 의해 영향을 받는다. 이들은 서로 복합적으로 상호간섭작용을 하기 때문에 모든 변수를 고려하여 모델링을 하는 것은 현실적으로 어려운 일이다. 따라서 본 연구에서는 차량의 종류를 트럭과 승용차, 그리고 버스 세 가지 종류로만 한정하였으며 각각 40km/h, 60km/h, 80km/h의 일정한 속도로 주행한다고 가정하였으며, 차량 주행 시 발생하는 마찰력은 무시하였다. 본 연구에서 기본적으로 사용된



(a) 3D Truck Model for Triaxial Trailer (Zeng and Bert, 2003)



(b) 3D Numerical Truck Model

Fig. 3. Truck Model

차량 모델은 Fig. 3과 같이 3축 트럭으로서 본체 강체와 트레일러 강체의 결합으로 이루어져 있으며, 각 바퀴에서는 수직변위와 가로 축에 대한 피칭 회전, 세로축에 대한 롤링 회전에 이루어졌다. Zeng and Bert (2003)의 트럭 모델을 ABAQUS해석에 적용할 수 있도록 수정하였으며, 승용차와 버스는 트럭에서 트레일러를 제거한 형태로 모델링하였다. 사용된 차량 모델의 제원은 Li (2005)가 제시한 트럭모델을 적용하였고, Zuo and Nayfeh (2003)가 제시한 승용차 모델을 사용하였으며, 버스 모델은 Ahmed et al. (1997)이 제시한 모델을 적용하였다.

### 3. 차량이동하중 시나리오

실제 차량이동 상황을 수치해석 모델에 적용시키기 위해서는 차량의 종류, 차량 속도, 그리고 차간거리와 같은 기본적인 정보가

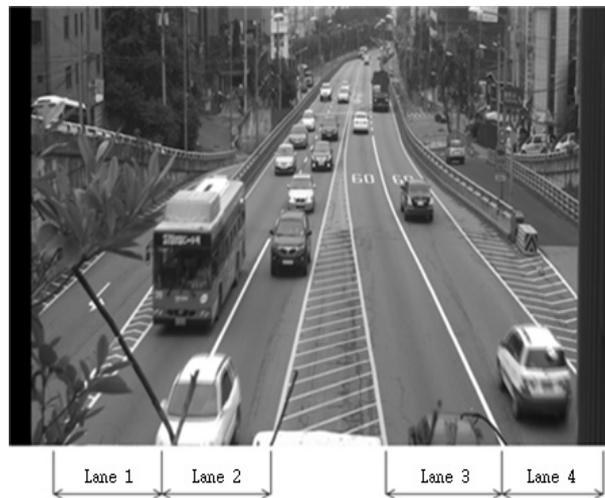


Fig. 4. Types of Cars and Distances between Cars(Field Observation)

Table 1. Ratio of Vehicle Type for Each Lane (%)

	Car	Bus	Truck
Lane 1	91.51%	6.27%	2.22%
Lane 2	92.59%	7.14%	0.27%
Lane 3	84.47%	15.53%	0%
Lane 4	94.05%	3.78%	2.17%

필요하다. 차량의 종류와 차간거리에 대한 사항은 Fig. 4와 같이 금화터널 앞 왕복 4차선 교량지점에서 측정하였으며, 차량의 속도는 40km/h, 60km/h 그리고 80km/h의 일정한 속도로 주행하는 것으로 가정하였다.

차량 종류에 대한 시나리오를 작성하는데 있어서 측정된 교통 데이터를 승용차, 버스 그리고 트럭의 3가지 차량으로 종류를 한정시켜 분류하였다. 분류된 차량을 각 차선에 따른 차량 종류의 비율(%)을 적용하여 Table 1에 나타내었으며, 프로그램 상에서 비율에 따라서 임의적으로 차량의 종류가 선택되도록 구성하였으며, 서울시 차량 등록 상황과 비교하여, 승용차의 비율이 2011년 5월을 기준으로 국토교통부에서 집계한 서울시 통계 수치인 81.8%보다는 높은 비율을 나타내지만 본 연구에서는 차량을 승용차, 버스 그리고 트럭의 3가지로만 분류하였기에 일반화물차량을 승용차로 적용한 통계 수치인 94.0%를 적용할 수 있다. 또한, 트럭의 경우 도로를 주행 할 때 일반적으로 최우측 차선을 이용하여 주행하는데, 본 연구의 관측에서도 이와 동일한 현상으로 2차선과 3차선에서는 트럭에 대한 비율이 매우 낮게 나타나는 것을 확인할 수 있다. 이러한 점을 통해 관측된 차선에 따른 차량 종류의 비율에 대해 신뢰성을 확보하였다.

차간 거리 분포에 대한 시나리오를 작성하기 위해 측정된 교통 데이터를 직접적으로 활용하는 것은 특정한 지역의 교통 상황을 제시하는 것으로 가정하였기에 Microscopic 흐름 특성에 주로 이용되는 교통 이론인 Pearson type III 분포에 측정된 교통 데이터를 적용시켜서 교통 흐름 상황을 재현할 수 있도록 하였다(May, 1990).

