

건설공사 공정별 작업기간 산정을 위한 신경망 기반 모형 구축

조빛나¹, 김현승¹, 강인석^{*}

¹경상대학교 토목공학과, 공학연구원

Development of Estimation Model of Construction Activity Duration Using Neural Network Theory

Bit-Na Cho¹, Hyeon-Seung Kim¹, Leen-Seok Kang^{1*}

¹Department of Civil Engineering, Gyeongsang National University

요약 공정계획 수립 시 각 공정별 작업기간 산정은 프로젝트 전체 공사기간 및 사업비용 결정과 직결되기 때문에 합리적인 산정계획이 요구된다. 그러나 일반적으로 작업기간 산정은 공사 담당자의 경험과 직관을 통해 이루어지고 있고, 다양한 영향 요인에 의한 불확실성으로 인해 예측에 어려움이 있다. 이에 본 연구에서는 작업기간 산정에 영향을 미치는 다양한 요인을 고려할 수 있도록 신경망 기반 건설공사 공정별 작업기간 산정 모형을 제시하고자 한다. 본 연구에서는 정량적 및 정성적 요인을 모두 고려하여 작업기간 산정 모형을 구축하고, 사례적용을 통해 모형의 적용가능성을 검토하였다. 또한 영향요인 상관성분석을 실시하여 구축된 신경망 구조의 적합성을 판단하였다. 연구에서는 작업기간 산정 모형을 통해 합리적인 일정 계획을 제공함으로써 계획공사기간과 실제공사기간의 오차율을 줄이는데 도움을 줄 수 있을 것으로 기대된다.

Abstract A reasonable process for the activity duration estimation is required for the successful construction management because it directly affects the entire construction duration and budget. However, the activity duration is being generally estimated by the experience of the construction manager. This study suggests an estimation model of construction activity duration using neural network theory. This model estimates the activity duration by considering both the quantitative and qualitative elements, and the model is verified by a case study. Because the suggested model estimates the activity duration by a reasonable schedule plan, it is expected to reduce the error between planning duration and actual duration in a construction project.

Key Words : Activity Duration, Back-Propagation Algorithm, Neural Network

1. 서론

1.1 연구의 배경 및 목적

건설공사에서 공정관리는 공사기간 준수를 위한 중요한 업무이며, 건설공사가 대형화·복잡화됨에 따라 공정의 합리적인 계획과 관리는 건설 프로젝트의 성공에 밀접한 영향을 미친다[1]. 따라서 공정계획에서 중요한 항목인 세부 작업기간 산정은 프로젝트의 전체 공사기간 및 사업비용의 결정과 직결되기 때문에 합리적인 산정계획이 요구된다. 그러나 일반적으로 작업기간 산정은 공

사 담당자의 경험이나 과거 공사기록을 참고하여 이루어지고 있는 실정이다. 또한, 작업기간은 건설 프로젝트에 내포된 다양한 영향요인에 의한 불확실성으로 인해 예측에 많은 어려움이 있다.

이러한 문제점을 해결하기 위해 공기산정에 회귀기법과 같은 연구가 진행되고 있지만[2], 회귀기법은 원인이 되는 요인들을 정량적으로 분석해야하고, 많은 수의 자료가 필수적이다. 그러나 작업기간 산정에 영향을 미치는 요인은 비선형적이며 요인들 상호간의 관계를 수학적으로 접근하여 설명하는 것은 복잡하고 쉽지 않다. 이와

*Corresponding Author : Leen-Seok Kang(Gyeongsang National Univ.)

Tel: +82-55-753-1713 email: lskang@gnu.ac.kr

Received November 26, 2014

Revised (1st January 17, 2015, 2nd January 23, 2015)

Accepted May 7, 2015

Published May 31, 2015

같은 경우 인간두뇌가 학습에 의해 추론, 연상하여 종합적인 판단을 하는 것을 모방한 신경망 이론(Artificial Neural Network, ANN)이 요인들 간의 비선형적인 상호관련성을 반영하기에 적합하다[3].

