

## 인공신경망모델을 이용한 교량의 상태평가

### A Condition Rating Method of Bridges using an Artificial Neural Network Model

오순택<sup>†</sup> · 이동준\* · 이재호\*\*

Soon-Taek OH · Dong-Jun Lee · Jae-Ho Lee

**Abstract** It is increasing annually that the cost for bridge Maintenance Repair & Rehabilitation (MR&R) in developed countries. Based on Intelligent Technology, Bridge Management System (BMS) is developed for optimization of Life Cycle Cost (LCC) and reliability to predict long-term bridge deteriorations. However, such data are very limited amongst all the known bridge agencies, making it difficult to reliably predict future structural performances. To alleviate this problem, an Artificial Neural Network (ANN) based Backward Prediction Model (BPM) for generating missing historical condition ratings has been developed. Its reliability has been verified using existing condition ratings from the Maryland Department of Transportation, USA. The function of the BPM is to establish the correlations between the known condition ratings and such non-bridge factors as climate and traffic volumes, which can then be used to obtain the bridge condition ratings of the missing years. Since the non-bridge factors used in the BPM can influence the variation of the bridge condition ratings, well-selected non-bridge factors are critical for the BPM to function effectively based on the minimized discrepancy rate between the BPM prediction result and existing data (deck; 6.68%, superstructure; 6.61%, substructure; 7.52%). This research is on the generation of usable historical data using Artificial Intelligence techniques to reliably predict future bridge deterioration. The outcomes (Long-term Bridge deterioration Prediction) will help bridge authorities to effectively plan maintenance strategies for obtaining the maximum benefit with limited funds.

**Keywords** : MR&R, BMS, ANN, BPM

요 지 대부분의 선진국에서 교량의 유지보수 및 보강(Maintenance Repair & Rehabilitation-MR&R)으로 인한 비용은 해마다 증가하고 있다. 전산화된 교량유지관리 및 의사결정시스템(Bridge Management System-BMS)은 가능한 최저의 생애주기비용(Life Cycle Cost - LCC)에 최적의 안정성을 확보하기 위해 개발되었다. 본 논문에서는 제한된 현존하는 교량진단기록을 이용하여 현존하지 않는 과거의 교량상태등급 데이터를 생성하기 위해 Backward Prediction Model (BPM)이라 불리는 인공신경망(Artificial Neural Network-ANN)에 기초한 예측모델을 제시한다. 제안된 BPM은 한정된 교량 정기점검기록으로부터 현존하는 교량진단기록과 연관성을 확립하기 위해 교통량과 인구, 그리고 기후 등과 같은 비구조적 요소를 이용하며, 제한된 교량진단기록과 비구조적 요소 사이에 맺어진 연관성을 통해 현존하지 않는 과거의 교량상태등급 데이터를 생성할 수 있다. BPM의 신뢰도를 측정하기 위하여 Maryland DOT로 부터 얻어진 National Bridge Inventory(NBI)와 BMS 교량진단자료를 이용하였다. 이중 NBI자료를 이용한 Backward comparison 에 있어서 실제 NBI기록과 BPM으로 생성된 교량상태등급과의 차이(상판: 6.68%, 상부구조부: 6.61%, 하부구조부: 7.52%)는 BPM 으로 생성된 결과의 높은 신뢰도를 보여준다. 이 연구의 결과는 제한된 정기점검 기록으로 야기되는 BMS의 장기 교량 손상 예측에 관련된 사용상의 문제를 최소화하고 전반적인 BMS 결과의 신뢰도를 높이는데 기여 할 수 있다.