Pearson type III 분포는 수학적 모델의 접근을 통해서 생성할 수 있다. 이 분포에 대한 확률 밀도 함수는 Eq. (1)과 같이 나타낸다.

$$f(t) = \frac{\lambda}{\Gamma(K)} [\lambda(t-\alpha)]^{K-1} e^{-\lambda(t-\alpha)} \quad (1)$$

여기서,  $f(t)$ 는 확률 밀도함수를 나타내며,  $K$ 는 0과  $\infty$  사이에 값으로 분포 형태에 영향을 미치는 사용자에게 의해서 선택되는 계수이고,  $\alpha$ 는 0보다는 크거나 같은 값으로 분포의 이동에 영향을 미치는 계수이다.  $\lambda$ 는  $K$ 와  $\alpha$ 에 의해서 결정되는 평균 차간거리

함수에 대한 계수이며,  $t$ 는 관측된 차간 거리에 따른 시간차(sec)이며,  $\Gamma(K)$ 는 Gamma 함수로서  $(K-1)!$ 과 동등한 형태를 나타낸다.

측정된 차간 거리 분포를 Pearson type III 분포에 적용시키기 위해서는 8단계의 과정이 필요하다. 첫 번째는 측정된 차간 거리에 따른 시간차 분포 데이터로부터 평균 차간 시간차( $\bar{t}$ )와 표준편차( $s$ )를 구한다. 두 번째로는 분포의 이동에 영향을 미치는 적절한 값  $\alpha$ 를 선택하는 것이다.  $\alpha$ 는 0보다 크거나 같을 수 있으며, 만약  $\alpha$ 의 값이 0이 된다면 분포의 이동이 발생하지 않는 것이고 차간 시간차가 0에 가까이 접근하는 것을 의미한다. 만약  $\alpha$ 의 값으로 0.5를 선택했다면, 차간 시간차가 0.5보다 적은 차간 시간차는 0으로 간주되는 것을 말한다. 일반적으로 많이 사용되는  $\alpha$ 값의 범위는 0.0에서 1.0(sec) 사이를 선택한다.

세 번째 단계에서는 분포의 형상에 영향을 미치는 적절한 값  $K$ 를 선택하는 것이다.  $K$ 의 범위는 0부터  $\infty$ 까지 다양하게 선택될 수 있으며, 만약  $K$ 가 1이라면 결과 분포는 Negative Exponential (Random) 분포를 형성한다.  $K$ 값이  $\infty$ 에 가까울수록 결과 분포는 일정한 차간 거리 분포를 가지게 된다. 예측값  $K$ 는 Eq. (2)를 적용시켜 구할 수 있다.

$$\hat{K} = \frac{\bar{t} - \alpha}{s} \quad (2)$$

네 번째 단계에서는  $\lambda$ 를 계산하는 과정으로, 평균 차간 시간차( $\bar{t}$ )와 사용자에게 의해서 설정되는  $\alpha$ 값의 의해서 Eq. (3)과 같이 계산된다.

$$\lambda = \frac{K}{\bar{t} - \alpha} \quad (3)$$

여기서,  $\lambda$ 는  $K=1$ 이고  $\alpha=0$ 일 때에만, 흐름 속도(평균 차간 시간차의 역수)와 동일하며, Eq. (2)에서  $\hat{K}$ 가 Eq. (3)의  $K$ 를 대체한다면  $\lambda$ 는 표준 편차의 역수가 된다.

다섯 번째 단계는 Gamma 함수  $\Gamma(K)$ 를 구하는 과정으로,  $\Gamma(K)$ 는  $(K-1)!$ 를 구하는 것과 동일하게 구할 수 있다. 만약  $K$ 가 1,2,3과 같은 정수라면 0!, 1!, 2!과 같이 쉽게 값을 구할 수 있지만, 4.785와 같이 정수가 아니라면 3.785!이라는 값은  $(K-1)!$ 를 적용하여 쉽게 구하기가 어렵다. 이를 극복하기 위해 직접적으로  $\Gamma(K)$ 를 구하기 위해서 Eq. (4)를 이용할 수 있다.

