

스틸 풀리 초기 설계를 위한 일반화된 회귀 신경망에 관한 연구 A study on the Generalized Regression Neural Network for preliminary design of steel pulley

*김형중¹, 이경태¹, 김지석¹, 천두만¹, #안성훈², 장재덕³

*H. J. Kim¹, K. T. Lee¹, J. S. Kim¹, D. M. Chun¹, #S. H. Ahn(ahnsh@snu.ac.kr)², J. D. Jang³

¹ 서울대학교 기계항공공학부 대학원, ² 서울대학교 기계항공공학부, 정밀기계설계공동연구소, ³ 한국파워트레인(주)

Key words : Steel pulley, Computer-Aided Engineering (CAE), Neural Network (NN), Genetic Algorithm (GA)

1. 서론

CAD(Computer-Aided Design)/CAE(Computer-Aided Engineering) 및 IT(Information Technology) 기술의 발전과 함께, 제품 설계 과정에 있어서 많은 시간을 차지하던 모델링, 도면화, 해석(finite element analysis, FEA) 업무 등의 신속성 및 효율성은 크게 향상되었다. 이에 비해 중요한 의사 결정이 필요한 설계 변형 및 결정에 있어서는 여전히 숙련된 설계자의 경험적 지식에 크게 의존하고 있다.

최근에는 이를 해결하기 위해 다양한 설계 인자들 간의 비선형적인 관계를 분석하고, 이를 기반으로 새로운 설계 조건에 적합한 설계안을 도출할 수 있는 신경망(neural network)에 대한 연구가 다수 진행되었다. Lin¹은 자동화된 구조 설계 시스템의 개발에 있어서 다층신경망을 적용하였으며, Stefano와 Angelo²는 항공기 날개 설계에 Bezier 신경망을 적용하였다. Salajeh³는 신경망과 가상 하위 개체군(Virtual Sub-Population, VSP) 방법론이라 불리는 유전자 알고리즘을 최적 구조 설계에 적용하였다.

본 논문에서는 자동차의 파워트레인에 사용되는 스틸 풀리의 초기 설계를 지원하기 위한 해석 결과 예측 모델을 구성하였다. 학습 데이터로는 스틸 풀리의 설계 및 해석 데이터를 사용하였으며, 학습 모델은 일반화된 회귀 신경망(Generalized Regression Neural Network, GRNN)을 적용하였다. 학습 결과의 신뢰성을 평가하기 위해 학습되지 않은 새로운 설계 및 그 해석 데이터와 비교를 하고 그 결과를 정리하였다.

2. 배경 이론

2.1 신경망

신경망은 학습과 경험을 바탕으로 새로운 상황에 대처하는 인간의 두뇌를 모사하기 위한 수학적 모델이다. 기존의 통계적 기법들에 적용하기 어려운 패턴 인식, 문자 인식, 예측 시스템 등과 같이 보편성과 적응성이 동시에 요구되는 분야에 주로 사용된다.

일반적으로 신경망은 입력층, 은닉층, 출력층으로 이루어진다. 입력/출력층은 입력/출력 데이터의 연산을 담당하며, 은닉층은 주어진 데이터에 대해서 학습을 수행한다. 학습 방식 및 입력 방식에 따라 뉴로-퍼지 신경망(Neuro-fuzzy network), 스파이킹 신경망(Spiking neural network), 일반화된 회귀 신경망 등으로 구분된다.

일반화된 회귀 신경망은 학습하는 모든 입력값에 대해서 은닉 객체가 존재하는 원형기준함수(Radial Basis Function, RBF) 모델 중의 하나이다. 확률밀도함수(Probability Density Function, PDF)를 이용하여 데이터 공간에서 임의로 주어진 입력값 중 가능성이 가장 큰 값을 탐색하며, 일반적으로 회귀 문제, 함수의 근사 등에 주로 사용된다.

2.2 유전자 알고리즘

유전자 알고리즘(Genetic Algorithm, GA)은 생물의 진화 메커니즘을 기반으로 최적해의 확률적인 탐색 방법에 대한 수학적 모델이다. 기존의 최적화 기법에 비해 전역적이고 강인한 최적화 과정을 제공할 수 있다. 파라미터 집합

을 대상으로 함으로써, 수학적 모델에 대한 결정론적 규칙이 아닌 탐색 공간에 대한 적합도 함수를 이용한 평가를 따르는, 확률에 기반을 둔 탐색을 수행한다.

