

# 인공신경망을 이용한 강박스거더의 유효온도 산정

이성행  
부산대학교 토목공학과

## Calculation of Maximum Effective Temperature of Steel Box Girder Bridge Using Artificial Neural Network

Seong- Haeng Lee

Department of Civil Engineering, Pusan National University

**요 약** 교량의 온도 설계하중의 기준이 되는 유효온도는 통계적 방법에 의한 분석이 일반적으로 사용된다. 본 연구에서는 통계적 방법을 개선할 수 있는 인공신경망을 구축하여 유효온도를 산정하였다. 강상자형교 시험체를 폭 2.0m, 높이 2.0m, 길이 3.0m, 상부슬래브 0.2m로 제작하였다. 21개의 온도 게이지를 부착하여 3년간(2014~2015) 온도를 측정하였다. 2014~2015년 측정된 온도데이터를 바탕으로 인공신경망을 학습시키고, 그 결과를 Euro code와 비교하였다. Euro code와 통계분석 값과의 오차율은 전체 측정점에 대하여 4.1%로 분석되었다. 2016년 측정된 온도데이터를 이용하여 인공신경망을 검증하고, 교량 유효온도를 산정하였다. 이 결과는 통계분석 값과 약 3.97%의 차이를 보였다. 이 정도의 오차율은 인공신경망에 의한 분석이 공학적인 측면에서 수용할 수 있는 크기인 것으로 판단된다. 인공신경망은 교량의 온도하중 설계 시 그 지역의 최고 대기온도, 교량 형식, 상부 아스팔트 두께 등 입력 값만 알면 교량의 유효온도를 간편히 예측해 줄 수 있다.

**Abstract** An analysis using a statistical method is generally used to determine the effective temperature based on the temperature design load of a bridge. In this study, the effective temperature was calculated by building an artificial neural network (ANN) capable of improving the statistical method. A Steel box girder bridge specimen was made with a width of 2.0 m, height of 2.0 m, and length of 3.0 m and 0.2 m the upper slab. Twenty one temperature gauges were attached to measure the temperature between 2014 and 2016 for three years. An ANN was learned using the data measured from 2014~2015 and the results were compared with the Euro codes. The error rate between the Euro code and statistical analysis values was analyzed to be 4.1 % for the total measurement point. The ANN was verified and the effective bridge temperatures were calculated using the temperature data measured in 2016. The results revealed an approximate 3.97 % difference from the statistical analysis values. This degree of error is considered to be acceptable in terms of engineering for the analysis of an ANN. An ANN can easily predict the effective temperature of a bridge by knowing the input values of the region's highest temperature, bridge type, and upper asphalt thickness when designing the bridge's temperature loads.

**Keywords :** Artificial neural network, Euro code, Maximum effective temperature, Steel box girder bridge specimen, Temperature measurement.

### 1. 서론

국내 구조물 설계환경이 LSD(한계상태설계법) 설계 기준으로서의 전면 전환시행을 앞두고 있다. 선진 설계기

법인 LSD 및 LRFD 등의 설계기준을 정립, 적용하고 있는 국가에서는 이미 오래전부터 50~100년 이상의 기상 데이터를 기반으로 한 온도하중에 대한 연구와 하중관련 규정이 이미 완비되어 있다. 이에 비하여 국내의 설계기

본 연구는 한국연구재단(NRF-2011-0023229, NRF-2015-R1D1A1A01060616)의 지원으로 수행되었음.

\*Corresponding Author : Seong-Haeng Lee(Pusan Nat'l Univ.)

Tel: +82-51-510-7645 email: lsh77@pusan.ac.kr

Received January 4, 2018

Revised (1st January 30, 2018, 2nd March 2, 2018)

Accepted March 9, 2018

Published March 31, 2018

준은 아직 미비한 상태이며, 이러한 차이를 극복하기 위하여 연구가 수행되고 있다[1],[2],[3].

온도 하중은 여름의 최고 온도와 겨울의 최저 온도에 따라서 결정되는데, 이를 반영하기 위하여 EURO Code[4]에서는 유효온도 개념이 도입된다. 유효온도는 교량 전체를 대표하는 기온으로 평균온도를 나타내는 개념이며, 여름철의 최고 유효온도와 겨울철의 최저 유효온도로 구분되며, 가능한 기상관측 자료가 사용될 수 있다.