$$\Gamma(K) = \int_0^{\infty} e^{-x} x^{K-1} dx \quad (4)$$

여섯 번째는 다양한  $t$ 값에 대해서 Eq. (1)을 사용하여  $f(t)$ 를

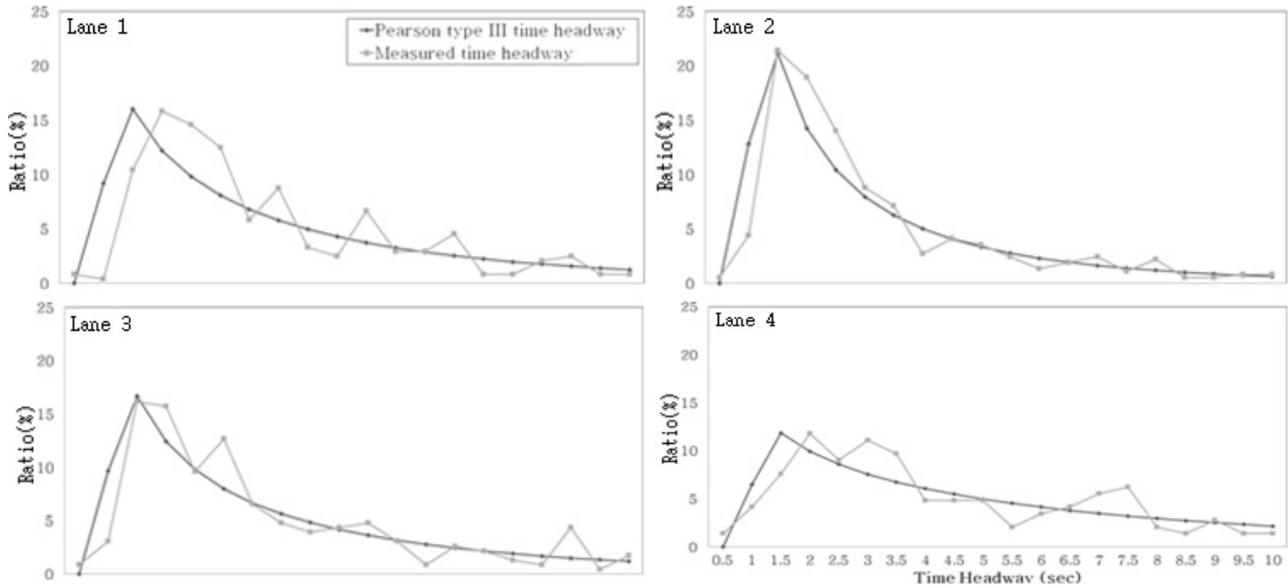


Fig. 5. Time Lag between Cars for Each Lane

구하며, 일곱 번째에서는 Eq. (5)를 사용하여 차간 시간차에 대한 확률을 구한다.

$$P(t \leq h < t + \Delta t) = \left[ \frac{f(t) + f(t + \Delta t)}{2} \right] \quad (5)$$

마지막으로 여덟 번째에서는 Eq. (6)을 사용하여 차간 시간차 그룹에서의 차간 시간차 예측 숫자를 구하는 것이다. N은 관측된 차량의 숫자를 의미하며 최소의 경우에 1320을 적용한다.

$$F(t \leq h < t + \Delta t) = N[P(t \leq h < t + \Delta t)] \quad (6)$$

본 연구에서는 각 차선에 대해 8단계의 과정을 적용하여 관측된 차량 데이터를 Pearson type III 분포 이론에 적용시켜서 이론적인 차간 시간차 분포 확률 곡선을 획득하여, 실제 교통 상황을 묘사할 수 있다. Fig. 5를 통해 관측된 차간 거리 분포와 Pearson type III를 적용한 분포를 쉽게 확인할 수 있다.

(8) Pearson type III 분포 이론을 바탕으로 만들어진 차간 거리 분포를 이용하여 각각의 차간 거리에 따른 비율(%)로서 임의적으로 차간 거리가 결정되도록 25가지의 경우에 대해서 차간 거리를 획득하였다. 또한, Table 1에 나타나 있는 바와 같이 교통상황을 바탕으로 승용차, 버스 그리고 트럭의 3가지 차량으로 종류를 한정시켜 차량 종류에 따른 비율(%)로서 임의적으로 차량의 종류가 선택되도록 25가지의 경우에 대해 차량 종류에 대한 시나리오를 작성하였다. 그리고 차간 거리와 차량 종류의 시나리오를 종합하여

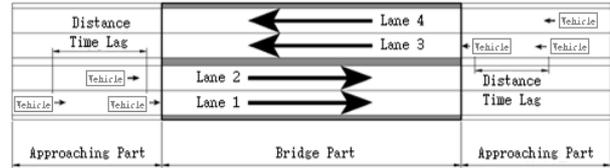


Fig. 6. Load Scenario for Moving Vehicle

총 25가지의 경우에 대해서 차량이동하중 시나리오를 Fig. 6과 같은 형태로 구성하였다. Fig. 7에서 차량의 속도에 따라 이동하는 차량하중에 대해 25가지의 경우 중 40km/h로 주행하는 경우 중 첫 번째 경우에 대한 것을 상세하게 나타내어 표현하였다. 또한, Fig. 7의 40km/h에 대한 내용과 마찬가지로 60km/h와 80km/h에 대한 차량이동하중 시나리오를 작성하였다. 차량은 교량 외부의 도입부분에 각각의 차선에 존재하며, 해석을 수행하기 직전의 위치이다. 교량의 한 지점을 기준으로 첫 번째 차량이 교량에 진입한 후 마지막 차량이 교량을 빠져나갈 수 있도록 설정하였다.

#### 4. 인공신경망(Artificial Neural Network)

##### 4.1 오차 역전파 학습알고리즘 개요

오차 역전파 학습알고리즘은 전방향처리(Feedforward)와 역방향처리(Feedback) 두 단계로 이루어진다. 학습에서 중요한 것은 연결강도의 지속적인 갱신인데 역전파 알고리즘은 역방향처리 단계에서 연결강도의 갱신이 이루어진다. 전방향처리는 자료가 신경망에 입력된 후 생성된 출력층에서의 출력값과 목표값과의 오차를

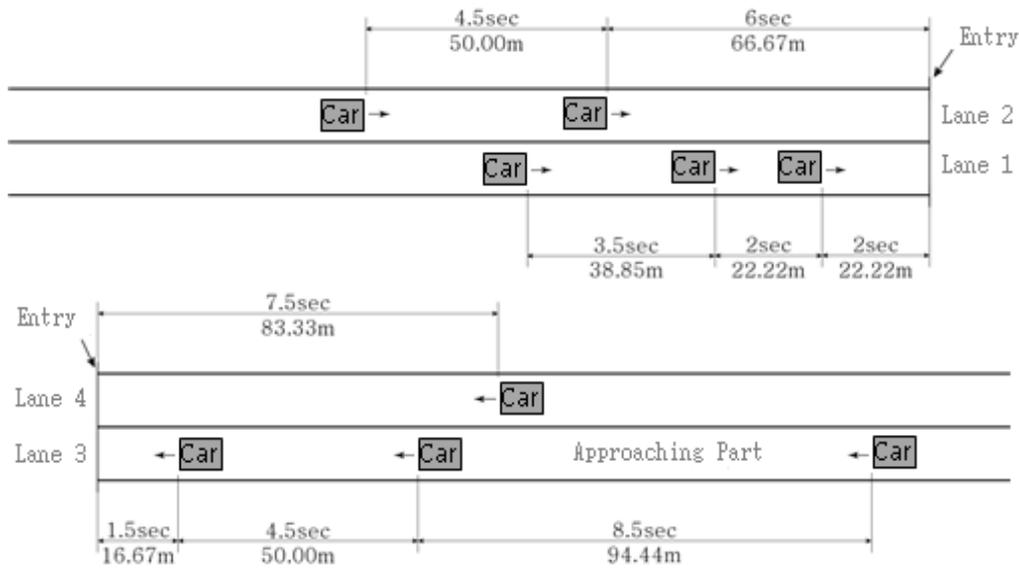


Fig. 7. Load Scenario for Moving Vehicle (Case1; v = 40km/h)

