

필로티 건축물의 인공지능 기반 내진성능 평가를 위한 데이터 기반 부재의 단면 형상비 연구

Effectiveness of Data-Driven Section Shape Ratios for Seismic Performance-Based Artificial Intelligence of Piloti-Type Buildings

이가윤¹⁾ · 토바오웁¹⁾ · 조혜림²⁾ · 신지욱³⁾ · 이기학^{4)*}

Lee, Gayoon¹⁾ · Quoc Bao To¹⁾ · Jo, Hye-rim²⁾ · Shin, Jiuk³⁾ · Kihak Lee^{4)*}

¹⁾세종대학교 건축공학과 딥러닝 건축연구소, 박사후연구원, ²⁾세종대학교 건축공학과 딥러닝 건축연구소, 석사과정, ³⁾경상국립대학교 건축공학과 부교수, ⁴⁾세종대학교 건축공학과 딥러닝 건축연구소, 건축공학과 교수

¹⁾Post-Doctoral Student, Deep Learning Architecture Research Center, Department of Architectural Engineering, Sejong University, ²⁾Student, Deep Learning Architecture Research Center, Department of Architectural Engineering, Sejong University, ³⁾Professor, Department of Architecture, Gyeongsang National University, ⁴⁾Professor, Deep Learning Architecture Research Center, Department of Architectural Engineering, Sejong University

/ A B S T R A C T /

Structures compromised by a seismic event may be susceptible to aftershocks or subsequent occurrences within a particular duration. Considering that the shape ratios of sections, such as column shape ratio (CSR) and wall shape ratio (WSR), significantly influence the behavior of reinforced concrete (RC) piloti structures, it is essential to determine the best appropriate methodology for these structures. The seismic evaluation of piloti structures was conducted to measure seismic performance based on section shape ratios and inter-story drift ratio (IDR) standards. The diverse machine-learning models were trained and evaluated using the dataset, and the optimal model was chosen based on the performance of each model. The optimal model was employed to predict seismic performance by adjusting section shape ratios and output parameters, and a recommended approach for section shape ratios was presented. The optimal section shape ratios for the CSR range from 1.0 to 1.5, while the WSR spans from 1.5 to 3.33, regardless of the inter-story drift ratios.

Key words: RC piloti structures, Machine learning, Inter-Story Drift Ratio (IDR), Section shape ratio

1. 서 론

2017년 포항에서 발생한 지진과 이후 발생한 여진들은 포항과 그 주변의 건축물에 큰 피해를 발생시켰다. 특히 주차 공간의 확보에 유리한 필로티형 RC 구조물에 상당한 피해가 발생하였다. 필로티형 RC 구조물의 구조적 특징은 하부는 최소한의 전단벽만을 사용하여 수직재인 기둥으로 주차공간을 확보하고, 상부층은 내력벽으로 구성하여 주거단지로 사용하는 구조 시스템을 의미한다. 이러한 구조 형태는 강성의 수직 비정형성을 초래하여 필로티 건축물은 일반건축물에 비해서 내진성능이 취약하다[1-3]. 특히 2017년 포항지진의 경우 필로티 기둥에서의 조기손상이 발생하여 약층 구조가 되어 변형능력이 크게 저하되었으며, 결과적으로 구조물 상당한 피해를 미치게 되었다[4-7].

국내의 필로티 건축물은 전형적으로 지상층에는 주차장을 포함하는 경우가 일반적이며, 전체적으로 3층에서 6층 높이의 건물로 설계되는 특징을 보인다. 필로티 형식의 철근콘크리트 구조는 1층의 주차 공간을 위한 라멘구조와 2층부터 옥상층까지의 주거 공간을 위한 전단벽 시스템으로 구성된다. 구조적 손상은 주로 약한 1층에 집중되었는데, 이는 상층부의 전단벽 시스템에 비해 기둥 구조는 횡강성이 현저히 감소하기 때문이다[8-11]. 이러한 필로티 형식의 철근콘크리트 건물은 공간이 협소한 도시에서 널리 사용되고 있으며, 구조에 내재되어 있는 수직적 불균형이 심각한 지진 피해를 유발할 수 있음을 보여준다.

국외 및 국내에서 지진 발생 이후 구조물의 활용에 대한 연구가 지속적으로 이루어지고 있으며, 지진으로 인한 구조적 손상을 명확하고 정량적으로 평가할 수 있는 성능기반 설계 기준의 개발이 전세계적인 추세이다. 성능기반 설계는 구조물의 설계, 평가 및 시공을 포함하며, 건물의 구조시스템이 지진 성능을 충족시키는 것을 목표로 한다[12-14]. 이는 주로 구조물의 성능을

*Corresponding author: Lee, Kihak

E-mail: kihaklee@sejong.ac.kr

(Received December 2, 2024; Revised December 4, 2024; Accepted December 4, 2024)

정확히 예측할 수 있는 능력에 기반하며, 엔지니어와 건물주는 다양한 지진 상황에서 구조물의 목표 성능 수준을 선택할 수 있어 구조물의 설계 및 시공에 영향을 미친다. 여기서 성능 수준은 특정 지진 설계 수준에서 구조물이 허용할 수 있는 최대 손상의 정도를 의미하며, 적절한 성능 수준을 선택하기 위해서는 구조물의 내구성, 중요도 및 건설 비용을 고려해야 한다. FEMA 273 (1997)/356 (2000)[15, 16]은 구조적 및 비구조적 성능 수준 모두에 관해 건물의 전체적인 성능을 분류하였다.