국내 온도하중에 대한 자료를 활용하여 설계하중의 기본 자료를 확보하기 위하여 일반적으로 신뢰도를 기반으로 한 통계분석과 함께, 인공신경망을 병행 활용하는 것이 가능할 것이다. 통계분석에 의한 분석은 결과를 예측하기 위한 자료가 추가될 경우, 새로운 통계분석의 전 과정을 거쳐야 하므로, 시간과 노력이 많이 소요되는데 반하여, 인공신경망은 기존 자료와 신규자료를 합쳐 컴퓨터에 의한 수치적인 학습과정만으로 새로운 결과를 빠르게 예측하는데 효과적인 도구가 될 수 있다. 또한 인공신경망은 특정 판단을 수행하기 위한 파라미터가 다양하고, 그 관계가 복잡다단할 경우에 인간 뇌의 판단 절차를 모사하여 결과를 예측하는 것으로서, 유효한 도구가 되어 토목분야에서도 많은 연구가 이루어지고 있다[5],[6],[7],[8].

다년간 측정된 온도 데이터를 이용하여 통계분석을 하게 되면 대기온도와 그에 대응하는 교량의 유효온도를 추출할 수 있다. 그러나 통계분석의 경우, 분석자의 선택에 따라 분석방법과 분석도구가 선택되고, 이에 따라 결과가 달리 해석될 여지가 있게 된다. 반면 인공신경망은 동일하게 코딩된 알고리즘에 의거하여 데이터만이 변경, 보완되므로, 일관성을 갖출수 있으며, 컴퓨터에 의한 학습만으로 결과를 제시하므로, 편리성과 경제성이 있다. 또한 측정 데이터를 바탕으로 인공신경망을 조직하고 학습하면, 특정 지역 대기온도를 입력하였을 때 그에 해당하는 교량 유효온도를 인공신경망이 예측해 줄 수 있는 적용성에 그 유용함이 있다. 또한 풍속, 교량의 상부 아스팔트 두께 등 다양한 파라메타를 추가하여 계속해서 인공신경망을 업데이트 할 수 있고, 누적데이터를 바탕으로 더욱 정교한 인공신경망을 구성할 수 있다.

본 연구에서는 교량시험체를 제작하여 국내 실 사용 조건과 같이 배치하여 온도를 측정하고, 기상청의 온도 자료와 함께 통계 분석하여 도출된 유효온도를 인공신경망을 이용하여 학습, 예측하고, 유로코드 및 실측데이터 등과 비교하여 인공신경망의 적용성을 평가하고자 하였

다. 이를 위하여 교량시험체의 2014년 ~ 2015년 측정 온도 중 일 최고온도 데이터를 통계 분석하여 최확값 유효온도를 얻은 뒤 인공신경망의 학습을 수행하며, 2016년 측정된 최고유효온도에 대하여 학습된 인공신경망의 검증을 수행하여, 인공신경망을 통한 교량의 설계 유효 온도 산정이 가능함을 확인하였다.

## 2. 유효온도 분석 및 데이터 구성

### 2.1 시험체 제작

대기온도에 따른 교량의 유효온도 산정을 위해, 일반적으로 많이 사용되는 강합성 거더의 시험체를 Fig. 1과 같이 제작하였다. 상부 슬래브는 200mm 두께의 콘크리트로 제작되었고, 하부 박스거더는 두께 10mm의 강판을 용접하여 제작되었다. Fig. 2는 시험체 단면의 온도계 부착 위치를 나타낸 것이다. 시험체의 온도 측정을 위해 총 21개의 온도계를 부착하였다. 시험체는 경상남도 양산시 물금읍에 위치한 부산대학교 양산캠퍼스에 설치되어 있다.



Fig. 1. Figure of Specimen




Fig. 2. Section and gauge numbers of specimen

### 2.2 유효온도의 산정

높은 대기온도의 분포를 보일 것으로 예상되는 2014년 7~8월, 2015년 7~8월까지 총2415개의 데이터를 이용하여 유효온도를 산정하였다. 유효온도의 산정을 위해 각 측정에서 측정된 온도데이터에 대하여 티센가중법 [9](Thiessens weighting method)을 적용하였다. 이는 각 온도측정 게이지별로 유효면적을 산정하고 면적에 가중치를 주어 유효온도를 산정하는 방법이다. Table 1은 시험체의 온도 게이지별 유효면적을 나타낸 것이고, Fig. 3, Fig. 4는 측정 기간 동안의 SC19(2200mm), SC5(1000mm) 위치에서의 온도 분포 예시를 나타낸 것이다.