주 요 어 : 교량 유지보수 및 보강, 교량관리시스템, 인공신경망, 손상예측모형

<sup>†</sup> 책임저자 : 정회원, 서울산업대학교, 건설공학부, 교수

\* 교신저자 : 서울산업대학교, 건설공학부, 강사

E-mail : djlee@snut.ac.kr

TEL : (02)970-6576

\*\* Griffith University, School of Engineering, Reseacher

### 1. 서론

교량은 사회기반시설 중 국가경제 사회발전에 중요한 요소로서 운송 네트워크에 있어서도 중요한 요소 중 하나이다. 교량의 공용연한과 관련하여 Fig. 1에서 볼 수 있듯이 유지보수와 보강을 위한 비용이 지속적으로 증폭 되어져야만 한다. 생애주기비용은 교량의 공용기간이 경과 할수록 증가한다. 증가되는 비용에도 불구하고, 교량의 구조적 내구성은 안정된 사용성을 지속적으로 유지하기 위하여 확보되어야 한다. 따라서 구조적 손상을 최소화하기 위한 적절한 교량의 유지보수 및 보강이 적합한 시기에 시행되어야만 한다. 그러나 교량을 포함한 구조물의 관리 네트워크에 있어서 교량관리 실무자로서 체계적인 관리기술 없이 한정된 유지보수비용으로 적절한 유지보수 계획을 최적의 시기에 시행하는 것은 매우 어렵다.

따라서 교량 관리기관은 효과적인 자산관리를 수행하기 위해 BMS를 도입하기 시작하였다.

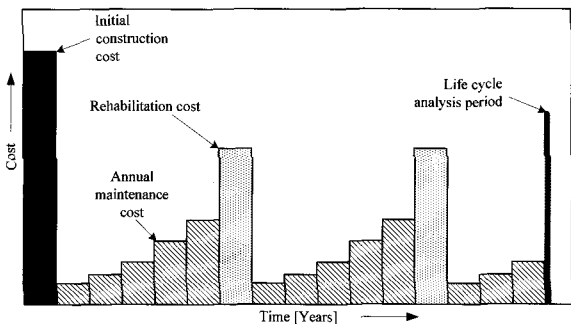


Fig. 1. 공용기간동안 LCC의 흐름[1]

BMS 지침서에 (AASHTO)[2] 따르면 시스템은 크게 네 가지의 요소로 나눌 수 있다. 일반적인 BMS 소프트웨어 구조는 Fig. 2에서와 같이 (a) data storage; (b) cost (c) deterioration; 그리고 (d) optimization 모듈과 같다.

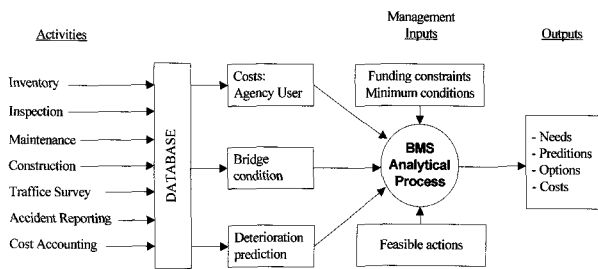


Fig. 2. BMS 의 전형적인 구조[3]

다양한 BMS의 기능은[4] 다음과 같이 요약 될 수 있다.

- 교량목록의 제공
- 교량요소의 미래상태 예측과 과거상태 기록
- 교량의 과거와 미래의 내하력 평가기록과 예측
- 손상 비율의 평가
- 효과적인 유지보수방법의 선택
- 유지보수 계획 및 예산산정

BMS의 결과물은 프로젝트 레벨과 네트워크 레벨 두 가지로 분류 될 수 있다. 프로젝트 레벨의 결과는 각 개별 교량과 관련이 있고, 네트워크 레벨의 결과는 전체 교량과 관련이 있다. 신뢰도 높은 결과물을 위해서는 충분한 기간의 교량 진단기록이 있어야 한다. 이는, 프로젝트 레벨의 교량 진단결과를 기반으로 앞에서 언급한 두 모듈이 BMS 운용의 결정적인 역할을 하기 때문이다. Fig. 3은 교량진단자료의 사용을 설명하고 또한 프로젝트 레벨과 네트워크 레벨 분석에 있어서 BMS 모듈과의 연관성을 설명한다.

이상적인 BMS는 신뢰도 높은 단기/장기 교량손상상태와 이를 대비할 수 있는 유지보수비용을 예측할 수 있어야 한다. 전형적인 BMS 소프트웨어는 주로 (a) 교량손상상태의 예측, (b) 교량손상을 보수보강하기 위한 개선안의 목록 제공, (c) 각각의 개선안을 시행하는데 수반되는 비용과 이익을 추정하는 기능이 있다. 지금까지의 BMS 손상모델에 관련된 연구는 보다 나은 MR&R 과 LCC 결과를 산출하기 위해서이나, 장기유지보수 전략의 수립에 있어 BMS로부터 나온 교량손상상태의 예측은 여전히 실무에 적용하기 적절하지 않다[5]. 현재 손상 모델링 기술에 있어서의 문제점은 과거의 교량요소의 상태변화와 관련된 자료의 부족으로 인하여 시행시점의 한정된 교량진단기록에 의존한 수학적 예측 모델링 기술을 이용하기 때문에 신뢰성 있는 결과를 기대하기 어렵다[6].