본 연구는 국내의 필로티 형식 RC 건물의 내진 성능을 예측하기 위해 단면 형상 비율에 따른 영향을 평가하고 인공지능 모델을 개발하는 것을 목표로 한다. 초기 단계에서는 변위 기반 손상 임계값과 같은 요소를 고려하여 반응 및 손상을 추정함으로써 내진 성능을 평가한다. 이후, 필로티 구조물의 내진 손상 성능을 예측하기 위해 기계 학습 모델을 분석하였다. 최적의 기계 학습 모델은 R제곱 값(R-squared), 평균 절대 오차(MAE), 평균 제곱 오차(MSE), 및 제곱근 평균 제곱 오차(RMSE)와 같은 여러 매개변수를 평가하여 결정된다. 최종적으로, 가장 적합한 모델을 활용하여 더 높은 적합성을 가지는 출력값을 도출함으로써 단면 형상 비율 상황에서 최적의 방법론 체계를 도출하는 것을 목표로 한다.

2. 피해 예측을 위한 내진성능 평가

2.1 문헌 검토

층간변위율(Inter-story Drift Ratio, IDR)은 두 연속된 층 간의 상대 변위와 층 높이의 비율로 정의되며, 지진 하중을 받는 구조물의 구조적 안정성을 평가하는 데 핵심적인 지표로 활용된다. 최근의 연구에서는 층간변위율을 결정하기 위한 측정 방법으로 접촉 방식(contact method)과 비접촉 방식(non-contact method)으로 구분하여 제시하고 있다.

접촉 방식은 층간변위율을 측정하는 가장 간단한 방법으로, 선형 가변 변위 변환기(LVDT)와 같은 변위 센서를 사용하여 각 층의 절대 변위를 직접 측정하는 것이다. 그러나 해당 방식은 견고한 기준 골조를 필요로 하여 현장 적용에서 실용적이지 않다. 이를 대체하기 위해 층간 상대 변위를 직접 측정하는 방법이 제안되었으며, LVDT와 함께 구획을 대각선으로 가로지르는 장력 조절 스프링 와이어가 사용된다. 해당 접근법은 중규모의 실험실 환경에서 외부 기준 변위를 통해 결과를 검증할 수 있는 경우 효과적으로 작동한다[17]. 그러나 와이어가 긴 거리를 걸쳐야 하는 실제 건물에서는 처짐에 취약해지는 문제가 있으며[18], 또한 여러 개의 칸막이벽과 거주자들이 있는 건물에서는 비실용적이다.

비접촉 방식은 현재 GPS 기술을 기반으로 하며, ±1 cm의 평면 정확도 내에서 20 Hz로 데이터를 샘플링할 수 있다. 이러한 기술은 고층 건물의 지붕 변위 모니터링 및 기타 장주기 구조물에 성공적으로 적용된 바 있다[19-21]. 비록 지붕에만 설치 가능하다는 제한된 적용 가능성이 있지만, 해당 시스템은 몇 가지 중요한 장점을 제공한다. 가장 두드러진 장점은 설치가 용이하고 구조물이나 사용자 활동에 거의 방해가 주지 않는다는 점이다. 또한, GPS 센서는 인근에 설치된 가속도계를 통해 측정된 변위를 검증하는 데 사용될 수 있다. 그러나 건물 부지와 비교했을 때 비이상적인 설치 위치 및 지반운동의 변동 가능성은 주요 한계로 작용한다.

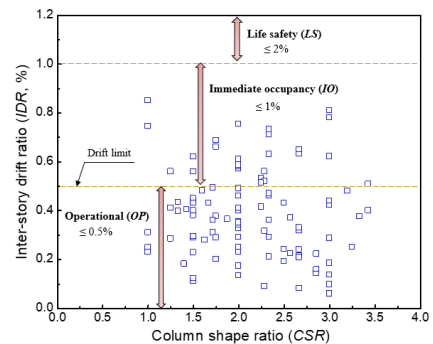
2.2 반응 및 손상 요구 예측을 위한 내진 성능 평가

내진 성능 수준은 일반적으로 층간 변위 비율(IDR)을 통해 평가되며 해당 값과 이에 상응하는 성능 수준 간의 관계를 설정하는 것은 복잡하고 어렵다. FEMA 356[16]에서는 다양한 구조 시스템에 대해 각 성능 수준별로 층간 변위 비율(IDR)의 표준값을 제시하고 있으며, 이를 Table 1에 나타내었다.

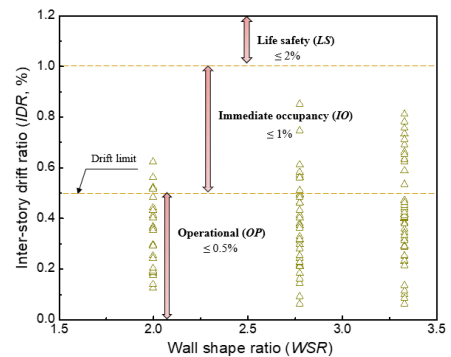
본 연구에서 사용된 데이터셋은 서울의 12개의 구에서 수집한 111개의 필로티 구조물들의 사례로 구성하였다. Fig. 1은 층간 변위 비율과 단면 형상 비율, 특히 기둥 형상 비율(CSR)과 벽체 형상 비율(WSR)의 상관관계를 나타낸다. 필로티 구조물은 운영 성능 수준(Operational)과 즉시 거주 성능 수준(Immediate Occupancy)에서 우수한 성능을 보였으며, 기둥 형상 비율(CSR)이 1.0에서 3.43으로 변화함에 따라 각각 80%와 20%의 분포를 나타냈다. 벽체 형상 비율(WSR)에 따라 성능 수준의 뚜렷한 다양성이 확인되었다. 필로티 구조물은 벽체 형상 비율(WSR) 값이 2.0, 2.78, 3.33일 때 각각 90%, 80%, 60%의 운영 성능 수준 분포를 나타냈다. 또한, 즉시 점유 성능 수준 분포는 벽체 형상 비율(WSR)이 2.0, 2.78, 3.33일 때 각각 10%,