$$E.T = \frac{\sum(A \times T)}{\sum A}$$

E.T= Effective Temperature

A= Area, T= Temperature

Table 1. Area of each parts of Specimen

Unit : mm<sup>2</sup>

	Gauge	A	Gauge	A
Steel	SC1	5450	SC17	5450
	SC2	2050	SC16	2050
	SC3	1950	SC15	1950
	SC4	3400	SC14	3400
	SC5	5950	SC13	5950
	SC6	4500	SC12	4500
	SC7	2150	SC11	2150
	SC8	5450	SC10	5450
	SC9	9100	SC18	9100
Con	SC19	170850		
	SC20	170850		
	SC21	339150		
	∑	760850		




Fig. 3. Example of temperature distribution (2200mm)




Fig. 4. Example of temperature distribution (1000mm)

### 2.3 통계분석에 의한 유효온도와 Euro Code와의 비교

통계분석을 통한 유효온도 값을 검증하기 위해 Euro code(British Standards)[6]와 비교해 보았다. Table 2는 각 대기온도에 따른 Euro code값과 통계분석에 의한 값을 나타낸 것으로, 강합성 모형에 대한 Euro code는 대기온도 38°C ~ 26°C에 대해 제시되었다. 오차율은 Euro code와 통계분석 값 간의 차이를 백분율로 나타내었으며, 전체 측점에 대한 평균 오차율은 약 4.1% 정도이다. Fig. 5는 대기온도에 따른 Euro code(직선)와 통계분석(점) 값을 나타낸 그래프이다. 30°C 이상의 높은 대기온도에서 Euro code에서 제시한 값과 통계분석 값이 더 큰 유사성을 가진다.

Table 2. Area of each parts of Specimen

Air (°C)	Euro Code (°C)	Statistics (°C)	Different (%)
38	40	42.3	5.8
37	40	41.3	3.2
36	39	40.3	3.3
35	39	39.2	0.6
34	38	38.2	0.6
33	37	37.2	0.5
32	37	36.2	2.3
31	36	35.1	2.4
30	36	34.1	5.2
29	35	33.1	5.5
28	34	32.1	5.7
27	34	31.0	8.7
26	33	30.0	9.1




Fig. 5. Comparison statistics between Euro code

### 2.4 인공신경망 학습용 데이터 추출

통계분석을 이용해 최고 유효온도를 산정하였고 Euro code와 비교하였다. 이 값을 인공신경망에 학습시키기 위한 학습용 데이터로 변환하였다. 인공신경망 학습용 데이터는 30분마다 측정된 온도 데이터 각각에 테센가

Table 3. Examples of learning data set for ANN (2014.08.06.)

Measurement data							Learning data	
Time	SC1	SC3	SC5	SC7	SC9	SC21	Air temperature	Statistical analysis
10:14	29.9	30.9	32.1	31.4	29.9	28	30.1	28.6
10:18	28.9	31.2	32.4	31.7	30.1	28.1	31.1	28.7
10:44	29.8	32.3	34	33.3	31.2	29	31.6	29.7
11:14	30.9	33.8	35.6	35	32.1	29.9	32.3	30.4
11:44	31.8	34.5	36.7	36.5	32.6	31.1	31.3	30.9
12:14	32.8	35.8	37.9	37.6	33.3	31.8	32.2	31.6
12:44	33.8	36.8	39.2	38.9	33.8	32.9	32.4	32.6
13:14	34.7	37.7	40.5	40.4	34.7	33.8	33	33.7
13:44	35.4	38.1	40.9	41	34.8	34.8	32.3	34.5
14:14	36.1	38.7	41.7	42.1	35.2	35.6	32.4	35.0
14:44	36.5	37.8	40.1	40.1	34.5	36.2	30.2	35.4
15:14	36.5	37.3	39.3	39.3	34	36.4	31.2	35.4
15:44	36.4	36.5	38.2	38.4	33.6	36.6	31.8	35.4
16:14	35.4	35.1	35.8	35.5	32.6	36.4	30.2	35.0
16:44	35.4	34.8	36.1	36.2	32.4	36.4	30.6	34.9
17:14	35.5	35	37.8	37.3	32.4	36.3	29.9	34.8
17:44	35.6	35.2	38.6	37.5	32.2	36.1	29.8	34.8
18:14	35.4	34.9	37.2	35.3	31.9	35.9	29.8	34.3
18:44	35	33.9	34.6	33	31.2	35.6	29.1	33.8
19:14	34.3	32.7	32.3	31.3	30.8	35.1	28.7	33.4
19:44	34.1	32.1	31.1	30.2	30	34.8	28.3	33.1
20:14	33.6	31.5	30.4	29.5	29.5	34.3	27.9	32.7
20:44	33.2	31	29.7	28.8	29	33.8	27.1	32.2
21:14	32.7	30.4	29.1	28.3	28.6	33.3	27.1	31.7
21:44	32.3	29.9	28.6	27.8	28.2	32.8	26.7	31.2
22:14	31.6	29.4	28.1	27.4	27.7	32.3	26.4	30.7
22:44	31.2	29.1	27.8	27.1	27.5	31.9	26	30.3
23:14	30.8	28.7	27.5	26.8	27.2	31.4	26	29.8
23:44	30.4	28.5	27.3	26.6	26.9	30.9	25.9	29.4