교량관리기관의 측면에서 BMS 소프트웨어 운용함에 있어 다음과 같은 문제점이 있다: (a) 초기에 BMS를 도입한 교량관리기관일지라도 소수의 점검기록만을 보유하고 있다. (b) 교량손상상태는 짧은 시간내에 크게 변동되지는 않는다. (c) 약 60%의 BMS 분석과정은 정기교량점검 결과에 크게 의존한다. 하지만 많은 연구 성과에도 불구하고 활용 가능한 교량점검기록의 절대량 부족과 같은 근본적인 문제들은 여전히 해결되어야할 문제로 남아있으며 성공적인 BMS운영, 즉 신뢰도 높은 교량손상상태의 예측은 풍부한 양질의 데이터를 바탕으로 하기 때문이다[7].

이러한 문제점을 극복하기 위해 현재는 기록되지 못한 과거 교량상태등급 데이터를 생성하는 인공지능망 기반의 BPM이 본 논문에서 방법론으로 제시된다.

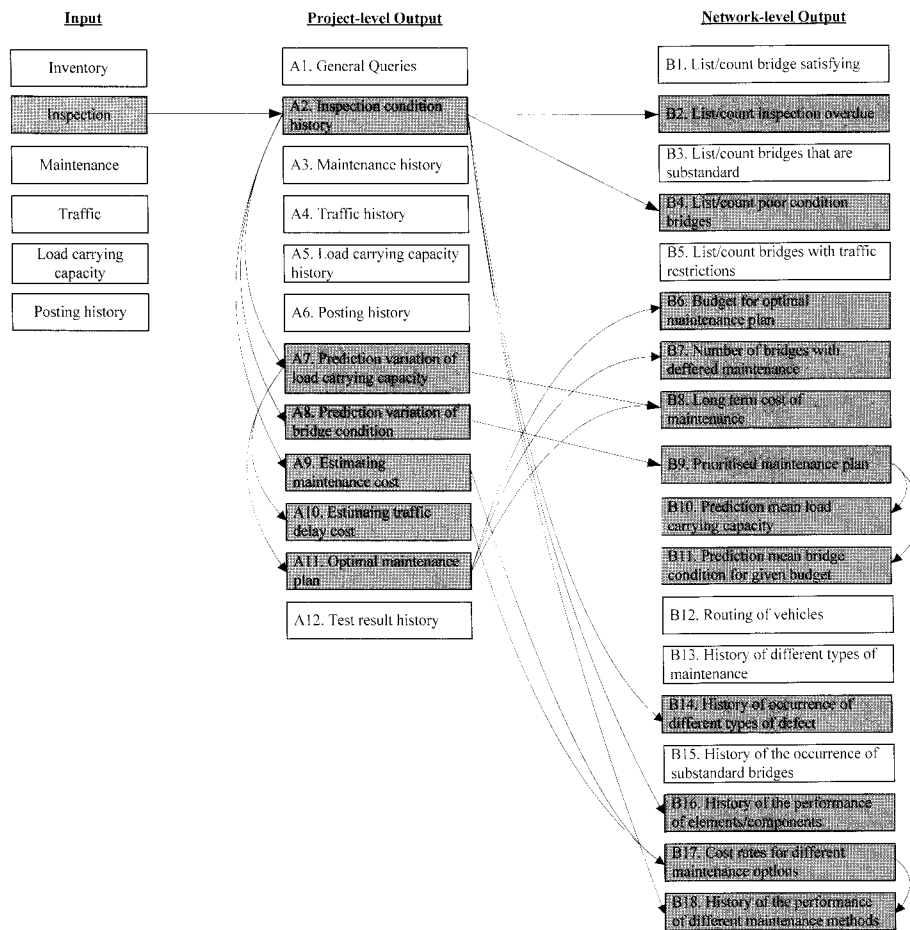


Fig. 3. 교량정기점검 자료와 BMS 결과물과의 관계[4]

## 2. BMS의 손상예측방법

지금까지 다양한 예측기술이 BMS 분석모듈에 적용되어져 왔다. 그 중 가장 빈번하게 사용되는 기술은 통계적 회귀 분석방법, Markov 이론을 기반으로 한 손상모델, Bayesian model, Fuzzy techniques, Genetic Algorithms(GA), Case Based Reasoning(CBR), 그리고 ANN 등이 있다. 그 중 특별히 Markov Decision Processes(MDP)는 대다수의 현존하는 BMS 소프트웨어에서 손상 모델로서 사용되고 있다.