Table 1. Code-defined drift limits for different performance levels

Level (i)	Seismic performance level (PLSi)	Drift limit (IDR)
1	Operational (OP)	≤ 0.5 %
2	PLS1- Immediate occupancy (IO)	≤ 1.0 %
3	PLS2- Life safety (LS)	≤ 2.0 %
4	PLS3- Collapse prevention (CP)	≤ 4.0 %



(a) CSR-IDR Relationship



(b) WSR-IDR Relationship

Fig 1. Seismic performance damage demand and relationship between section shape ratios and IDR

Table 2. Statistics of data set of pilotti-type buildings in South Korea

Case S#	Number of columns (CN)	Column size (mm)	Column shape ratio (CSR)	Beam depth (mm)	Wall Thickness (mm)	Wall shape ratio (WSR)	Concrete compressive strength (fc')	Transverse spacing (TS)	Inter-story drift ratio (IDR)
1	7	300x800	2.67	500	180	2.78	17.31	300	0.21
2	7	300x800	2.67	500	180	2.78	17.87	300	0.21
3	8	300x800	2.67	500	180	2.78	18.22	200	0.21
...									
109	10	400x1200	3.00	400	200	2.00	14.86	300	0.44
110	11	400x1000	2.50	400	200	2.00	24.67	300	0.43
111	10	500x800	1.60	400	200	2.00	21.77	300	0.48

Table 3. Summary of input parameters, ranges and training points

Parameter type	Parameters	Model ranges
Input	Column number (CN)	2.0 to 18
	Column shape ratio (CSR)	1.0 to 3.43
	Wall shape ratio (WSR)	2.0 to 3.33
	Concrete compressive strength (fc')	14.86 to 27.6 MPa
	Transverse spacing (TS)	125 to 400 mm
Output	Inter-story drift ratio (IDR)	

20%, 40%로 나타났으며, 벽체 형상 비율(WSR)이 감소함에 따라 필로티 구조물의 효율성이 증가하고 안전성이 향상되는 것으로 나타났다.

3. 내진성능 및 손상 요구예측을 위한 인공지능 기법 개발

3.1 입출력 데이터셋 구성

본 연구의 데이터셋은 서울의 12개의 구에서 수집한 111개의 다양한 필로티 건물들로 구성하였다. Table 2는 수집된 데이터에 대한 항목을 보여준다. 입력 변수로는 기둥 개수(Column Number, CN), 기둥의 크기에 따른 기둥 형상 비율(Column Shape Ratio, CSR), 벽의 두께와 보의 경간에 따른 벽 형상 비율(Wall Shape Ratio, WSR), 콘크리트 압축 강도(fc'), 횡 방향 간격(Transverse Spacing, TS)으로 5가지 범주로 선정되었다. 입력 변수는 Table 3에 제시된 바와 같이 필로티 구조물의 예측 중간 변위 비율에 해당한다. 입력 변수는 출력 변수는 층간 변위 비율(Inter-story Drift Ratio, IDR)로, 이는 지진 하중을 받는 구조물의 구조적 안정성을 평가하는 데 매우 중요한 지표로 활용된다.

3.2 인공지능 방법론

SVM(Support Vector Machine)과 ANFIS(Adaptive Neuro-Fuzzy Inference System)의 2가지 인공지능 알고리즘은 Fig. 2와 같이 생성하였다. SVM모델은 커널(kernel) 함수에 의존한 비모수적 방법이다. ANFIS 모델은 적응형 프레임워크를 통해 복잡한 구조와 비선형 해석을 효과적으로 다룰 수 있다.

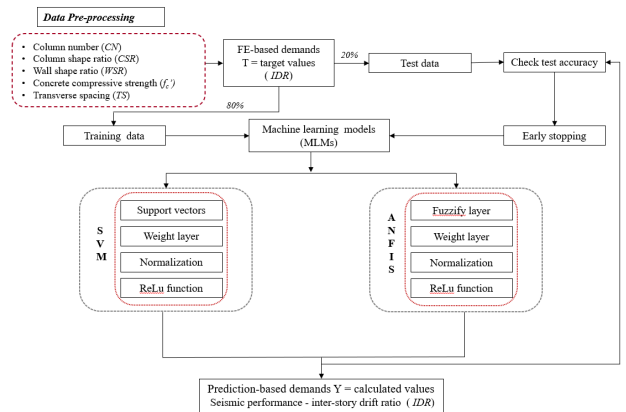


Fig. 2. Flow chart of machine learning methods to predict seismic performance

실제 시스템을 정확히 예측하기 위해 지능형 시스템의 매개변수는 적절한 학습 방법론을 사용하여 보정된다. 평균 절대 오차(Mean Absolute Error, MAE)와 평균 제곱 오차(Mean Squared Error, MSE) 및 평균 제곱근 오차(Root Mean Squared Error, RMSE) 등의 값은 식 (1)~(3)에 따라 관측 및 예측값을 사용하여 계산되었다. 평균 절대 오차(MAE)는 실제 값과 예측 값의 차이 합을 제곱근으로 계산되었다. 또한 평균 제곱 오차(MSE)는 통계적 모델에서 오류의 정도를 정량화하여 실제 값과 예측값 사이의 평균 제곱 편차를 계산하였다.