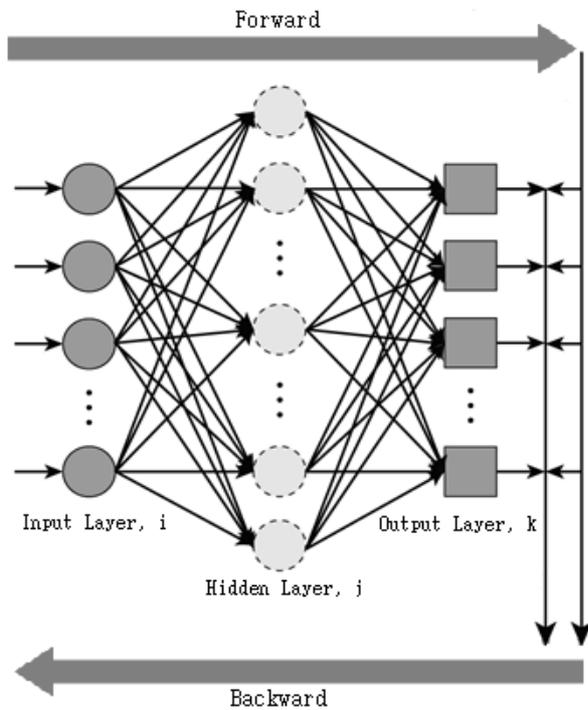


Fig. 8. Multi-Layer Perceptron of Error Back-Propagation

계산하고 이를 은닉층에 전파하는 과정으로 목표값과 출력값의 차이인 델타(Delta,  $\Delta$ )를 이용하여 학습을 하는 델타법칙(다층퍼셉트론)이다. 전방향처리는 신경 회로망에 입력 패턴을 제시하고, 각 노드에 대해서 입력 함수와 활성화 함수를 이용하여 출력을 산출하는 단계이기 때문에 입력신호는 전방향, 즉 출력층 방향으로

만 전달된다. 초기에 정해져 있는 임의의 연결 강도에 의해서 출력층에서 출력값과 목표값이 일치하지 않고 큰 오차가 발생된다. 역방향 처리는 출력층에서 출력값이 목표값과의 오차를 최소화시키도록 은닉층과 출력층의 연결강도를 조절하고 은닉층의 출력값을 얻어 은닉층과 입력층 사이의 연결강도를 반복적으로 조절하는 형태를 갖는데, 이것은 델타법칙에 역전과 방법이 추가된 일반화된 델타법칙(Generalized Delta Rule, 다층퍼셉트론)이다. 역방향 처리는 목표 출력과 실제 출력의 차이를 계산하여 오차를 구하고, 이를 역방향, 즉 출력층에서 입력층으로 순서대로 층과 층 사이의 연결강도를 갱신하는 단계이다. 연결 강도를 조절한 후 다시 입력을 넣어 계산하면 처음 시도 때보다 적은 오차값을 가지는 출력값을 획득하게 된다. 시스템이 안정화될 때까지 반복 작업을 통해서 발생하는 총 오차의 합이 정해진 오차의 기준치에 도달할 때까지 실행해 원하는 값에 수렴시키는 것이다.

#### 4.2 인공신경망 학습 및 구조

하중에 의해서 발생하는 교량의 변형률과 변위를 측정하기 위해서 Fig. 9(a)에서와 같이 하나의 거더 플랜지 아래에 점으로 표시된 3.6m의 균일한 간격으로 거더의 지간을 10등분하여 11개의 지점에서 학습 자료를 획득하였다. Fig. 9(b)와 같이 총 5개의 거더를 사용하여 해석을 수행하였기에 총 55개의 변형률과 변위 계측 지점을 설정하였다. 차량 하중에 의해서 지속적으로 발생하는 변형률과 변위를 시간에 따라서 측정하였으며, 획득된 자료는 0.01초 시간 간격으로 모든 계측 지점에서 데이터를 획득하였다.