이와 같은 예측기술 중 ANN은 신뢰도 있는 교량손상상태의 단기 예측결과를 산출해 낼 수 있다. 이에 비해 장기간의 예측은 과거의 교량진단 기록의 부족으로 신뢰성이 떨어진다[8,9]. 또한 과거의 유용한 BMS 데이터 부족문제는 현재 가용할 수 있는 기술, 즉 data-mining으로 접근할 수 있지만 상실된 데이터를 얻어내기 위해서는 현존하는 전체 데이터로부터 상실된 데이터의 크기가 5% 혹은 그 이하여야 하고[10] 일정치 않은 기간별로 채집된 표본 데이터 세트의 경우에는 분석결과가 신뢰성을 확보할 수 없다[11].

따라서 본 논문에서는 보다 개선된 교량손상상태 예측모

델을 구축하기 위한 ANN방법을 이용한 BPM으로 과거의 교량상태등급 데이터를 생성하는 방법을 개발하였다.

## 3. Backward Prediction Model (BPM)

Fig. 4에서와 같이 BPM에서 사용된 비구조적 요소는 교량의 주변 환경에 영향을 주는 지역기후와 교통량 그리고 인구증가율 등의 요소를 포함한다. BPM에서 비구조적 요소를 사용하는 이유는 교량의 상태등급에 영향을 주는 지역기후와 교통량변화 등과 같은 간접요소를 이용하여 현재 운영될 수 있는 교량 상태등급과의 연관성을 규정하여, 필요한 과거의 교량상태등급 데이터를 생성하여 교량손상상태 예측모델에 적용하기 위함이다. BPM의 원리는 첫째로 기록된 교량진단기록과(m년도부터 m+n년도까지) 그에 상응하는 기간의 비구조적 요소(m년도부터 m+n년도까지) 사이에 ANN을 통하여 연관성을 부여하고, 생성된 연관성을 교량진단기록이 없는 기간의 비구조적 요소(0년도부터 m년도까지)에 적용되어 필요한 교량상태등급 데이터(0년도부터 m년도까지)를 생성한다[12].

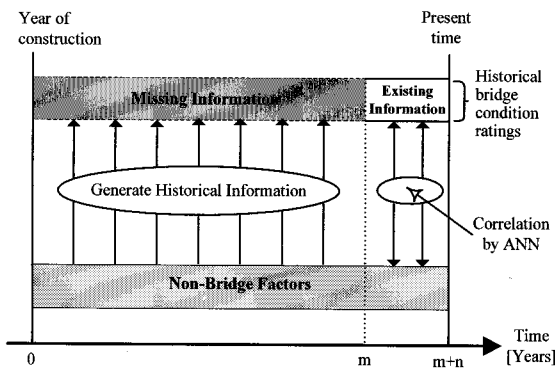


Fig. 4. BPM의 원리

Fig. 5에서 볼 수 있듯이, 인공신경망 기반의 BPM은 Input, Hidden, 그리고 Output Layer로 구성되어 있다. BPM에서 인공신경망의 주요기능은 Input(비구조적 요소)과 Output(교량상태등급)의 관계를 형성하는 것이다.