중법[9]을 적용하여 각각의 유효온도를 산정한 총 2415 개의 온도데이터와 그에 대응하는 유효온도이다. 인공신경망의 정밀도를 높이기 위하여 같은 대기온도를 가지는 서로 다른 유효온도 값에 대하여는 최고 유효온도만을 선택적으로 고려한 결과, 최종 학습용 데이터는 총 185 개로 구성되어진다. Table 3은 학습용 데이터 추출 예시이며, 표의 가장 오른쪽 2개의 값인 대기온도와 유효온도가 학습용 데이터 세트가 된다.

## 3. 인공신경망 구성

### 3.1 조직

Fig. 6.은 유효온도를 예측하기 위한 인공신경망구조의 개략적인 모식도를 나타낸 그림이다. Table 4는 인공신경망의 입-출력층 파라미터가 될 수 있는 인자들을 나타낸 것이다. 인공신경망을 이용하면 다양한 입력층 파라미터를 활용하여 교량유효온도를 예측할 수 있다. 실제로는 Table 4에 있는 파라미터 이외에 더 많은 인자가 있을 것이나 논문에서는 최고 대기온도에 의해서만 교량 유효온도가 결정된다고 가정한다.




Fig. 6. ANN schematic diagram

Table 4. Parameters for predicting effective temperature

Stage	Input layer	Output layer
Parameta	Maximum air temperature(A*), Minimum air temperature(N*), Wind speed(N*), Bridge type(N*), Asphalt depth of concrete deck(N*)	Effective temperature of bridge

A\*: Applied item, N\*: Non-use item

Table 5. Number of nodes used in ANN

Layer	Input ( <i>i</i> ) layer	Inner ( <i>j</i> ) layer	Out ( <i>k</i> ) layer
The number of neurons	2	4-8	1

### 3.2 인공신경망 학습 및 분석

인공신경망 학습을 위한 학습용 데이터 쌍은 2.4절의 Table 3과 같은 방식으로 추출된 185개의 데이터이며, 학습용 데이터는 모두 대기온도가 다르며, 최고 유효온도 산정을 위하여 대기온도 20℃를 넘는 데이터만을 포함하였다. 이후 학습용 데이터를 인공신경망에 학습시켜 가중치(Weight)를 도출하였다.




Fig. 7. Effective temperature estimated by each method

Fig. 7의 각 점은 앞서 2014년 7~8월 2015년 7~8월 까지 총 2415개 데이터 각각을 통계분석 한 유효온도를 나타낸 것이고, 3차 곡선은 이 유효온도의 추세선을 나타낸 것이다. 또한 마른모 모양의 굵은 곡선은 학습된 인공신경망에 185개 대기온도만을 입력하였을 때 도출된 유효온도 값을 보인다.

3차 추세선(통계분석)과 곡선형 굵은 곡선(인공신경망)을 비교해 보았을 때 22~35℃ 대기온도 범위에서 인공신경망의 유효온도가 더 높은 것을 알 수 있다. 이는 인공신경망을 학습시킬 때 대기온도 20℃ 이상을 사용하고 같은 대기온도를 가지는 유효온도 중 가장 높은 값을 가지는 데이터만을 인공신경망의 학습에 사용하였기 때문으로 판단된다. 35℃ 이상의 대기온도에서는 3차 다항식의 추세선으로 통계분석 한 값의 유효온도가 더 높게 나타났다.