따라서 본 연구에서는 건설현장에서 발생할 수 있는 다양한 요인을 복합적으로 고려하기 위해 신경망이론을 적용하고 작업기간을 산정할 수 있는 모형을 구축하고자 한다. 이를 통해 일정 계획 단계에서의 합리적인 작업기간 산정으로, 계획공사기간과 실제공사기간의 오차율을 줄이고자 한다.

1.2 연구동향

건설분야 작업기간과 관련된 연구사례는 다음과 같다. 우중평[4]은 자원의 생산성분석을 통해 공정별 표준 작업기간 산정 방안을 제시하였다. 신재원[5]은 회귀분석과 몬테카를로 시뮬레이션을 통하여 기후요인에 따른 공사기간 예측모형을 제시하였다. 이현수[6]는 기후요인과 생산성을 분석하여 고층 건축물 프로젝트의 공사기간 산정 모형을 제시하였다.

건설분야 신경망이론 적용과 관련된 국내의 연구사례는 다음과 같다. 한형동[7]은 신경망이론을 적용하여 공사기획단계에서 활용 가능한 도로공사비 개략전적 모형을 제시하였다. Pewdum Wichan[8]은 고속도로 건설의 최종 공사기간 및 예산을 예측하기 위하여 신경망이론을 적용하였다. Ok Seung C[9]는 신경망이론을 적용하여 토목장비의 생산성 예측 모형을 개발하였다.

이와 같이 건설분야 작업기간 산정 관련 연구에서는 작업기간 산정 시 자원의 생산성 및 기후요인을 분석하여 활용하기 위한 연구가 이루어지고 있는 것을 알 수 있다. 하지만 작업기간 산정 시 다양한 요인을 복합적으로 분석하여 적용하는 연구는 아직 부족한 실정이다. 건설분야 신경망이론 적용과 관련된 연구에서는 공사비전적 및 생산성 분석에 관한 연구가 대부분이며, 신경망이론을 공사기간 산정에 적용하고자 하는 시도는 아직 부족한 것을 알 수 있다.

따라서 본 연구에서는 신경망이론을 활용하여 건설공사의 공정별 작업기간 산정을 위한 모형을 제시하고자 한다. 이를 통해 공정별 작업기간에 영향을 미치는 다양한 요인을 분석하고, 이를 복합적으로 고려함으로써 합리적인 공정계획 수립을 도모하고자 한다.

2. 신경망 이론

2.1 신경망 이론 개요

신경망은 인간의 뇌에서 수행되는 정보처리 방식을 모방한 수학적 모델이라고 정의할 수 있다.

신경망에서 기본 구조는 Fig. 1의 위와 같이 신호값(x_i)과 연결가중치(W_i)가 각각 곱해서 합산되고, 합산된 값은 활성화 함수(Activation Function)를 거쳐 결과를 출력한다. 또한, 신경망의 구조는 계층 수에 따라 나눌 수 있으며, Fig. 1의 아래와 같이 단층(Single-Layer) 신경망과 다층(Multi-Layer)신경망으로 구성되어 있다. 단층신경망은 가장 단순한 구조로 입력층(Input Layer)과 출력층(Output Layer)으로 구성되어 있으며, 다층신경망은 입력층과 출력층 사이에 하나 이상의 은닉층(Hidden Layer)으로 구성되어 있다. 은닉층은 직접적으로 결과를 출력하지 않고 전달하는 역할을 하며, 신경망의 구조가 더 커지고 복잡해질수록 더 나은 기능을 수행하여 복잡한 문제를 해결하는데 유용하게 사용된다 [7,10,11].




Fig. 1. Neural Network Basic and Level Structure[10]

2.2 오류 역전파 알고리즘

신경망 이론에서의 핵심은 학습을 통해 최적의 연결가중치를 찾는 것이다. 학습을 위한 알고리즘은 여러 종류가 있으며, 오류 역전파 알고리즘(Back-Propagation Algorithm)은 지도학습(Supervised Learning)의 대표적인 학습알고리즘이다. 오류 역전파 알고리즘은 다층 신경망을 기본구조로 하고 있으며, 이는 입력 특성을 비선형으로 함으로써 다양한 분야의 예측과 분류 문제에서 활용되고 있다[10,11]. 오류 역전파 알고리즘 학습은 입력값에 대응하는 목표값이 주어짐에 따라 원하는 출력값이 도출되도록 연결가중치를 조절한다.