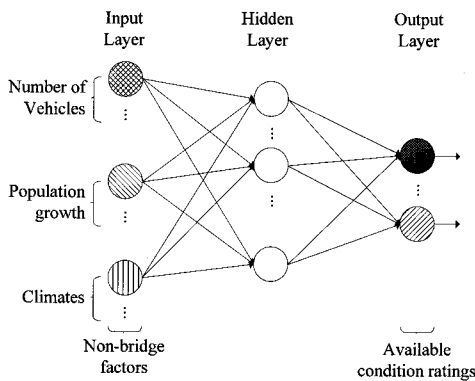


Fig. 5. ANN기반의 BPM 구조

제안한 BPM의 신뢰성을 확보하기 위해서 Maryland주 교량관리국으로부터 National Bridge Inventory(NBI)와 BMS에 사용되는 교량진단기록을 적용하여 손상예측모형을 생성하였다. 일반적으로 교량관리국의 BMS용 교량진단기록 보유량은 앞에서 언급한 바와 같이 10~16년도(5~8개)정도이고, 이에 반해 NBI는 같은 성격의 진단평가이면서도 약 30년 이상 누적된 기록을 확보하고 있다. NBI는 Element-level(상부바닥판, 교대, 교좌장치 등)의 분류방식으로 기록되어 BMS에 적용하기 위하여 Component-level(상부구조, 하부구조, 배수거 등)의 분류방식으로 변환이 요구된다. 따라서, 수집된 NBI 데이터를 BPM으로 적용하기 위한 5회분의 BMS 교량진단기록으로 변환하였다.

### 3.1 NBI data set에 의한 BPM

NBI 자료는 전형적인 ANN 입력환경을 이용하는 BPM 방법론에 사용되어지기 위해서 보정작업이 필요하다. Fig.

6은 NBI의 교량상태등급과 대응되는 BPM 입력상태등급을 도식적으로 표현하였다. NBI에서 교량상태에 관련된 정보는 상판부(NBI#58), 상부구조부(NBI#59), 하부구조부(NBI#60)이고, 상태지수(Condition Index; CI)는 10단계 등급으로 최하등급 0부터 최상등급 9까지 구분된 NBI 등급을 0부터 1.0으로 할당되는 인공신경망 등급으로 변환하였다. 비구조적 요소와 관련해서 과거의 교통량, 인구조사, 기후자료는 각각 Federal Highway Administration, U.S. Census Bureau, and the U.S. Department of Commerce, National Oceanic & Atmospheric Administration에서 인용하였다.

Excellent Condition	9	1.0
Very Good Condition	8	0.9
Good Condition	7	0.8
Satisfactory Condition	6	0.7
Fair Condition	5	0.6
Poor Condition	4	0.5
Serious Condition	3	0.4
Critical Condition	2	0.3
Failure Condition	1	0.2
Failed Condition	0	0.1

NBI Scale for the #58, 59 & 60 ANN model

Fig. 6. BPM을 위한 NBI의 스케일

Fig. 7에서와 보여주는 바와 같이 BPM을 위하여 이용된 교량의 점검기록은 1966년(건설년도)부터 2004년(마지막 데이터 수집년도)까지를 확보하였다. 이 기간 중 최근 5개를(Fig. 7(c)) ANN에 입력하고 출력된 14개를(Fig. 7(d)) 바탕으로 손상예측모형을 완성하였다. 이 손상예측모형으로 최근 5개의(Fig. 7(g)) 교량의 손상등급을 추정하여 기존의 NBI 기록과의(Fig. 7(e)와 (h)) 비교를 통하여 오차분석을 실시하였다.




Fig. 7. 각 단계별 표본 교량 데이터의 적용기간

### 3.2 손상예측모형과 NBI기록의 비교분석

5개의 최근NBI 교량진단기록이 BPM 입력자료로 사용하였으며 (1996년부터 2년 단위로 2004년까지) 또한 최상 등급의 교량상태로 가정하 총 5개의 데이터를 ANN을 적용하여 14개의 과거 교량상태등급기록을 생성하여 손상예측모형을 완성하였다. 즉, 19개의 실제 NBI 데이터가 존재하지만 BPM방법론 입증을 위해 최근 5개 데이터만이 존재한다고 가정하였다.