일반적으로 초기해를 염색체(chromosome)라 불리는 이진 스트링(binary string)으로 구성하고, 유전 연산자(genetic operator)인 선택(selection), 교차(crossover), 돌연변이(mutation) 등을 통해 적합도가 높은 해로 수렴한다.⁴

3. GRNN 과 GA 이 결합된 모델

GRNN 모델의 학습 데이터에 대한 적합도는 스프레드(spread) 값에 의해 결정된다. 스프레드란 회귀 함수의 완만함(smoothness)을 조절하는 주요 변수로 주로 실험적으로 결정되며, GA를 이용하여 최적화된 값을 구할 수 있다.

제시된 예측 모델의 작동 순서는 다음과 같다.

1. 임의의 스프레드를 GA를 통하여 생성한다.
2. 훈련군의 데이터와 스프레드를 GRNN에 입력한다.
3. 스프레드와 입력된 데이터로 GRNN의 은닉층에서 다변수 가우시안 함수(multiple gaussian function)를 통해 학습한다.
4. 은닉층의 학습 결과와 연결 강도를 결합하여 출력층의 선형 변환 함수에 입력한다.
5. GRNN의 결과를 출력한다.
6. 출력된 결과를 적합도 함수에 대입하여 적합도를 계산한다.
7. 적합도를 토대로 GA는 이진 스트링화된 스프레드의 염색체를 유전 연산자를 사용하여 적합도가 더 높은 스프레드를 생성한다.
8. 2 ~ 7의 과정을 반복하여 적합도가 최대가 되는 스프레드를 생성한다.

일반적으로 종료 조건으로는 총 연산 시간, 최대 세대 수, 최적 해의 최소 변화량이 사용된다.

4. 사례 적용

4.1 학습 데이터

자동차용 스틸 풀리는 파워트레인에서 비교적 단순한 부품 중의 하나이지만, 그 설계 과정에서는 다른 부품들과




Fig. 1 CAD model of typical pulley

마찬가지로 다수의 설계 및 해석 작업이 요구된다(Fig. 1). 또한 해석 결과는 주로 주요 변수에 의해 결정되며, 서론에서 제기된 바와 같이, 이와 같은 결정은 주로 담당자의 경험적 지식에 의존한다.

스틸 풀리의 설계 변수는 크게 재료와 형상의 범주로 구분될 수 있다. 재료 관련 변수로는 밀도, 탄성 계수, 프아송 비, 전단 탄성 계수, 열팽창 계수 등이, 형상 관련 변수로는 두께, 벨트 중심에서 장착 면까지의 거리, 브래킷과 결합하는 볼트의 위치, 직경 등이 있다.

본 논문에서는 입력값으로 형상 관련 변수 중 해석 결과에 영향이 큰 두께와 벨트 중심에서 장착면까지의 거리를, 출력값으로 FEA 해석 결과 중 최대 응력을 선택하였다. 학습데이터는 한국파워트레인에서 양산 중인 스틸 풀리의 설계 데이터 베이스에서 57 개의 데이터 셋을 수집하였다.

4.2 결합 모델의 학습에 적용

제시된 예측 모델의 학습 및 스프레드 값의 최적화를 위해, 전체 57 개의 데이터를 각각 훈련군 46 개와 표본군 11 개로 나누었다. 훈련군은 예측 모델의 훈련에 사용되며, 표본군은 GA 를 이용하여 최적의 스프레드 값을 찾는 과정에서 학습된 GRNN 모델의 적합도를 판단하는 기준으로 사용된다. 시험군은 기존 데이터 범위 내에서 임의로 생성하였고, GRNN 을 통해 결과값을 얻기 위한 입력값들이다. 그리고 적합도 함수는 데이터의 해석 값과 GRNN 을 통해 얻은 결과값의 평균제곱근오차(Root Mean Square Error, RMSE)이다.

최적의 스프레드를 찾기 위한 GA 연산의 설정값들은 사전에 학습 데이터들을 평가하여 Table 1 과 같이 정하였다.