교량의 한 지점을 기준으로 첫 번째 차량이 교량에 진입한 후

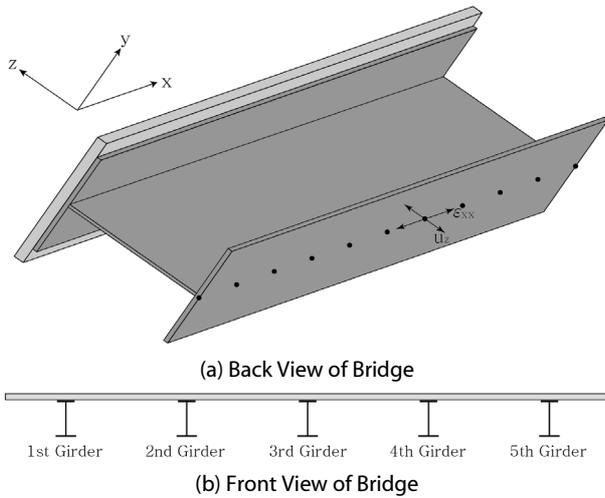


Fig. 9. Measuring Points on the Bridge

교량을 빠져나갈 때까지 마지막 차량이 교량에 진입할 수 있도록 설정하여 교량과 도입 부분을 충분히 지나갈 수 있도록, 40km/h의 속도로 주행하는 경우에서는 최대 15초(1500개), 60km/h의 경우 13초(1300개), 80km/h의 경우에는 11초(1100개) 동안 차량이 이동하도록 설정하여 학습 데이터를 획득하였다. 이 때, 획득된 데이터의 개수가 속도에 따라서 다르며, 데이터의 개수가 많으면 학습에 소요되는 시간이 오래 걸린다. 따라서, 데이터를 각 속도별로 균일하게 하여 다양한 개수의 세트에 대한 학습을 진행하였고, 학습 결과 및 소요시간에 따라 모든 속도에 대하여 800개의 데이터 세트를 획득하였다. 하나의 데이터 세트는 55개의 계측지점에서의 변형률과 변위 자료를 포함하고 있으므로, 하나의 이동 하중 시나리오에 대해서 800×55에 해당되는 데이터를 적용하였다. 각 속도에 따라서 각각 25가지의 경우에 대해서 시나리오를 적용하였다. 학습 자료와 테스트 자료를 선정하기 위해서 각 속도에 따라서 24가지의 경우를 학습 자료로 사용하였으며, 나머지 한 가지는 테스트 자료로 사용하였다. 테스트 자료를 선정하는 기준은 각 속도에 따른 인공신경망의 학습 결과 정도의 차이를 확인하기 위해서 각 속도에 따른 25가지의 경우 중에서 한 가지의 테스트자료를 선정하였으며, 선정 방법으로는 25가지의 경우 중 한 가지를 임의적으로 선출하였다. 최종적으로 하나의 이동하중 시나리오 800×55세트에 대하여 총 24가지의 이동하중 시나리오를 각각의 속도별 학습 자료로 구성하여 57600×55의 데이터세트를 이용하여 인공신경망을 학습시켰다. 또한, 나머지 하나의 이동하중 시나리오에 대해서는 각 속도별로 최초로 데이터를 획득한 40km/h의 경우 1500개(15초), 60km/h의 경우 1300개(13초) 그리고 80km/h의 경우 1100개(11초)를 이용한 총 3900×55의 데이터세트로 테스트를 진행하였다.

본 연구에서는 상용프로그램인 MATLAB TOOLBOX 내의

인공신경망을 사용하였으며, 인공신경망 가중치와 바이어스(bias)의 학습은 역전파 알고리즘 중에서 많은 데이터의 양을 처리하기에 적합한 SCGBP (Scaled Conjugate Gradient Back Propagation) 알고리즘을 사용하였다. 입력층과 출력층은 유니트수가 입력 자료와 출력 자료에 의해서 쉽게 결정되는 반면, 은닉층의 유니트수는 신경망의 학습과 일반화 능력에 있어 중요한 영향을 미치므로 최적 신경망 구조를 갖도록 결정을 해야 한다. 은닉층의 유니트수에 관해서는 계속적으로 논의중에 있으며(Mussone et al., 1996), 은닉층의 유니트수를 적게 하면 입력층의 정보량의 자유도가 저하되며 많이 설정하면 입력층의 정보량을 과대하게 평가하여 네트워크가 수렴하지 않으며, 학습시간도 비례하여 늘어날 뿐만 아니라, 모델의 적합정도가 향상되지 않기에 은닉층의 유니트수는 적당히 적게 설정하는 것이 좋으므로(Moon, 2000), Eq. (7)을 통해서 유니트수에 따른 MSE (Mean Square Error)를 비교할 수 있다.

$$MSE = \frac{1}{N} \sum_{i=1}^N (Q_i - \bar{Q}_i)^2 \quad (7)$$

여기서,  $Q_i$ 는 수치해석을 통한 자료이고,  $\bar{Q}_i$ 는 인공신경망을 통한 자료이다. N은 자료의 개수를 의미한다.