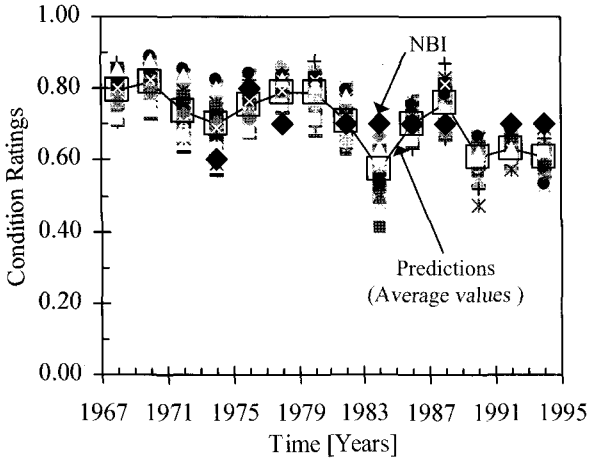


Fig. 8. 교량 상부구조의 추정치와 NBI 기록의 비교

Fig. 8에 표현된 인공신경망으로 생성된 14개의 추정 교량상태등급은 확보된 NBI 교량점검결과와 비교하여 오차값을 산출하고 그 평균값을 구조부분별로 상판, 상부구조, 하부구조부에서 각각 6.68%, 6.61% 그리고 7.52% 로 계산되었다. 이 결과는 10단계 등급구분인 경우 최대허용오차 ( $\pm 10\%$ ) 이내에 포함되어 그 안정성을 증명하였다.

### 3.3 추정손상등급과 NBI기록의 비교분석

Forward 예측 결과와 NBI기록과의 비교를 위한 입력자료는 Backward Prediction으로 생성된 결과 데이터(1968-1994)를 이용하여 Forward로 예측하여 최근 5개의 상태등

급을 생성하여 기존의 NBI 데이터(1996-2004)와 구조부위별로 비교분석하였다.

Table 1에서 상판, 상부구조, 하부구조부에서 비교된 결과들의 평균오차 모두 최대허용오차  $\pm 10\%$  범위에 포함되며, Backward Prediction으로 생성된 결과보다도 우수한 신뢰도를 입증하였다.

Table 1. 대상교량의 추정손상등급과 NBI기록 비교오차

교량 요소	평균오차(%)
상판	3.20
상부 구조	3.10
하부 구조	3.20

### 3.4 BMS data set에 의한 BPM

BMS 교량진단기록을 이용한 손상예측모형의 생성을 위하여 교량(#3210xxx1) 상부구조부 요소(#234: reinforced concrete pier cap)의 BMS 기록을 이용하였다. 1996년부터 2004년까지의 5단계 상태등급(Condition State; CS) 중 CS1, CS2 그리고 CS3에 대하여 각각 80%, 16.2%, 그리고 3.8% 로 분포되었다. 따라서 BPM은 Fig. 9에서 볼 수 있듯이 각 3단계 등급별로 1968년부터 1994년까지 대상교량의 추정 과거 상태등급 데이터를 생성하였다. 매년 예측된 BPM의 결과는 각각 66개이며 이 수는 ANN 구성에 있어서 학습 적용 수와 momentum coefficients 수의 조합으로 얻어졌다.

1968년부터 1994년까지 기록된 BMS 교량진단기록은 존재하지 않기 때문에 BPM을 통하여 생성된 교량상태등급 데이터(1968-1994)와 직접 비교할 수 없다. 따라서 Fig. 10에서 볼 수 있듯이 Backward prediction의 결과(1968-1994)가 BMS교량진단기록이 존재하는 기간(1996-2004)의 추정교량상태등급 데이터를 생성하여 기록된 진단자료와 비교하기 위해 BPM 입력 자료로 사용되어졌다.