3. 건설공사 공정별 작업기간 산정 모형

3.1 공정별 작업기간 산정 모형구축 방법론

본 연구에서 제시하는 신경망 기반의 건설공사 공정별 작업기간 산정 모형은 Fig. 2와 같다. 우선 작업기간 산정에 영향을 미치는 영향요인을 도출하며, 도출된 영향요인과 작업기간에 대한 사례 데이터를 수집한다. 이후 수집된 데이터에 대한 최적의 신경망 구조를 구축한다. 영향요인이 적합하다고 판단되면 영향요인 상관성 분석을 생략하고 실제 데이터를 입력하여 결과를 도출할 수 있다. 그러나 실제 데이터를 입력하기 전에 영향요인에 대한 적합성을 검토하고자 한다면, 신경망 구조 구축 후 영향요인의 상관성 분석을 실시한다. 영향요인에 대한 다양한 조합을 이용하여 적합성을 검토하며, 해당 공종에 대한 최적의 영향요인 구조를 도출한다. 본 연구에서는 위와 같은 과정을 통하여 작업기간 산정 모형을 제시하고, 이를 통해 작업기간 산정을 보다 합리적이고 효율적으로 수행 가능하도록 하고자 한다.

3.2 영향요인 도출 및 데이터 수집

본 연구에서 제시하는 작업기간 산정 모형을 구축하기 위해서는 먼저, 작업기간에 영향을 미치는 영향요인을 도출한다. 이를 위해 기존 문헌, 연구 자료 분석과 전문가의 설문 및 인터뷰를 실시하고, 영향도가 높다고 판단되는 요인을 도출하였다. 도출된 영향요인은 작업물

량, 자원 수, 작업공간, 기후조건, 지질조건 5가지이며, 이는 정량적 요인뿐만 아니라 환경적요인을 포함하기 때문에 현장상황에 맞게 복합적으로 분석이 가능하다.

신경망 이론을 적용하여 구조를 형성하기 위해서는 입·출력 변수와 그에 따른 데이터가 필요하다. 본 연구에서 입력변수는 5가지의 영향요인으로 설정하였으며, 출력변수는 작업기간으로 설정하였다. 입·출력 변수를 설정한 후, 신경망 구조의 학습을 위해 Table 1과 같이 입·출력변수를 수치화 하였다.

Table 1. Variables of Input and Output

| Variable | Contents | Value | Explanation |
|----------|----------------------|-------------|---|
| Input | Work Quantity | Unit | Total Work Quantity of Activity |
| | Number of Resource | Unit | Number of Worker or Equipment of Activity |
| | Work Space Condition | 1 | Large Work Space Conflict |
| | | 2 | Slight Work Space Conflict |
| | | 3 | No Work Space Conflict |
| | Weather Condition | 1 | Bad Weather (30% of Work Possibility) |
| | | 2 | Normal Weather (70% of Work Possibility) |
| | | 3 | Good Weather (100% of Work Possibility) |
| | Ground Condition | 1 | Soft Ground |
| | | 2 | Normal Ground |
| 3 | | Good Ground | |
| Output | Activity Duration | Day | Total Activity Duration |