$$MAE = \sqrt{\sum_{i=1}^N \frac{(Y_i - T_i)}{N}} \quad (1)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i^2 - T_i^2) \quad (2)$$

$$RMSE = \sqrt{\frac{1}{(N) \sum_{i=1}^N (Y_i - T_i)^2}} \quad (3)$$

여기서, T: 실제 시스템의 출력 (측정 또는 관찰된 출력), Y: 적응형 지능형 시스템 출력, N: 인스턴스 값

3.3 서포트 벡터 머신 (SVM) 모델

최근 수십 년 동안 지원 벡터 머신(SVM)에 대한 이론적 이해와 이를 구현하고 실제 문제에 적용하기 위한 알고리즘 방법론이 상당히 발전했다. 1990년대 초에 Vapnik이 개발한 지원 벡터 머신(SVM)은 고차원 공간 내에서 선형 함수의 가설 공간을 사용하는 인공지능 시스템으로, 통계적 학습 이론을 기반으로 하는 학습 편향을 적용하는 최적화 알고리즘을 사용하여 학습된다[22].

SVM은 통계적 학습 이론을 기반으로 하며 구조적 위험 감소 원칙에서 유래하여 경험적 위험(empirical risk)과 학습 모델의 신뢰 구간(confidence interval)을 모두 줄여 일반화 성능을 향상시키는 것을 목표로 하며, 분류 및 회귀 알고리즘으로서 뛰어난 효율성을 입증했다. SVM 회귀의 세부 사항은 Vapnik et al.[23, 24]에서 참조되는데, SVM 회귀의 주요 개념은 다음과 같이 요약할 수 있다. N개의 관측치, x_i 및 x_j 로 표시된 다변량 집합과 해당 관측된 응답 값 Y_n 이 있는 훈련 데이터 세트를 가진다. 커널 트릭을 통합한 비선형 지원 벡터 회귀의 결정 함수는 식과 비선형 지원 벡터 회귀의 이중 표현은 식 (4)와 같다.

$$\begin{aligned}
 \text{Minimize } L(\alpha) = & \\
 & \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)K(x_i, x_j) \\
 & + \varepsilon \sum_{i=1}^N (\alpha_i - \alpha_i^*) - \sum_{i=1}^N Y_i (\alpha_i - \alpha_i^*) \\
 & \sum_{i=1}^N Y_i (\alpha_i - \alpha_i^*) = 0 \\
 & \forall_n : 0 \leq \alpha_n \leq C \\
 & \forall_n : 0 \leq \alpha_n^* \leq C
 \end{aligned}
 \tag{4}$$

여기서 상수 C는 상자 제약 조건이고, $K(x_i, x_j)$ 는 커널 함수를 의미한다. 여러 유형의 커널 함수를 Table 4에서 보여주고 있다. 커널 트릭을 통합한 비선형 SVM의 결정 기능은 식 (5) 같이 표현된다. SVM 모델의 구조는 Fig. 3에서 보여준다[22],[25].




Fig. 3. Structure of SVM model

$$f(x) = \sum_{i=1}^N Y_i (\alpha_i - \alpha_i^*) K(x_n, x) + b \tag{5}$$

여기서 α_n, α_n^* 는 최적화에서의 해는 음이 아닌 제곱수이다.

Fig. 4는 SVM 회귀의 결과를 보여준다. Fig. 4의 그림(a)는 오차에 대한 히스토그램은 수행된 스마트 모델의 성능을 의미하며 이는 학습 네트워크에 대해 실제 그리고 예측값 간의 관계를 20구간으로 나누어 나타낸다. 여기서 0점은 시뮬레이션에서 달성한 최고 성능을 나타낸다. 약 85%의 데이터가 1% 미만의 오류율을 보이는 것으로 확인되었다. Fig. 4(b)와 (c)는 SVM 회귀 모델이 17번의 반복(iteration) 이후 수렴하며 실제와 예측값이 상당히 유사한 결과를 보인 것을 확인하였다.

SVM 모델의 성능은 Fig. 5에서 보여준다. 각 모델 평가를 위해 각 데이터 세트에서 11개의 샘플 예제를 무작위로 선택했으며, 학습에 사용된 예제는 제외했다. 학습 및 테스트 곡선은 학습 곡선에서는 거의 차이가 없었으며 테스트 곡선과 밀접하게 일치하는 것을 확인했다. 훈련, 테스트 및 전체 지진 데이터의 R 제곱 값은 각각 0.946, 0.938 및 0.942로 확인되었다. 이를 통해 통계적 분석으로 인한 모델 예측값과 실제 데이터 간의 큰 차이가 없음을 확인하였다. MAE, MSE 및 RMSE는 각각 0.022, 0.019 및 0.122로 Table 5에 나와 있는 것처럼 SVM 모델은 실제 결과와의 높은 연관성을 입증하였고 예상되는 패턴을 식별하는 데 있어 효율적으로 작용하였다.