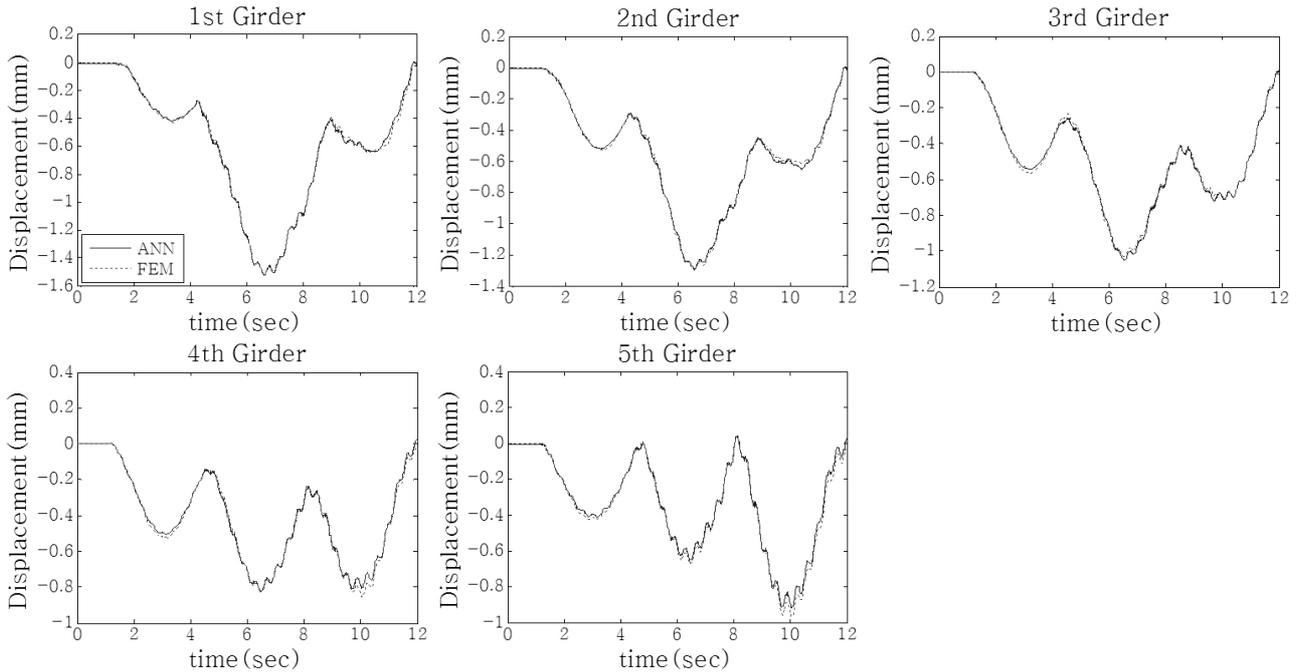
MSE가 최소가 되는 은닉층의 개수를 선정하기 위해서 반복수행을 실시하였으며, 은닉층의 개수에 따른 MSE의 차이가 크게 발생되지 않았다. Kim et al. (2000)의 연구에서 언급된 바와 같이 은닉층의 유니트수의 개수는 대칭적으로 설정되는 것이 바람직하기에 대칭적으로 은닉층의 개수를 결정하였다. 학습률과 모멘텀항에 따른 MSE 역시 일괄적으로 증가하거나 감소하는 경향을 발견할 수 없었다. 따라서 본 연구에서 사용된 인공신경망은 학습률과 모멘텀항에 따라서 MSE와 상관관계가 없다고 판단하였다. 최종적으로 사용된 인공신경망의 구조는 55-40-40-55(입력층-은닉층1-은닉층2-출력층)이며, 학습률은 0.1을 사용하였고 모멘텀항은 0.9를 적용하였다. 연구에 사용되는 전달함수는 압출력 자료의 범위가 차량의 조합에 의해서 발생하는 하중의 상한선이 제한되어 있기 때문에 Sigmoid나 Tan-Sigmoid함수와 같은 비선형함수가 적합하다고 할 수 있다. 따라서 각각의 함수를 적용하여 학습을 수행한 후, MSE를 비교한 결과 차이는 발생하지 않았으나, -1~1 사이의 값으로 전달되는 값의 영역을 확장시켜주기 위해서 Tan-Sigmoid 함수를 사용하였다.

### 4.3 인공신경망 학습 결과

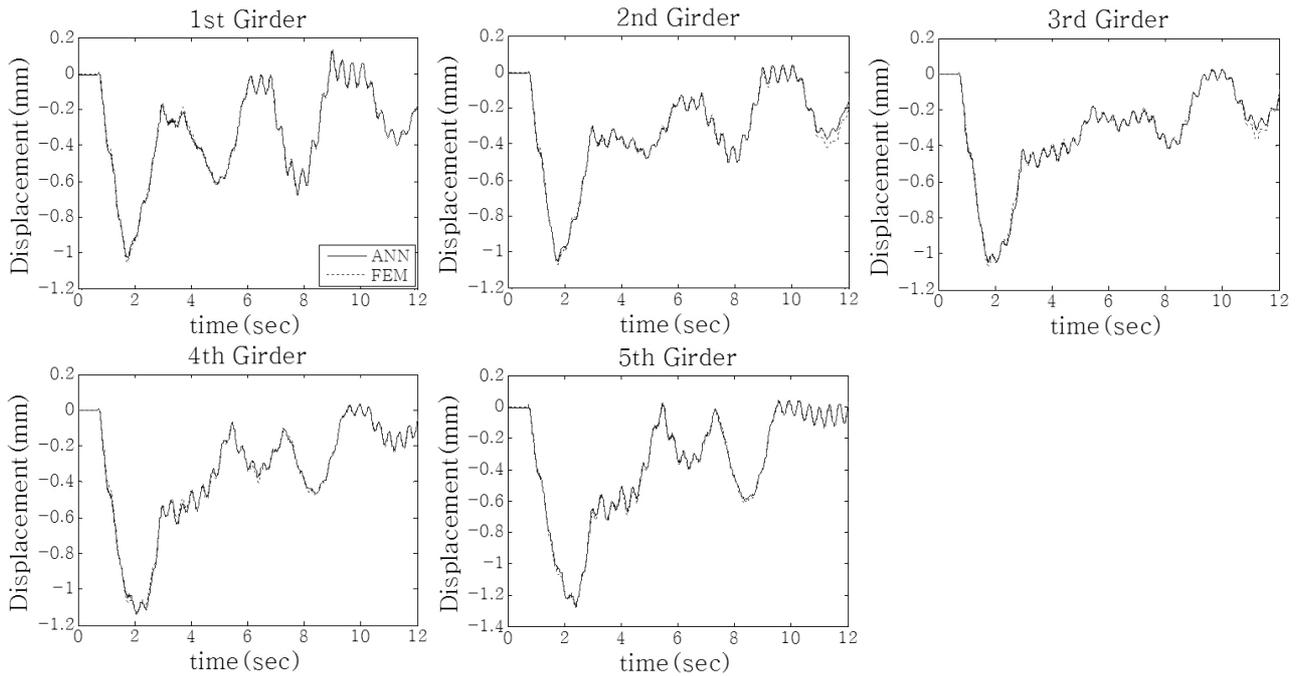
인공신경망의 학습은 6039번의 반복을 거친 후에 수렴하며, 인공신경망 자체에서 측정되는 목표값과 결과값의 상관관계는