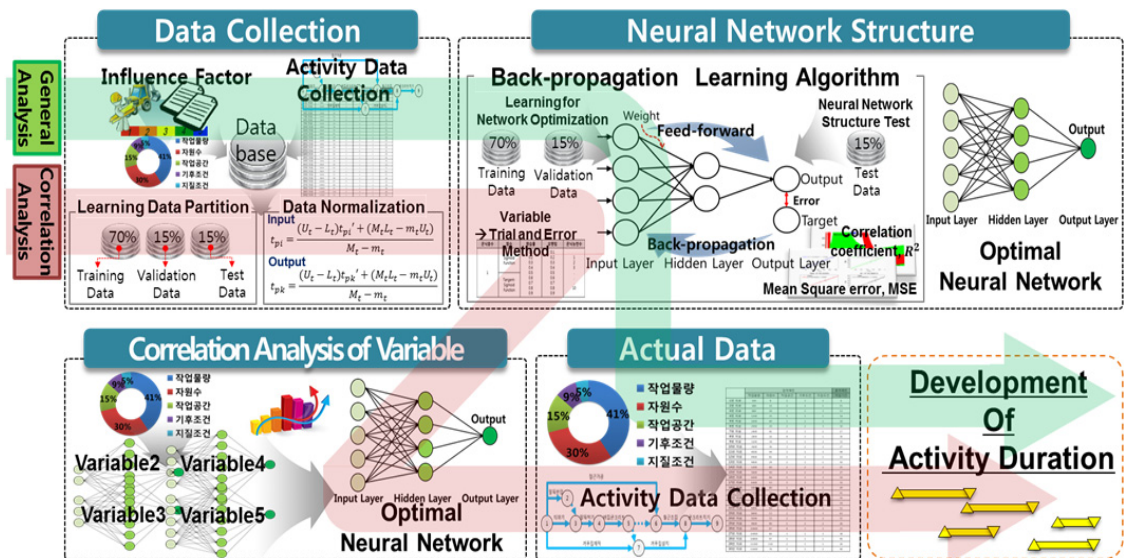


Fig. 2. Estimation Model for Construction Activity Duration Using Neural Network

입력변수에서 정량적 요인인 작업물량과 자원 수 그리고 출력변수인 작업기간은 고유의 수치를 그대로 이용한다. 또한 정성적 요인인 작업공간조건, 기후조건, 지질 조건은 정량적으로 나타내기 위해 현장을 3가지 경우로 한정하여 수치화 한다. 수치화한 Table 1의 조건으로 공정별 세부공종에 대한 사례 데이터를 수집한다. 수집된 사례 데이터는 신경망 구조 구축을 위한 학습데이터로 활용되며, 데이터는 학습과정에서 수치적 안정성을 위해 데이터의 정규화 과정을 거쳐 0에서 1사이 값으로 변환된다. 또한, 변환된 데이터는 훈련과정, 검증과정, 시험 과정에 70%, 15%, 15%씩 할당하도록 설계한다.

3.3 신경망 구조 구축

작업기간 산정에 영향을 미치는 요인을 복합적으로 분석하기 위해 신경망 이론을 적용하며 신경망 구조의 구축이 필요하다. 본 연구에서는 신경망의 구조를 구축하기 위해 수집된 데이터를 활용하고, 데이터를 학습하기 위해 오류 역전파 학습 알고리즘을 적용한다. 수집 데이터 중 훈련, 검증과정 데이터는 신경망구조의 구축을 위해 사용하고, 시험과정데이터는 구축된 구조의 최종 성능 평가에 사용한다.

3.3.1 수집 데이터 학습

오류 역전파 알고리즘 학습은 전향 단계와 후향 단계로 나눌 수 있으며, 학습에서 중요한 연결가중치 갱신은 후향 단계에서 이루어지며, 적정 수준의 오차값이 도출되기 위해 학습을 반복적으로 수행한다. Fig. 3은 데이터 학습 단계를 나타낸 것이다.




Fig. 3. Data Learning Phase

훈련데이터(70%)의 정규화된 입·출력 데이터를 입력하고, 입력층부터 출력층까지 각 노드의 입력데이터와 초기 연결가중치를 곱하여 활성화함수 통해 출력값을 산출한다. 이때 초기 연결가중치는 랜덤으로 설정하는데,

이로 인해 출력값과 출력변수의 데이터 값이 일치하지 않고 오차가 발생하게 된다. 식(1)은 출력데이터(t_{pk})와 출력값(O_{pk})과의 오차(E_p)계산식을 나타낸 것이다.

$$E_p = \frac{1}{2} \sum_k (t_{pk} - O_{pk})^2 \quad (1) [10]$$

발생한 오차값을 줄이기 위해 출력층에서 입력층까지의 연결강도를 갱신한다. 70%의 훈련데이터가 학습완료될 때의 오차값이 설정한 오차 값보다 크다면 오차를 0으로 두고 다시 학습단계를 거치며, 오차값이 설정오차보다 작다면 학습을 종료한다.