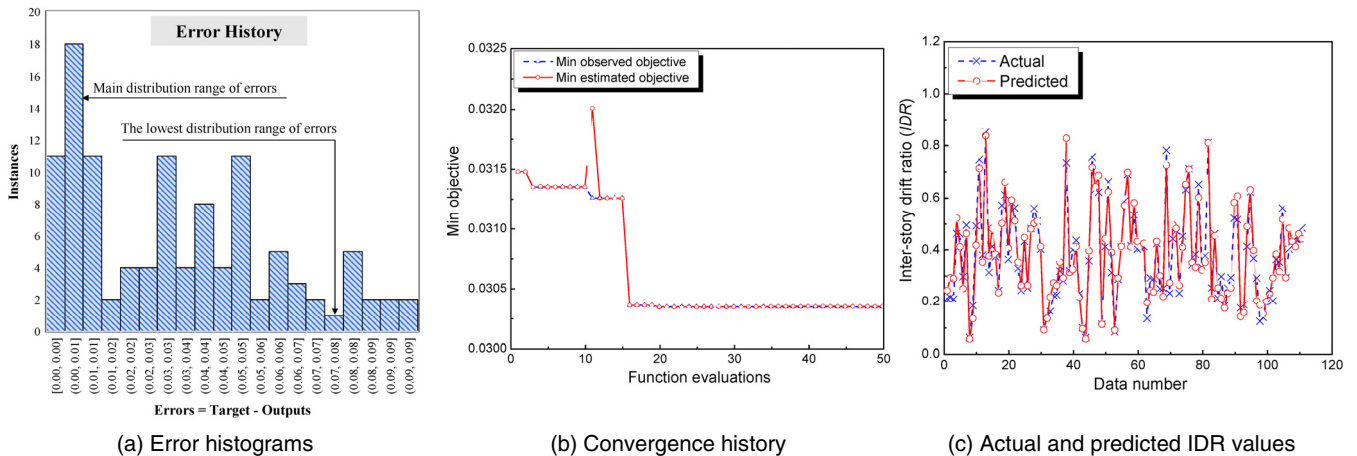


Fig. 4. Performance evaluation for SVM model




Fig. 5. Performance evaluation - Regression analysis for the SVM simulation

Table 4. Kernel functions

Kernel name	Kernel function
Linear	$K(x_i, x_j) = x_i^T x_j$
Gaussian	$K(x_i, x_j) = \exp(- \ x_i - x_j\ ^2)$
Polynomial	$K(x_i, x_j) = (1 + x_i^T x_j)^q$ where, q is in the set {2,3,...}

Table 5. Seismic performance evaluation of the SVM model

Statistical parameter	Requirements	Calculated results
MAE	Close to 0	0.022
MSE	Close to 0	0.019
RMSE	Close to 0	0.122
R ²	Greater than 0.9	0.942

3.4 적응형 신경 퍼지 추론 시스템(ANFIS) 모델

적응형 신경 퍼지 추론 시스템(ANFIS)은 신경망과 퍼지 논리 시스템의 장점을 결합한 인공지능 프레임워크이다. ANFIS는 신경망과 유사하게 데이터를 기반으로 학습하고 의사 결정을 내릴 수 있는 능력을 가지고 있다. 또한, 퍼지 논리 시스템(fuzzy logic system)과 마찬가지로 모호하거나 불완전한 데이터를 이해할 수 있는 능력을 보여준다. ANFIS는 동적이거나 모호한 데이터를 포함하는 애플리케이션에 특히 적합하다. 학습 알고리즘은 네트워크 내 뉴런 간의 연결 가중치를 조정하며, 이를 통해 신경망은 새로운 데이터를 학습하고 적용할 수 있다.

ANFIS는 다층 퍼드포워드 네트워크로, 각 노드는 입력 신호에 대해 지정된 기능을 수행하고 관련된 매개변수 세트를 보유하며, 인공지능망(ANN)과 퍼지 추론 시스템에 의해 수행되는 퍼지화(fuzzification)를 포함한 여러 계층으로 구성되어 있다[26-28]. ANFIS는 기존 데이터를 기반으로 규칙을 추출하여 새로운 입력에 대한 결과를 예측할 수 있다. ANFIS 설계를 위해 퍼지화 계층(fuzzification layer), 규칙 계층(rule layer), 정규화 계층(normalization layer), 역퍼지화 계층(defuzzification layer) 및 전체 출력 계층(total output layer)과 같이 5개의 계층으로 구성되며, Fig. 6과 같이 나타난다. 타카기-스겐(Takagi-Sugeno, T-S) 퍼지 추론 시스템은

Takagi와 Sugeno에 의해 개발된 일반적으로 사용되는 정확한 퍼지 모델이며, T-S 퍼지 추론 시스템은 퍼지 집합을 사용하는 대신 가중 선형 결합을 통해 명확한 입력(crisp inputs)을 통합함으로써 퍼지 규칙을 생성한다[29].

퍼지 시스템은 퍼지(IF-THEN) 규칙을 통해 프로세스에 대한 전문가의 지식을 표현하는 데 도움을 준다. 해당 규칙은 퍼지 시스템에서 지식 습득의 기본 단위로 사용된다. 퍼지 규칙은 ‘IF’ 절과 ‘THEN’ 절로 구성되며, 각각 전제(antecedent)와 결과(consequent)로 불린다는 점에서 인공지능의 전통적인 규칙과 유사하다는 특징을 갖고 있다. 식 (6)은 퍼지 규칙의 기본 구조를 보여준다. 퍼지 규칙의 전제는 특정 조건에 따라 일정 수준까지 만족될 수 있으며, 전통적인 규칙과 마찬가지로 논리 연산자 AND, OR, NOT을 통해 여러가지의 간단한 조건을 복잡한 형태로 통합할 수 있다는 특징이 있다. 퍼지 규칙의 결과는 퍼지 결론(Fuzzy consequent)과 함수형 결론(Functional consequent)의 두 가지 주요 유형으로 분류할 수 있다.