### 3.3 인공신경망 검증

인공신경망의 예측결과를 검증하기 위해 2016년 8월의 데이터를 이용하였다. 검증용 데이터 추출방법은 앞


서 학습용 데이터 추출 방법과 동일하다. Table 6은 8월 한달 동안의 분석 값 중, 8월 1일 하루 동안(24시간)의 인공신경망 결과 값의 검증 예시이다. 이 표의 ‘유효온도’ 값은 통계분석을 통한 최고 유효온도를 나타낸 것이고 ‘ANN’값은 인공신경망에 대기온도 인자만 넣었을 때 인공신경망에서 도출한 유효온도 값이다.

Table 6. Verification of ANN

Time	Air temperature	Effective temperature	ANN	Error rate(%)
2016-08-01 0:15	27.2	31.1	33.8	8.5
2016-08-01 0:45	27.2	30.5	33.8	10.6
2016-08-01 1:15	26.8	30.5	33.2	9.0
2016-08-01 1:45	26.6	30.6	33.0	7.9
2016-08-01 2:15	26.4	30.3	32.7	8.1
2016-08-01 2:45	26.3	29.3	32.6	11.1
2016-08-01 3:15	26.3	29.7	32.6	9.7
2016-08-01 3:45	26.1	29.4	32.3	9.8
2016-08-01 4:15	26.3	29.0	32.6	12.3
2016-08-01 4:45	26.2	29.4	32.4	10.4
2016-08-01 5:15	26.3	29.3	32.6	11.1
2016-08-01 5:45	26.3	29.1	32.6	11.9
2016-08-01 6:15	26.2	29.1	32.4	11.3
2016-08-01 6:45	26.4	28.4	32.7	15.2
2016-08-01 7:15	26.7	29.1	33.1	13.9
2016-08-01 7:45	27.4	29.3	34.0	16.0
2016-08-01 8:15	28.4	29.8	35.2	17.9
2016-08-01 8:45	29.6	30.1	36.4	20.7
2016-08-01 9:15	30.2	30.8	36.9	20.0
2016-08-01 9:45	30.7	31.8	37.4	17.7
2016-08-01 10:15	32.5	33.0	38.7	17.3
2016-08-01 10:45	32.7	33.8	38.9	14.9
2016-08-01 11:15	32.5	34.7	38.7	11.5
2016-08-01 11:45	34.3	35.9	39.8	11.1
2016-08-01 12:15	34.2	37.0	39.8	7.6
2016-08-01 12:45	34.7	37.7	40.0	6.1
2016-08-01 13:15	35.3	38.7	40.4	4.3
2016-08-01 13:45	35.9	39.5	40.6	2.9
2016-08-01 14:15	35.4	40.4	40.4	0.0
2016-08-01 14:45	33.7	40.5	39.5	2.4
2016-08-01 15:15	32.9	40.4	39.0	3.4
2016-08-01 15:45	29.4	39.5	36.2	8.3
2016-08-01 16:15	26.1	37.2	32.3	13.3
2016-08-01 16:45	24.8	35.5	30.3	14.6
2016-08-01 17:15	25.6	34.4	31.6	8.3
2016-08-01 17:45	25.5	33.7	31.4	6.8
2016-08-01 18:15	25.2	33.1	31.0	6.5
2016-08-01 18:45	25.2	32.5	31.0	4.7
2016-08-01 19:15	25.1	32.1	30.8	4.0
2016-08-01 19:45	24.8	31.8	30.3	4.7
2016-08-01 20:15	25.1	31.4	30.8	1.8
2016-08-01 20:45	25.0	30.8	30.7	0.4
2016-08-01 21:15	24.8	30.4	30.3	0.3
2016-08-01 21:45	24.9	30.2	30.5	1.0
2016-08-01 22:15	24.9	29.9	30.5	2.1
2016-08-01 22:45	24.6	29.4	30.0	2.2
2016-08-01 23:15	24.4	29.2	29.7	1.6
2016-08-01 23:45	24.6	28.7	30.0	4.7

**Table 7.** Comparison between ANN and Statistics analysis in effective temperature (2016)

Air (°C)	Euro Code (°C)	Statistics (°C)	ANN (°C)
38	40	43.6	42.6
37	40	42.8	42.2
36	39	42.0	41.8
35	39	41.1	41.3
34	38	40.1	40.7
33	37	39.0	40.1
32	37	37.9	39.4
31	36	36.8	38.6
30	36	35.6	37.7
29	35	34.3	36.7
28	34	33.1	35.6
27	34	31.8	34.4
26	33	30.5	33.0