3.3.2 구조 최적화

신경망 구조의 최적화는 70%의 훈련데이터와 15%의 검증데이터의 학습을 실시 할 때, 은닉층의 개수, 은닉층의 뉴런 개수, 학습률, 모멘텀, 학습방법, 활성화함수 등의 변수를 적절히 설정해 주어 최적의 구조를 찾는 것을 의미한다.

본 연구에서는 신경망의 구조에 필요한 변수 값을 찾아가는데 있어서 별도의 알고리즘을 사용하지 않고, 시행착오적인 방법(Trial and Error Method)을 거쳐 결과를 도출한다. 시행착오적 방법을 통해 최적의 조합을 찾기 위한 변수를 다음 Table 2와 같이 설정하였다.

신경망 구조를 위한 학습방법은 오류 역전파 알고리즘을 이용하고, 활성화 함수는 Tan-Sigmoid Function을 적용하며 은닉층 개수는 1개로 설정한다.

Table 2. Parameter Combination Setting

| Parameter | Setting |
|------------------------|----------------------------|
| Learning Method | Back-Propagation Algorithm |
| Activation Function | Tan-Sigmoid Function |
| Number of Hidden Layer | 1 |
| Number of Hidden Nodes | 1 - 20 |
| Learning Rate | 0.1 - 0.9 |
| Momentum | 0.1 - 0.9 |

시행착오방법을 이용하여 조정할 변수는 은닉층의 뉴런개수, 학습률, 모멘텀으로 설정하고 최적화를 위한 범위를 정한다. 은닉층의 뉴런개수는 1개에서 20까지 1개 단위로 설정하였으며, 학습률과 모멘텀은 0.1에서 0.9까지 0.1간격으로 설정하였다. Table 2와 같은 조건으로 훈련데이터와 검증데이터를 이용하여 구조 최적화를 실시한 뒤 학습에 전혀 사용하지 않은 시험데이터를 통해

신경망 구조의 최종 성능 평가를 실시한다. 본 연구에서는 신경망 학습과 결과도출을 위해 MATLAB R2013b를 이용하였다.

3.4 영향요인 상관성 분석

영향요인 상관성 분석에서는 구하고자 하는 실제 데이터를 입력하기 전, 영향요인과 결과 값의 상관관계를 분석하여 구축된 신경망 구조의 적합성을 판단한다. 적합성 판단은 영향요인의 여러 조합에 대한 분석을 통해서 판단하며, 해당공종에 가장 알맞다고 판단되는 조합을 선택한다. 이를 통해 신경망의 입력변수 구조가 달라질 수 있으며, 분석 후의 신경망 구조에 구하고자 하는 실제 데이터의 입력변수를 입력하면 최적의 작업기간이 도출된다.

4. 사례적용

4.1 작업기간 산정 모형 사례적용

본 연구에서 제시한 작업기간 산정모형 구축 방법론의 타당성과 현장 적용가능성을 판단하기 위하여 사례적용을 통한 분석을 실시한다.

사례적용을 실시할 대상은 건설공사의 대표 세부공종인 합판거푸집과 터파기 공종을 대상으로 하고, 이에 대한 수집데이터를 각각 50개씩 구축하였다. 입·출력 변수는 Table 1과 같이 설정하고, 입력변수에서 자원의 종류로는 각각 형틀목공과 백호를 대상으로 한다. 구축한 데이터에서 가장 중요한 부분인 작업물량과 자원 수의 정보는 품셈을 바탕으로 산정 하였고, 데이터의 추가적인 정보에 대해서는 실무 전문가의 의견수렴 내용들을 구성하여 구축하였다. 학습 데이터 분할은 훈련과정 데이터 35개, 검증과정 데이터 8개, 시험과정 데이터 7개로 할당하였다.