BPM으로 생성된 교량상태등급 데이터는 기록된 BMS 데이터세트와 비교분석하였으며 해당연도별 평균예측오차

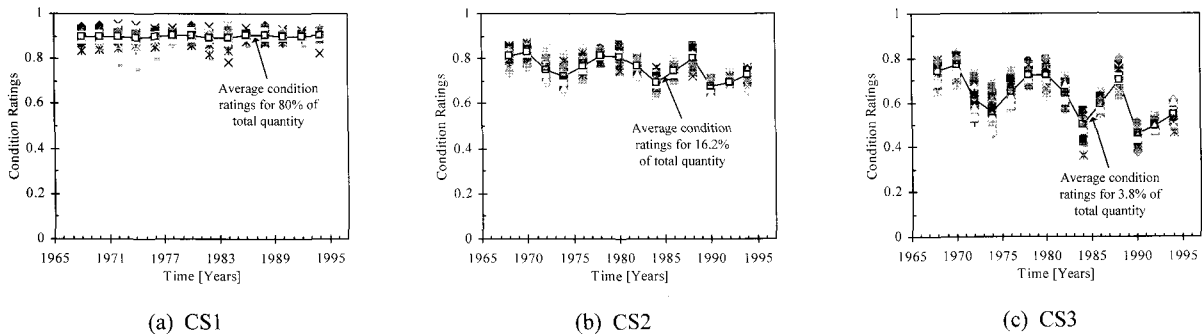


Fig. 9. 각 CI별 교량(#3210xxx1) 상부구조의 추정과거상태등급

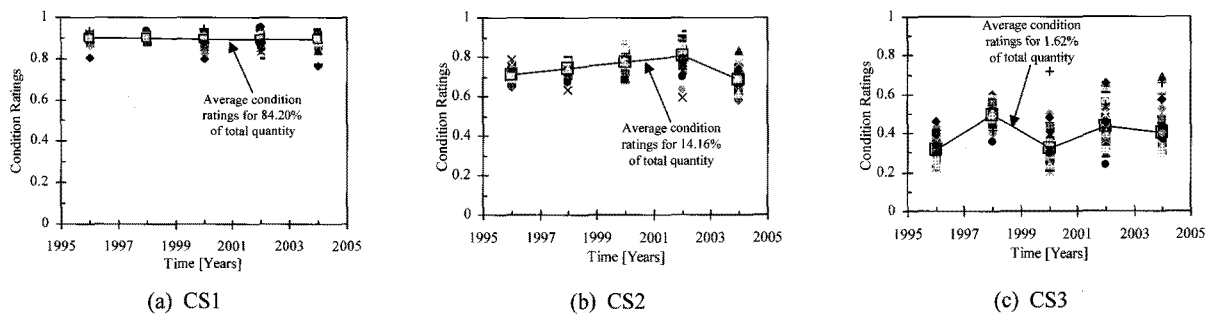


Fig. 10. 각 CI별 교량(#3210xxx1) 상부구조의 추정상태등급비교

는 최소 1.12%에서 최대 4.87%로 5단계 등급구분의 최대 허용오차( $\pm 20\%$ ) 이내로 계산되어 BMS의 예측 신뢰도를 재 입증 할 수 있다.

### 3.5 사례연구 요약

인공신경망을 이용한 BPM의 신뢰성을 확보하기 위해 Road and Traffic Authority of New South Wales(RTA NSW), Australia로 부터 획득한 BMS 교량진단기록을 이용한 사례연구를 시행하였다[12]. 이 연구에서는 총 9개소의 교량요소와 3가지 다른 진단등급(3CSs, 4CSs, 5CSs)이 적용되었다. BPM을 이용한 손상모형의 추정손상등급과 진단기록을 비교하여 등급별 오차를 계산하여 Tabel 2에 요약하였다. 적용된 각 진단등급별 최대 허용오차는 3CSs, 4CSs, 5CSs에 대해 33%, 25%, 그리고 20%이다. 각 진단등급별 최대평균오차는 각각 10.21%, 9.26%, 4.40%으로 최대허용오차 이내로 계산되었다.

Tabel 2. 진단등급별 BMS 결과비교 최대평균오차

교량요소 (Bridge elements)	진단등급	최대허용 오차(%)	최대평균 오차(%)
Assembly Joint Seal	3CSs	33	10.21
Brick/Masonry/Reinforced Earth			
Elastomeric Bearing Pad			
Concrete-Deck Slab	4CSs	25	9.26
Concrete-Pile			
Concrete-Pier			
Concrete-Pre-tensioned Girder			
Metal Railing	5CSs	20	4.40
Steel(L)-Beam/Girder			

## 4. 결론

ANN을 이용한 BPM으로 교량의 손상예측모형을 활성

화하는 교량상태 평가법을 제시하였다. BPM의 목적은 기록된 BMS를 위한 교량 관련기록이 충분치 못한 경우 이로 인한 부정확한 손상상태예측모형의 한계점을 극복하고자 함이다. BPM은 충분치 못한 BMS기록과 대상 교량의 상태등급에 영향을 주는 지역적 기후, 인구밀도와 교통량 등 교량의 구조성능을 형성하는 요소와 관계없지만 유지관리와 LCC를 결정하는 중요요소로서의 비구조적 요소를 적용하여 부족한 과거의 교량상태등급 데이터를 생성하고 BPM으로 활성화된 풍부한 과거 상태등급 데이터가 교량의 손상상태를 예측한 모형 결과값의 신뢰성을 높인다.