99.97%수준으로 나타났기 때문에 인공신경망의 학습은 잘 이루어졌다고 판단할 수 있다. 추출된 테스트 자료를 학습된 인공신경망에 대입하여 MSE를 구한 결과는 0.0104 수준으로 나타났으며, 그 결과를 각 속도에 따른 거더 중심 부분에 대한 변위의 출력값과 목표값을 도시하였다. Fig. 10에서 나타난 바와 같이 시간에 따라서

이동하는 차량하중에 의해서 발생하는 교량의 수직방향 변위를 거더 중심 부분에서 시간의 흐름에 따라서 나타내었다. ABAQUS를 이용한 수치해석을 통해서 직접적으로 획득된 시간-변위 곡선과 수치해석으로 획득된 변형률을 학습된 인공신경망에 대입하여 획득된 시간-변위 곡선을 하나의 그림에 나타내었다. MSE 값을



(a) Displacement (Test Data;  $v=40\text{km/h}$ )



(b) Displacement (Test Data;  $v=60\text{km/h}$ )

Fig. 10. Displacement by Full Model

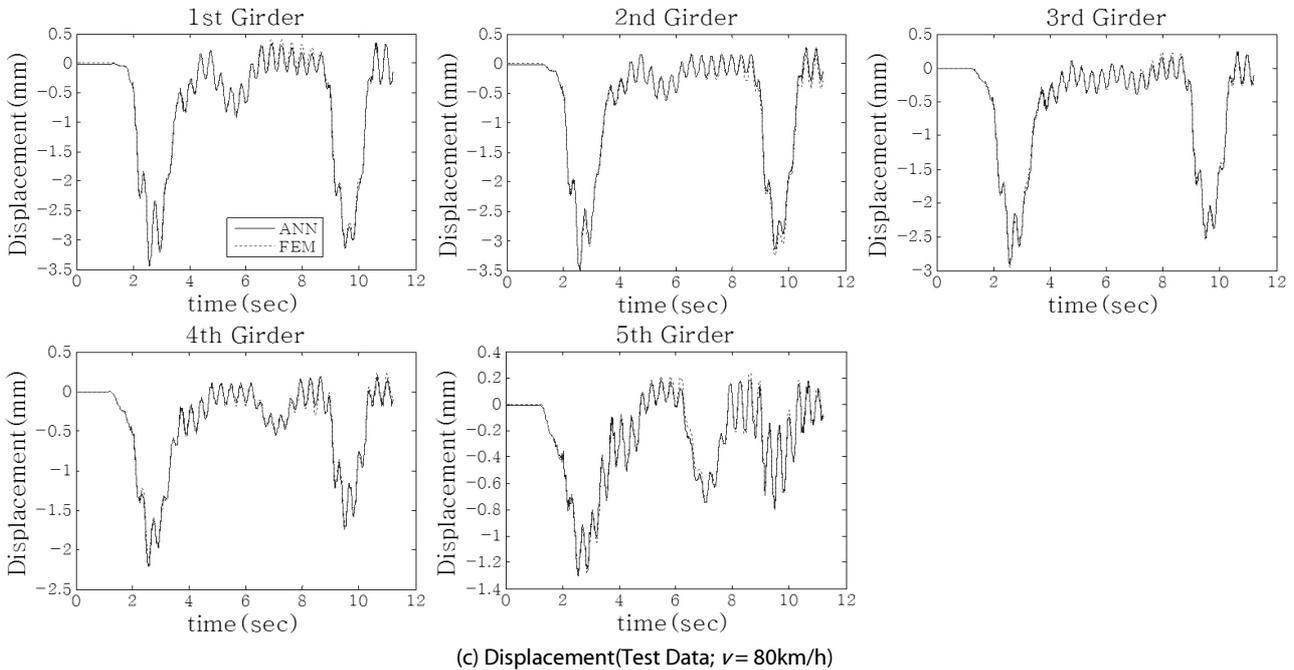


Fig. 10. Displacement by Full Model (continue)

통해서도 충분히 확인할 수 있지만, 인공신경망을 이용하여 추정된 교량의 수직방향 변위가 수직 해석을 통해서 획득된 교량의 수직방향 변위를 잘 표현해 내는 것을 확인할 수 있다.

MSE 값과 상관관계를 통해서도 알 수 있듯이 Fig. 10에서 40km/h, 60km/h, 80km/h의 모든 Case에 대해서는 인공신경망이 유한요소해석에 따른 변위형상을 잘 모사하고 있는 것을 확인할 수 있다. 이 때, 확인할 수 있는 약간의 오차는 임의의 속도에서 발생하는 변위를 확인하기 위해서 모든 속도에서 계측한 변형률과 변위 자료를 하나의 인공신경망에 적용하여 학습을 수행하였기에 발생하는 현상으로 해석할 수 있다.