4.2 사례적용 결과 및 영향요인 조합별 상관성 분석

본 연구에서는 Table 2에서 설정한 은닉층 뉴런 개수, 학습률, 모멘텀을 시행착오적 방법으로 학습을 실시하고 최적의 조합을 도출하여 신경망구조를 구축한다. 시행착오방법을 위한 학습에는 훈련과정 데이터와 검증과정 데이터를 활용하고, 학습결과 평균제곱오차(Mean Squared

Error: MSE)가 최소일 때의 변수와 연결가중치를 선택한다.

사례적용 결과, 합판거푸집 공종에 대한 신경망 구조의 경우 은닉층 뉴런 개수 4개, 학습률 0.9, 모멘텀 0.7일 때 MSE가 4.65로 가장 낮았다. 또한, 터파기 공종에 대한 신경망 모형의 경우 은닉층 뉴런 개수 8개, 학습률 0.7, 모멘텀 0.2일 때 MSE가 7.91로 가장 낮은것을 알 수 있었다.

구축된 신경망 구조를 활용하여 영향요인 조합별로 결과에 어떠한 영향을 미치는지를 알아보기 위해 상관성 분석을 실시하였다. 영향요인 조합은 기본적으로 가장 중요한 작업물량과 자원을 포함하여 하나씩 개수를 늘려가며 분석하였고, 결과는 Fig. 4와 같다.

Correlation Analysis of Input Variable




Fig. 4. Correlation Analysis of Input Variable

Fig. 4의 세로값은 결정계수(R^2)의 값을 나타낸 것이며, 결정계수는 정확도를 나타내는 수치로써 1에 가까울수록 모형이 정확한 것으로 판단된다[11].

결과 작업물량과 자원 수는 가장 영향을 많이 미치는 요인이었고, 다음은 작업공간조건으로 나타났다. 기후와 지질조건은 영향정도는 터파기공종에서는 비슷하게 적용하였고, 합판거푸집공종에서 지질조건은 영향도가 낮은 것을 알 수 있었다.




Fig. 5. Optimal Neural Network

(a) Plywood Form Activity (b) Excavation Activity

따라서 합판거푸집공종은 4개의 영향요인을 포함하고, 터파기공종은 5개의 영향요인을 포함하는 것이 해당공종의 최적 구조라고 판단된다. 해당 공종의 최적 신경망 구조는 Fig. 5의 (a), (b)와 같다.

4.3 검증

Fig. 5의 (a), (b)의 구축된 신경망 구조에 7개의 시험 데이터로 구조검증을 실시하였다. 또한, 시험데이터 7개의 작업기간과 구축된 신경망 구조를 통해 예측된 작업기간의 오차율을 산출하여 모형의 적합성을 검토하였다. Table 3과 Table 4는 합판거푸집과 터파기공중의 시험 데이터에 대한 작업기간 예측의 오차율을 나타낸 것이다.

Table 3. Error Rate of Plywood Form Activity

| Data | Output Variable(Day) | Output Value(Day) | Error (Day) | Absolute Error Rate(%) |
|---------|----------------------|-------------------|-------------|------------------------|
| 1 | 14 | 15 | -1 | 7.143 |
| 2 | 49 | 43 | 6 | 12.245 |
| 3 | 35 | 36 | -1 | 2.857 |
| 4 | 29 | 25 | 4 | 13.793 |
| 5 | 19 | 16 | 3 | 15.789 |
| 6 | 36 | 39 | -3 | 8.333 |
| 7 | 87 | 80 | 7 | 8.046 |
| Average | | | 2.143 | 9.743 |