$$\text{IF} < \text{antecedent} > \text{ THEN} < \text{consequent} > \quad (6)$$

제안된 ANFIS 모델의 최적 성능은 영향/클러스터 중심 범위 $r = 0.45$ 및 50개의 규칙을 활용한 조건에서 나타났다. Fig. 7은 ‘AND’ 논리 연산을 사용한 50개의 규칙으로 구성된 ANFIS 모델의 구성을 나타내며, 제안된 ANFIS 모델의 규칙은 지정된 입력 매개변수(CN = 10, CSR=2.21, WSR=2.67, $f'_c = 20.2$ MPa, TS = 250 mm)를 활용하여 Fig. 8과 같이 나타났다.

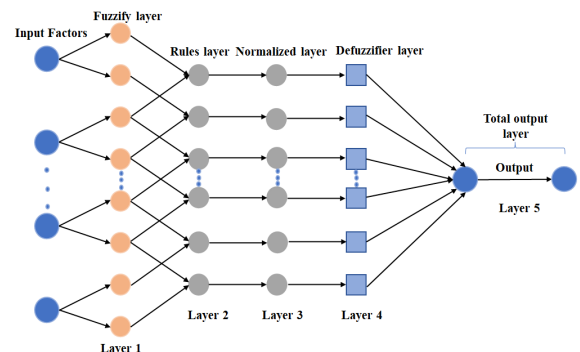


Fig. 6. Structure of ANFIS model




Fig. 7. Structure of ANFIS model by using MATLAB software




Fig. 8. ANFIS rule structure with 50 rules


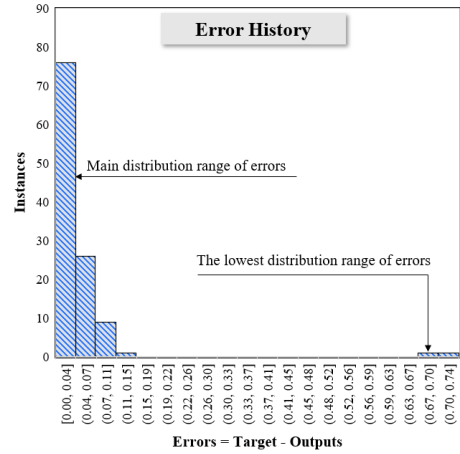



Fig. 9. Performance evaluation - 3D-surface plot of section shape ratios with input parameters and output

출력 매개변수(IDR) 예측에 대한 모든 입력 변수의 영향을 결정하기 위해 매개변수 분석이 수행되었다. 3차원 표면 그래프를 사용하여 입력 변수가 출력 매개변수에 미치는 영향을 시각적으로 나타냈다. Fig. 9는 CSR 및 WSR이 추가 입력 변수와 결합하여 출력 매개변수에 미치는 영향을 보여준다. 최고 출력값은 CSR=2.21, WSR=2.67, CN=1, =20.2 MPa, TS=250 mm로 계산되었다. 각 입력 데이터와 출력 데이터 간의 상호작용은 이론상 연속적이며 다른 입력 데이터와 독립적인 관계이지만, ANFIS의 신경-퍼지 논리 프레임워크에서는 적용되지 않는다. ANFIS 신경-퍼지 시스템에서는 각 입력 변수와 출력 변수 간의 상관관계가 다양한 조합에 따라 변동되며, 극값과 곡률에 대해 유사한 양상을 보인다는 특징이 있다.

Fig. 10는 ANFIS 모델에서의 회귀 결과를 보여준다. 시뮬레이션된 스마트 모델의 성능을 나타내는 에러 히스토그램은 네트워크 내 모든 데이터를 대상으로 실제 값과 예측 값 간의 관계를 20개의 빈(Bin)으로 나타낸다. 여



(a) Error histograms



(b) Actual and predicted IDR values

Fig. 10. Performance evaluation for ANFIS model

기서 에러가 0인 지점은 시뮬레이션에서 달성된 최적의 성능을 나타내며, 약 95%의 데이터는 에러율이 1% 미만을 기록하였다(Fig. 10 (a)). Fig. 10 (b)는 ANFIS 모델이 실제 결과와 예측 결과 간의 불일치가 거의 없을 때 높은 일치도를 나타냄을 보여준다.

Fig. 11은 ANFIS 모델의 성능을 자세하게 보여준다. 각 데이터셋에서 무작위로 모델 학습에 사용되지 않은 데이터인 11개의 샘플을 선정하여 모델 평가에 활용하였다. 학습 곡선과 테스트 곡선은 큰 차이 없이 유사하게 나타남으로서 과적합(Overfitting)이 없음을 확인하였다. 학습, 테스트, 그리고 전체 지진 데이터에 대한 결정 계수(R-squared) 값은 각각 0.967, 0.942, 0.958로 나타났다. 평균 절대 오차(MAE), 평균 제곱 오차(MSE)와 평균 제곱근 오차(RMSE)는 각각 0.17, 0.011, 0.104로 계산되어 지능형 모델 성능 평가의 신뢰도를 확인하는 지표로 사용되었으며, 이는 Table 6에 나타나 있다. ANFIS 모델은 실제 결과와 높은 상관관계를 보였으며, 더 높은 출력값을 생성할 수 있는 경향을 효과적으로 파악할 수 있음을 확인하였다.