**Fig. 8.** Comparison between ANN and Statistics in effective temperature

Table 7은 통계자료에 의한 유효온도 값과 인공신경망을 통한 유효온도 값을 Euro code와 비교한 것이다. 8월 한 달 동안 26°C에서 38°C 구간에서 인공신경망의 유효온도값은 통계분석된 유효온도 값과 전체 평균 오차율 3.97%로 유사한 경향을 나타내었다. 이 정도의 오차율은 공학적인 측면에서 수용할 수 있는 크기인 것으로 판단된다. 또한 ANN 분석값은 Euro Code의 값과 5.04%의 오차율이 계산되었고, 통계분석은 Euro Code의 값과 5.52%의 오차율이 계산된다. 인공신경망은 실측데이터를 바탕으로 유효온도를 예측하고, 그 추론의 과정이 인간의 두뇌와 같은 블랙박스의 계산결과로서, 분명한 이론적 접근이 없어 그 차이를 분명히 제시할 수는 없으나, 이러한 오차가 공학적인 측면에서 수용할 수 있다면, 적용에는 문제가 없다고 판단된다. Fig. 8은 Table 7의 값을 그래프화 시킨 것으로 통계분석 값과 인공신경망 값 사이의 유사한 경향을 볼 수 있다. Fig. 8에 따르면 두 값의 상관계수는 분석결과 0.97로 산정되어, 높은 유사성을 나타냈다

대기온도 36°C이하의 온도에서는 인공신경망의 유효온도가 높지만, 대기온도 37°C이상의 온도에서는 3차 다항식으로 통계분석 된 유효온도 값이 더 높게 산정되었다.

#### 4. 인공신경망 활용

학습된 인공신경망의 예상결과를 이용하여 지도상에 지역별 최고 유효온도 Contour map의 작성이 가능하다. 이는 사계절 온도 분포가 뚜렷한 국내 지역별 교량의 최고 유효온도 분포를 가시적으로 나타내어 온도 설계시 유효하게 사용될 수 있다. Fig. 9와 Fig. 10은 ARC-GIS 프로그램을 이용하여 작성한 온도 contour map 예시이며, 기상청에서 지역별 50년 빈도 대기온도 자료를 활용하여 온도 contour map을 작성하였다. contour map작성할 때, 인공신경망을 이용하면 아래 온도 contour map과 같이 많은 양의 대기온도 데이터를 한 번에 처리할 수 있어 contour map 작성에 유리한 점이 있다.



**Fig. 9.** Contour map of statistical analysis in maximum Temperature

Fig. 9는 통계분석을 통한 온도 contour map이며, Fig. 10은 ANN을 이용한 온도 contour map을 작성한 것이다. 향후 다년간의 온도데이터가 쌓이면 신뢰성 높



은 contour map의 작성이 가능 할 것이다. contour map 작성을 위하여 통계적인 분석기법을 적용할 경우와 비교하여, 인공신경망을 이용하면 온도 contour map의 작성 과정에서 소요되는 많은 양의 작업을 쉽게 처리할 수 있어 contour map 작성에 유리할 것이다.




Fig. 10. Contour map of ANN in maximum Temperature

## 5. 결론

콘크리트 슬래브가 있는 강박시험체의 제작을 통해 2014년, 2015년, 2016년 온도를 측정하고, 이를 바탕으로 인공신경망을 학습, 검증하여 유효온도를 산출하고 다음과 같은 결론을 도출하였다.

- (1) 다년간의 온도 측정 데이터를 바탕으로 인공신경망을 학습, 검증하여 신뢰성 있는 인공신경망을 구축하였다.
- (2) 2016년 데이터를 이용한 인공신경망 검증에서 통계분석 유효온도와 인공신경망의 유효온도 값은 상관계수는 0.97, 평균 오차율은 약 3.97%로 유사한 상관관계를 가진다.
- (3) 대기온도 36℃이하의 온도에서는 인공신경망의

유효온도가 높지만, 대기온도 37℃이상의 온도에서는 3차 다항식으로 통계분석 된 유효온도 값이 더 높은 것을 알 수 있다. 통계분석과 인공신경망의 산정결과 오차율은 3.97%로, 공학적인 측면에서 수용할 수 있는 크기인 것으로 판단된다.