Table 4. Error Rate of Excavation Activity

| Data | Output Variable(Day) | Output Value(Day) | Error (Day) | Absolute Error Rate(%) |
|---------|----------------------|-------------------|-------------|------------------------|
| 1 | 11 | 12 | -1 | 9.091 |
| 2 | 19 | 18 | 1 | 5.263 |
| 3 | 33 | 38 | 3 | 15.152 |
| 4 | 18 | 17 | 1 | 5.556 |
| 5 | 19 | 22 | -3 | 15.789 |
| 6 | 8 | 7 | 1 | 12.5 |
| 7 | 35 | 37 | -2 | 5.714 |
| Average | | | -1.143 | 9.866 |

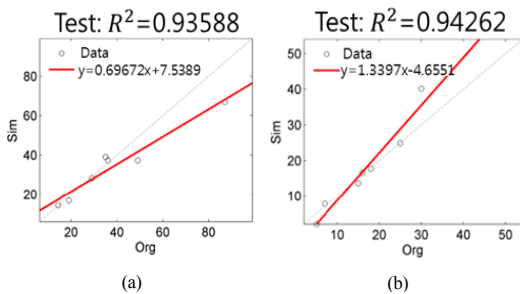


Fig. 6. Determination Coefficient(R^2) of Test Data
(a) Plywood Form Activity (b) Excavation Activity

분석결과, 합판거푸집공중의 경우 절대오차율의 평균은 9.743%로 나타났으며, 터파기공중의 경우 9.866%로 나타났다. 또한, Fig. 6의 (a), (b)는 각 공중의 R^2 값을 나타내며 분석 결과 0.936, 0.943의 값으로 도출되었

고 이는 양호한 결과를 나타내고 있음을 알 수 있다.

본 연구에서 제시하는 신경망 기반 공정별 작업기간 산정 모형에 해당 공사에 대한 영향요인 조건을 모형에 입력하게 되면 적정 공사기간이 도출된다. 이는 일정계획 수립 시 의사결정에 도움을 줄 수 있을 것으로 판단된다.

5. 결론

본 연구에서는 기존 작업기간 산정 방법의 한계를 보완하기 위해 신경망 기반 건설공사 공정별 작업기간 산정을 위한 모형 구축 방법론을 제안하였다. 본 연구의 결론은 다음과 같다.

첫째, 본 연구에서는 작업기간 산정을 위한 영향요인을 기존 연구자료 및 전문가의 의견수렴 내용 등을 통하여 정량적 및 정성적 요인을 모두 고려하여, 작업물량, 자원 수, 작업공간, 기후조건, 지질조건 5가지 요인을 구성하였다. 이를 통해 현장의 다양한 여건을 고려하며 이를 종합적으로 판단하고 분석함으로써 예측과 실제 공사기간 사이의 오차율을 줄일 수 있도록 하였다.

둘째, 본 연구에서는 5가지 영향요인 중 작업물량 및 자원 수는 표준품셈을 바탕으로 산정한 정보를 이용하여 50개의 학습데이터를 구성하였으며, 이를 통해 모형의 신뢰도를 높일 수 있었다. 향후 데이터의 정보 및 개수가 충분하게 확보된다면 보다 높은 정확도를 가진 결과를 제시할 수 있을 것으로 사료된다.

셋째, 영향요인의 상관성 분석결과 요인의 조합에 따라서 결과가 달라지는 것을 알 수 있었다. 따라서 실제 현장 적용 시에는 현장여건에 맞추어 영향요인을 선택적으로 적용함으로써 실무적 활용성을 갖출 수 있을 것으로 판단된다.

넷째, 예측값과 실제값을 통한 모형의 검증 결과, 평균 절대오차율이 9.8%, 결정계수 평균 0.939의 값으로 양호하게 나타났다. 이를 통해 작업기간 산정을 위한 모형의 적합성 및 적용가능성을 확인하였다.

본 연구에서 제시하는 신경망 이론 기반 작업기간 산정 모형은 공사 일정 계획 단계에서 다양한 현장조건을 고려하여 합리적인 공사기간을 계획할 수 있을 것이라 사료된다.