분류된 데이터들을 이용하여 제시된 예측 모델의 학습을 진행하는 과정은 Fig. 2 와 같다. 제시된 예측 모델에서 사용된 종료조건은 최대 연산시간 1000 초, 최대 세대수 70, 최적해 변화량 10e-6 을 사용하였다.

4.3 적용 결과

제안된 응력 예측 모델의 유효성을 평가 하기 위하여 학습 데이터와 중복되지 않는 6 개의 시험군의 실제 응력 값과 제안된 모델을 통해 얻어진 결과값을 비교하였다. 시험군을 통하여 오차를 구해본 결과, 5.2% ~ 11.75%의 오차

Table 1. Parameters and values of GA operation

Parameter	Value
Population Size	50
Maximum Generation	70
Crossover probability	0.9
Mutation probability	0.01

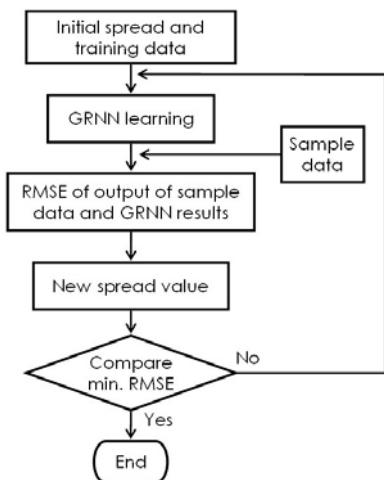


Fig. 2 Flow chart of stress estimation model

가 나타났다(Fig. 3). 주어진 학습 데이터에서 데이터 셋의 분포가 고르지 못한 경우, 상대적으로 큰 오차가 나타났다. 이와 같은 현상은 실제 현장에서 양산되는 스틸 풀리의 설계 데이터가 계속 누적됨에 따라 줄어들 것으로 판단된다.



Fig. 3 Difference between FEA results and proposed estimation for tested pulley design

5. 결론

본 논문에서는 자동차용 스틸 풀리의 설계/해석 데이터를 각각 입력/출력값으로 하여 GRNN 학습을 수행하고, 초기 설계를 지원할 수 있는 예측 모델을 구성하였다. GRNN 의 스프레드 값을 최적화하기 위해 GA 를 적용하였으며, 이전에 학습되지 않은 새로운 데이터에 예측 모델을 적용하여 신뢰성 평가하였다. 이를 통해 정리된 결과는 다음과 같다.

1. 자동차용 스틸 풀리의 설계/해석 데이터의 분석에 GA 를 이용한 GRNN 모델을 적용하였다.
2. 설계 담당자에 의해 20~30 분 정도가 소요되는 FEA 해석 작업 대신 수 십초 이내에 결과값을 예측할 수 있었으며, 10% 이내의 오차(평균 8.24%)를 나타내었다.

풀리 설계 시, 설계 변수 결정에 있어서 신속성 및 효율성을 도모할 수 있다. 오차를 줄이기 위해서 보다 복잡한 설계 조건들을 고려한 연구가 수행될 것이며, 단일군의 학습 데이터가 아닌 학습 데이터 자체의 특성을 사전에 분류(classification)하여 각각 고유의 특성을 지닌 설계 데이터군에 대한 분석이 가능한 시스템을 구성할 예정이다.

후기

본 연구는 서울대학교 2 단계 BK21 사업, 정밀기계설계 공동연구소, 산업자원부 중기거점기술개발 사업(10016432)의 지원으로 수행되었으며, 이에 감사 드립니다.

참고문헌

1. Lin, J.C., "Free-form surface rebuild using an abductive neural network", Journal of Material Processing Technology, **116**, 170-175, 2001.
2. Stefano, P.D. and Angelo, L.D., "Neural network based geometric primitive for airfoil design," Proceedings of the Shape Modeling International 2003, 12-16 May, Seoul, Korea, 201-206, 2003.
3. Salajegheh, E. and Gholizadeh, S., "Optimum design of structures by an improved genetic algorithm using neural networks," Advances in Engineering Software, **36**, 11-12, 757-767, 2005.
4. Richard, O., Peter, E., and David G., Pattern Classification, A Wiley-Interscience Publication, 373-382, 2001.