### 5. 결론 및 향후 적용방향

본 연구에서는 차량의 이동하중에 의한 교량의 수직 변위를 추정하기 위해서 인공신경망을 적용하였다. 교량의 수직방향 변위를 직접적으로 측정하는 것은 환경적인 제약으로 인해 실제 적용에 많은 어려움이 있기 때문에 변형률 센서를 사용하여 획득되는 축방향 변형률 계측 자료를 이용하여 교량의 수직방향 변위를 추정하는 방법을 제시하였다. 수치해석을 통하여 대상 교량에 변형률과 변위 자료를 획득하기 위해서 교량을 모델링하였으며, 실제 차량의 이동을 모델링에 적용시키기 위해서 차량이동하중 시나리오를 구성하였다. 차량이동하중 시나리오를 작성함에 있어서 Pearson Type III 분포에 대한 이론식을 적용하여 실제 교통상황을 반영할 수

있도록 구성하였다. 실제 시나리오를 적용하여 획득된 학습 자료를 바탕으로 인공신경망에 적용시켜 교량의 수직 방향 변위를 추정할 수 있는 방안을 모색하였고 다음과 같은 결론을 도출하였다.

첫째, 실제 시나리오를 통해서 배치된 차량에 의해 획득된 자료를 이용하여 인공신경망을 학습시킨 후, 임의적인 차량 배치에 의해 발생하는 변형률을 학습된 인공신경망에 적용하여 교량의 수직 변위를 추정할 수 있었다.

둘째, 축방향 변형률을 이용한 수직방향 변위를 추정하는데 사용된 인공신경망에서 학습률과 모멘텀항, 은닉층의 유니트수에 따른 결과의 차이가 크게 나타나지 않았다. 본 연구에서는 학습률 0.1과 모멘텀항 계수 0.9를 사용하여 실제 교량의 수직 변위를 인공신경망을 통해서 추정할 수 있었다.

본 연구를 통해서 변형률 측정과 변위 측정에 대한 수치해석을 통해서 이후 교량 구조물에서 확장시켜 변위추정이 쉽지 않은 구조물이나 바람에 의해서 많은 영향을 받는 고층구조물, 그리고 여러 가지 하중에 의해 영향을 받는 LNG가스탱크와 같은 구조물의 유지·관리에 활용이 가능하다.

### 감사의 글

본 연구는 BK21플러스사업 ‘레질리언트 사회기반시설 창의인재양성사업단’의 연구비지원에 의해 수행되었습니다.

## References

- AASHTO (2002). *AASHTO Standard specifications for highway bridges*, 17th Edition, Washington, D.C.
- AASHTO (2007). *AASHTO LRFD bridge design specifications*, 4th Edition, Washington, D.C.
- Ahmed, K. A., Abdelhady, M. B. A. and Abouelnour, A. M. A. A. (1997). "The improvement of ride comfort of a city bus which is fabricated on a lorry chassis." *Engineering Research Journal*, Vol. 53 (June).
- Cho, N. S. and Kim, N. S. (2008). "Prediction of the static deflection profiles on suspension bridge by using FBG strain sensors." *Journal of KSCE*, Vol. 28, No. 5A, pp. 699-707 (in Korean).
- Chun, P. (2010). *Skewed bridge behaviors: Experimental, Analytical, and Numerical Analysis*, Ph.D. Dissertation, Wayne state University, Detroit.
- Hong, Y. H. (2007). *A regularization scheme for displacement reconstruction using acceleration data measured from structures*, Master Dissertation, Seoul National University Graduate School, Seoul (in Korean).
- Jang, S. J. and Kim, N. S. (2008). "Estimation of displacement response from the measured dynamic strain signals using mode decomposition technique." *Journal of KSCE*, Vol. 28, No. 4A, pp. 507-515 (in Korean).
- Kim, B. T., Kim, Y. S. and Lee, W. J. (2000). "Prediction of lateral deflection and maximum bending moment of model piles using artificial neural network." *Journal of KGS*, Vol. 16, No. 5, pp. 169-178 (in Korean).
- Kim, N. S. and Cho, N. S. (2002). "Estimation of bridge deflection using fiber optic bragg-grating sensors." *Journal of KSCE*, Vol. 22, No. 6A, pp. 1357-1366 (in Korean).
- Li, H. (2005). *Dynamic response of highway bridges subjected to heavy vehicles*, Ph.D. Dissertation, The Florida State University, Panama.
- May, A. D. (1990). *Traffic flow fundamentals*, Prentice Hall, Englewood Cliffs.
- Moon, T. H. (2000). "ANN simulation of the parcel-based land price appraisal." *Journal of KPA*, Vol. 35, No. 2, pp. 33-42 (in Korean).
- Moses, F. (1979). "Weigh-in-Motion system using instrumented bridges." *Transportation Engineering Journal*, Vol. 105, No. 3, pp. 233-249.
- Mussone, L., Rinelli, S. and Reitani, G. (1996). "Estimating the accident probability of a vehicular flow by means of an artificial neural network." *Environment and Planning B: Planning and Design*, Vol. 23, No. 6, pp. 667-675.
- Powell, G. H. and Allahabadi, R. (1988). "Seismic damage prediction by deterministic methods : Concept and Procedure." *Earthquake Engineering And Structural Dynamics*, Vol. 16, pp. 719-734.
- Zeng, H. and Bert, C. W. (2003). "Dynamic amplification of bridge/vehicle interaction: A Parametric Study for a Skewed Bridge." *Journal of Structural Stability and Dynamics*, Vol. 3, No. 1, pp. 71-90.
- Zuo, L. and Nayfeh, S. A. (2003). "Structured H2 optimization of vehicle suspensions based on multi-wheel models." *Vehicle System Dynamics*, Vol. 40, No. 5, pp. 351-371.