4. IDR을 기반으로 한 단면 형상비의 내진성능

RC 필로티 구조에 대한 최적의 구성 접근법은 CSR 및 기타 매개 변수의 변화에 따라 WSR이 1.5일 때 최적의 모델이 되는 것을 확인되었다. 최적방




Fig. 11. Performance evaluation - Regression analysis for the ANFIS simulation

Table 6. Seismic performance evaluation of the ANFIS model

Statistical parameter	Requirements	Calculated results
MAE	Close to 0	0.172
MSE	Close to 0	0.011
RMSE	Close to 0	0.104
R ²	Greater than 0.9	0.958

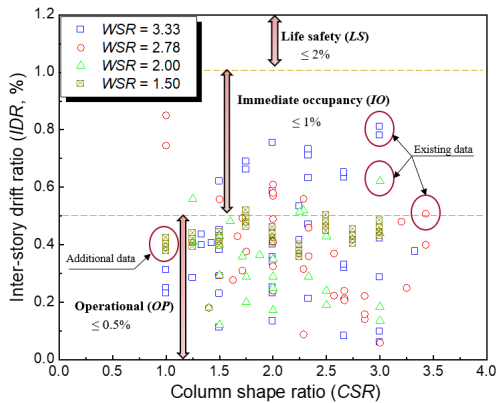


Fig. 12. Predicted the effect of section shape ratios to inter-story drift ratio

안은 기둥 형상비(CSR)과 벽체 형상비(WSR)과 같은 구성 특성을 기반으로 하였다. Fig. 12를 통해 CSR이 1.0에서 1.5로 변화할 때, 필로티 구조는 WSR 값이 1.5와 WSR 값이 3.33에서 작동 레벨에 도달했음을 보여준다. 또한 CSR이 1.5에서 2.25로 변화할 때 필로티 구조의 내진 성능의 작동 레벨은 WSR 값이 2.0에 도달했으며, CSR이 1.5에서 2.0으로 증가하거나 2.5 이상이 될 때 WSR는 2.78에서 유지되었다. 하지만, 필로티 구조는 WSR 시나리오와 관계없이 CSR 값이 1.5에서 2.5 사이에 있을 때 즉시 재사용 수준을 유지하였다. 따라서, 제안된 최적 보강 방안은 CSR의 범위는 1에서 1.5 사이이며, WSR이 2.78 일 때 CSR이 2.5 초과하는 것을 알 수 있었다.

5. 결론

본 연구는 필로티형 구조물의 내진 성능 예측을 위한 인공지능 기법 개발에 초점을 맞추고 있으며, 필로티 구조물의 손상에 따른 성능을 예측하기 위

해 서포트 벡터 머신 (SVM) 과 적응형 신경망 기반 퍼지 추천 시스템 (ANFIS)를 사용하였다. 주요 결론은 다음과 같다.

- 1) CSR 변화에 따른 성능 개선을 통해 필로티 구조물은 CSR이 1.0에서 3.43으로 변경된 후 필로티형 건물은 80%가 작동수준, 20%는 즉시 재사용 수준의 성능을 나타남 확인하였다. 또한, WSR 값에 따른 작동성능 분포는 WSR 값이 2.0, 2.78, 3.33일 때 각각 90%, 80%, 60%의 작동성능 분포를 나타냈다. 이는 WSR 감소는 필로티 구조물의 효율성과 안전성을 향상시키는 것으로 판단하였다.
- 2) SVM과 ANFIS 모델은 직교 설계를 사용할 때 내진 성능을 정확하게 예측하는 데 신뢰할 수 있다. 이는 실제 결과와 예상 결과 사이에 강력한 연관성이 있음을 보여준다. 그럼에도 불구하고 ANFIS 모델은 MAE, MSE, RMSE 및 R²와 같은 특징적 특성에서 알 수 있듯이 필로티 구조의 손상 성능을 예측하는 데 두 모델 중에서 더 우수한 정확도를 보여준다.
- 3) 개별 상황에 맞는 필로티 구조물을 위한 적절한 프레임 워크 수립이 중요하다. CSR 및 WSR 매개변수는 층간변위비와 관련된 내진 성능에 큰 영향이 미치는 것을 알 수 있었으며, 제안된 최적방법은 CSR이 1.0에서 1.5사이이며, WSR이 1.5에서 3.33 사이인 경우와 WSR이 2.78일 때 CSR이 2.5를 초과하는 범위를 포함하는 것으로 판단하였다.
- 4) 필로티 구조 성능의 정확한 예측에 관한 연구 결과는 유한 요소 모델을 활용하여 2~3층의 필로티 구조와 같은 더 큰 구조물에서도 사용할 수 있다. 기계 학습은 내진 성능을 예측하는데 유용한 것으로 판단되며, 다양한 단면에 형상비로 내진 성능을 예측할 수 있을 것으로 기대된다.

/ 감사의 글 /

이 논문은 국토교통부 국토교통과학기술진흥원 국토교통 기술사업화를 위한 이어달리기사업의 지원을 받아 수행된 연구임 (RS-2024-00410886). 이에 감사드립니다.