References

- [1] S. J. Kim, J. S. Lee, "An Optimal Scheduling Method Using Probability on the Estimation of Construction Duration", *Korean Journal of Construction Engineering and Management*, Vol.5, No.6, pp.72-79, 2004.
- [2] D. C. Kwon, C. S. Lee, "The Estimation of Construction Duration for High School Buildings Based on the Actual Data", *Korean Journal of Construction Engineering and Management*, Vol.5, No.22, pp.138-145, 2004.
- [3] A. H. Boussabaine, A. P. Kaka, "A Neural Networks Approach for Cost Flow Forecasting", *Construction Management & Economics*, Vol.16, Issue 4, pp.471-479, 1998.
DOI: <http://dx.doi.org/10.1080/014461998372240>
- [4] J. P. Woo, H. S. Cha, K. R. Kim, D. W. Shin, "A Study on Duration Calculation Method for Eco-Friendly Remodeling Demolition Work Using Productivity Analysis", *Korean Journal of Construction Engineering and Management*, Vol.14, No.1, pp.124-132, 2013.
DOI: <http://dx.doi.org/10.6106/KJCEM.2013.14.1.124>
- [5] J. W. Shin, H. G. Ryu, H. S. Lee, M. S. Park, "Probabilistic Model to Forecast the Duration of Structural Work in High-rise Building Construction Considering Weather Elements", *Journal of Architectural Institute of Korea*, Vol.23, No.6, pp.123-132, 2007.
- [6] H. S. Lee, J. W. Shin, M. S. Park, H. G. Ryu, "Probabilistic Duration Estimation Model for High-Rise Structural Work", *Journal of Construction Engineering & Management*, Vol.135, Issue 12, pp.1289-1298, 2009.
DOI: [http://dx.doi.org/10.1061/\(ASCE\)CO.1943-7862.0000105](http://dx.doi.org/10.1061/(ASCE)CO.1943-7862.0000105)
- [7] H. D. Han, J. H. Kim, J. H. Yoon, J. W. Seo, "Road Construction Cost Estimation Model in the Planning Phase Using Artificial Neural Network", *Journal of the Korean Society of Civil Engineers*, Vol.31, No.6, pp.829-837, 2011.
- [8] W. Pewdum, T. Rujirayanyong, V. Sooksatra, "Forecasting Final Budget and Duratio of Highway Construction Projects", *Engineering, Construction and Architectural Management*, 16(6), pp.544-557, 2009.
DOI: <http://dx.doi.org/10.1108/09699980911002566>
- [9] S. C. Ok, S. K. Sinha, "Construction Equipment Productivity Estimation using Artificial Neural Network Model", *Construction Management and Economics*, Vol.24, Issue 10, pp.1029-1044, 2006.
DOI: <http://dx.doi.org/10.1080/01446190600851033>
- [10] Hag-young Han. *Introduction to Pattern Recognition*. p.1-572, HANBIT Media, 2009.

- [11] Hee-Sun Jung. Rainfall Adjust and Forecasting in Seoul Using a Artificial Neural Network Technique Including a Correlation Coefficient. Master Thesis, University of Yonsei, Seoul, Korea, 2007.

조 빛 나(Bit-Na Cho)

[준회원]



- 2013년 2월 : 경상대학교 토목공학과 (공학사)
- 2015년 2월 : 경상대학교 토목공학과 (공학석사)

<관심분야>
건설관리

김 현 승(Hyeon-Seung Kim)

[정회원]



- 2008년 2월 : 경상대학교 토목공학과 (공학사)
- 2009년 2월 : 경상대학교 토목공학과 (공학석사)
- 2011년 9월 ~ 현재 : 경상대학교 토목공학과 박사과정

<관심분야>
건설관리

강 인 석(Leen-Seok Kang)

[정회원]



- 1991년 1월 ~ 1991년 8월 : 대한주택공사연구소 선임연구원
- 2013년 11월 ~ 현재 : 한국건설관리학회 회장
- 1991년 9월 ~ 현재 : 경상대학교 토목공학과 교수

<관심분야>
건설관리