- (4) 신뢰성 높은 유효온도 값을 도출하기 위해 다년간의 온도측정 데이터가 누적되면, 우리나라 각 지역별로 대기온도에 대한 신뢰성있는 contour map을 산정할 수 있을 것이다. 이때 인공신경망을 활용하면, 통계분석 방법보다 편리하고, 유용하게 온도 contour map을 작성 할 수 있다. 특히 온도 데이터가 추가되거나, 다른 변수가 추가되었을 때 유용한 도구가 될 수 있다.

인공신경망을 이용함으로써, 추가적인 온도데이터의 확충이나 비선형적인 인과관계를 갖는 입출력간의 예상 가능성이 가능함을 제시하여, 기존의 통계분석의 방법에 비하여 시간적, 비용적으로 효율적인 인공신경망의 적용이 가능함을 제시하였다. 그러나 인공신경망은 인간의 두뇌에서 이루어지는 추론과 비슷한 블랙박스식의 계산결과로서, 그 계산에 대한 분명한 이론적 접근이 없는 것도 사실이다. 다만, 현재의 기술수준에서 많은 인공신경망들이 검증을 통하여 적절한 수준의 결과를 도출하고 있고, 현실에 적용되어 무리 없이 사용되고 있다. 추후, 지역의 최고 대기온도 뿐 아니라, 교량 형식, 상부 아스팔트 두께 등에 대하여 추가적인 연구와 학습이 이루어진다면, 폭넓은 적용이 가능할 것이다.

## References

- [1] Lee, S. H., Shin, H. K., Kim, K. N., Jung, k. S., An Experimental Study for Estimation of effective temperature for design in Steel Box Girder Bridge, *Journal of korean Society of Steel Construction*, Vol, 28, no. 6, pp. 449-458, 2016.
- [2] Lee, S. H., Evaluation of Maximum Effective Temperature for Estimate Design Thermal Loads in Steel Box Girder Bridges, *Journal of the korea Academia-Industrial cooperation Society*, vol. 17, no. 8, pp. 133-138, 2016.  
DOI: <http://dx.doi.org/10.5762/KAIS.2016.17.8.133>
- [3] Lee, S. H., Study of the Temperature Difference between the Top and Bottom Web of Steel Box Girder without Concrete Slab by using Gauge Measurement, *Journal of the Korea Academia -Industrial cooperation Society*, Vol, 15, no. 12, pp. 7350-7356, 2014

- [4] British Standards Institution, Steel, Concrete and Composite Bridges, Part 2. Specification for loads, appendix E. BS5400: Part2:1978, pp. 20-23, 2004.
- [5] Lee, J. H., Kim, S. G., Chang, S. P., Frequency Domain Pattern Recognition Method for Damage Detection of a Steel Bridge, *Journal of Korean Society of Steel Construction*, vol. 17, no. 1, pp. 1-12, 2005.
- [6] Choi, B. H., Lim, J. H., Design of Steel Structures Using the Neural Networks with Improved Learning, *Journal of Korean Society of Steel Construction*, vol. 17, no. 6, pp. 661-671, 2005.
- [7] Park, M. S., Jo, B. W., Lee, J. W., Kim, S. K., Development of Steel Composite Cable Stayed Bridge Weigh-in-Motion System using Artificial Neural Network, *Korean Society of Civil Engineers*, vol. 28, no. 6A, pp. 799-808, 2008.
- [8] Kim, K. N., Lee, S. H., Jung, K. S., Prediction on the Fatigue life of Butt-Welded Specimens Using Artificial Neural Network, *International Journal of Steel and Composite Structures*, vol. 9, no. 6, pp. 557-568, 2009. DOI: <https://doi.org/10.12989/scs.2009.9.6.557>
- [9] Yoo, C. S., Jung, K. S., Estimation of Area Average Rainfall Amount and Its Error, *Journal of Korea Water Resources Association*, KCI 1738-9488, vol. 34, no. 4, pp. 317-326, 2005.

이 성 행(Seong-Haeng Lee)

[정회원]



- 1983년 2월 : 충북대학교 토목공학과 (공학사)
- 1985년 2월 : 서울대학교 토목공학과 (공학석사)
- 1997년 2월 : 충북대학교 토목공학과 (공학박사)
- 1997년 9월 ~ 현재 : 부산대학교 토목공학과 교수

<관심분야>

강교량, 교량 온도하중, 대형수문 진동실험