대상교량의 사용가능한 19회의 NBI 데이터 중 최근 5회만 기록된 것으로 가정한 후 BPM로 14회분 과거 데이터를 생성하고 기록된 14회분의 데이터와 비교분석하였다. 이 비교에서 상판, 상부구조부, 하부구조부의 평균예측오차는 각각 6.68%, 6.61% 그리고 7.52%로 허용범위를 만족하였다. 14개의 활성화된 과거교량상태등급을 다시 인공신경망을 이용하여 최근의 5회분 예측등급을 추정하고 기존의 진단자료와 비교하여 평균예측오차는 각 구조부별로 각각 3.20%, 3.10% 그리고 3.20%로 허용오차를 만족하였다. 또한 BMS 진단기록을 이용한 BPM에서 동일한 방법을 이용한 예측 교량상태등급과 실제 진단자료와 비교하여 연간 평균오차가 허용범위 안에 있음을 증명하였다. 더불어 RTA NSW로 부터의 9개의 전형적인 교량요소를 이용한 BPM 사례연구도 수행되어졌다. 세 가지 다른 상태평가등급(3CSs, 4CSs, 5CSs)의 평균오차는 각각 10.21%, 9.26% 그리고 4.40%이며 각각의 최대 허용가능오차범위를 만족했다.

도로교의 검증된 BMS 진단자료와 비구조적 요소를 고려한 인공신경망 손상상태모형을 의사결정시스템에 적용한 방법은 모든 구조물의 유지보수 및 보강을 위한 활용이 가능하리라고 판단되며, 특히 초기단계인 고속철 또는 경전철을 위한 교량의 상태평가에도 적용이 가능할 것으로 사료된다.

## 참고문헌

1. R. Hudson, R. Haas, and W. Uddin (1997), "Infrastructure management: I.D., C. M. R & R," McGraw-Hill, NewYork, pp. 18-20.
2. P. Steel, G. Cole, R. Parke, B. Clarke, and E. Harding (2000), "Bridge maintenance strategy and sustainability," Bridge management, E&FNSpon, London: Thomas Telford, pp. 361-369.
3. B. Godart and R. Vassie (1999), "Review of existing BMS and definition of inputs for the proposed BMS," BRIME Report Project PL97-2220, pp. 18-22.
4. C. Das (1996), "Bridge maintenance management objectives and methodologies," Bridge Management, Thomas Telford, pp. 1-7.
5. G. Morcous, H. Rivard, and M. Hanna (2002), "Modeling bridge deterioration using case based reasoning," J. of Infrastructure System, Vol. 8, No. 3, pp. 86-95.
6. J. Kleywegt and C. Sinha (1993), "Tools for bridge management data analysis," 7th Conference on Bridge Management, pp. 16-26.
7. J. H. Lee, K. Sanmugarasa, and M. Blumenstein (2005), "An artificial neural network model for the condition rating of bridges," ICCEM2005, Seoul, Korea. CD-ROM Proceedings.
8. J. H. Lee, K. Sanmugarasa, K. Le, and M. Blumenstein (2005), "Use of non-bridge element-level inspection data in the implementation of BMS," ISEC-03, Japan, pp. 705-712.
9. G. Tabachinick and S. Fidell (2001), "Using multivariate statistics," Allyn and Bacon.
10. T. Karna, F. Rossi, and A. Lendasse (2006), "LS-SVM functional network for time series prediction," ESANN 2006, Bruges, Belgium, pp. 473-478.
11. J. H. Lee, K. Sanmugarasa, M. Blumenstein, and Y. C. Loo (2008), "Improving the Reliability of a BMS using an ANN-based BPM," J. of Automation in Construction, Vol. 17, No. 6, pp. 758-772.
12. 홍철기, 양신추, 김연태 (2002), "토노반상 콘크리트궤도의 노반 허용침하기준설정에 관한 연구", 한국철도학회 논문집, 제 10권, 제 3호, pp. 355-364.

접수일(2009년 7월 29일), 수정일(2009년 12월 11일),  
게재확정일(2010년 2월 8일)