/ REFERENCES /

1. Lee HS, Ko DW. Shaking table tests of a high-rise rc bearing-wall structure with bottom piloti stories. J Asian Archit Build. 2002;

- 1(1):47–54.
2. Maidiawati, Tanjung J, Sanada Y, Nugroho F, Wardi S. Seismic analysis of damaged buildings based on postearthquake investigation of the 2018 palu earthquake. *GEOMATE Journal*, 2020;18(70): 116–122.
 3. Sextos AG, Katsanos EI, Manolis GD. Ec8–based earthquake record selection procedure evaluation: Validation study based on observed damage of an irregular r/c building. *Soil Dyn Earthq Eng*. 2011; 31(4):583–597.
 4. Kim JC, Shin SH, OH SH. Damage investigation of pilotis structures and analysis of damage causes by pohang earthquake. *J Archit Inst Korea Struct Constr*. 2019;35(3):3–10.
 5. EOM TS, Lee SJ, Park HG. Investigation of structural damage in bearing wall buildings with pilotis by 2017 Pohang earthquake. *J Earthq Eng Soc Korea*. 2019;23(1):9–18.
 6. Dang-Vu, H., Lee DH, Shin J, Lee K. Influence of shear-axial force interaction on the seismic performance of a piloti building subjected to the 2017 earthquake in Pohang Korea. *Struct Concr*. 2020; 21(1):220–234.
 7. Dang–Vu H, Nguyen QD, Chung TC, Shin J, Lee K. Frequency–based data–driven surrogate model for efficient prediction of irregular structure’s seismic responses. *J Earthquake Eng*. 2022;26(14):7319–7336.
 8. Lee HS, Ko DW. Shaking table tests of a high–rise RC bearing–Wall structure with bottom piloti stories. *J Asian Archit Build*, 2002; 1(1):47–54.
 9. Lee HS, Ko DW. Seismic response characteristics of high–rise RC wall buildings having different irregularities in lower stories. *Eng Struct*. 2007;29(11):3149–3167.
 10. Shin J, Lee K, Jeong SH, Lee HS, Kim J. Experimental and analytical studies on buckling–restrained knee bracing systems with channel sections. *Int J Steel Struct*. 2012;12(1):93–106.
 11. Structural Engineers Association of California, SEAOC, Vision 2000, Performance based seismic engineering of buildings. Sacramento, CA: Vision 2000 Committee; c1995.
 12. Federal Emergency Management Agency (FEMA) 349. FEMA/EERI, Action plan for performance – based seismic design. Washington DC: Federal Emergency Management Agency; c2000.
 13. ENV 1998–1, Eurocode 8: Design of Structures for Earthquake Resistance Part 1: General rules, seismic actions and rules for buildings. Code of Practice, London; c2005.
 14. ATC. Development of performance–based earthquake design guidelines. Redwood City: ATC–58; c2002.
 15. Federal Emergency Management Agency (FEMA) 273. NEHRP guidelines for the seismic rehabilitation of buildings. Washington DC: Federal Emergency Management Agency; c1997.
 16. Federal Emergency Management Agency (FEMA) 356. Prestandard and commentary for the seismic rehabilitation of buildings. Washington DC: Federal Emergency Management Agency; c2000.
 17. Skolnik D. Building instrumentation, Ph.D. dissertation, Dept. of Civil Engineering, Univ. of California, Los Angeles; c2008.
 18. Eunjong Y, Derek S, Daniel H, W, John W. W. Forced vibration testing of a four–story reinforced concrete building utilizing the nees@ UCLA mobile field laboratory. *Earthquake Spectra*, 2008; 24(4):969–995.
 19. Çelebi M, Sanli A. GPS in pioneering dynamic monitoring of long–period structures. *Earthquake Spectra*. 2002;18(1):47–61.
 20. Wahbeh AM, Caffrey JP, Masri SF. A vision–based approach for the direct measurement of displacements in vibrating systems. *Smart Mater Struct*. 2003;12(5):785.
 21. Fu G, Moosa AG. An optical approach to structural displacement measurement and its application. *J Eng Mech*, 2002; 128(5):511–520.
 22. Vapnik VN. *The Nature of Statistical Learning Theory*. Springer New York; c2000.
 23. Vapnik V, Golwih S, Smola AJ. Support vector method for function approximation, regression estimation and signal processing, in: Mozer M, Jordan M, Petsche T (Eds.), *Advances in Neural Information Processing Systems*, vol. 9, MIT Press, Cambridge, MA, USA; c1997, p. 281–287.
 24. Collobert R, Bengio S, SVMForch: support vector machines for largescale regression problems, *J Mach Learn Res*. 1 2001;143–160.
 25. Cristianini N, Shawe–Tylor J, in: *An Introduction to Support Vector Machines and Other Kernel–Based Learning Methods*, Cambridge University Press, UK; c2000.
 26. Jang J. S. R. ANFIS: Adaptive–network–based fuzzy inference system. *IEEE TransactionsonSystems, Man, andCybernetics1993*23(3): 665–685.
 27. Petković D, Hafizah Ab Hamid S, Čojbašić Ž, T. Pavlović N. Adapting project management method and ANFIS strategy for variables selection and analyzing wind turbine wake effect. *Nat Hazards*. 2014;74(2):463–475.
 28. Sari PA, Suhatri M, Osman N, Mu’azu MA, Katebi J, Abavisani A, Ghaffari N, Chahnasir ES, Wakil K, Khorami M, Petkovic D. Developing a hybrid adoptive neuro–fuzzy inference system in predicting safety of factors of slopes subjected to surface eco–protection techniques. *Eng Comput*. 2020;36(4):1347–54.
 29. Talei A, Chua LHC, Quek C, Jansson P–E. Runoff forecasting using a Takagi–Sugeno neuro–fuzzy model with online learning. *J Hydrol (Amst)*. 2013; 488:17–32.