

# 인공신경망 가중치의 효과적인 최적화를 위한 하이브리드 메타휴리스틱 알고리즘

고광종 · 허재석<sup>†</sup>

한국공학대학교 경영학부

## An Effective Hybrid Metaheuristic Algorithm for Weight Optimization of Artificial Neural Networks

GwangJong Ko · Jaeseok Huh

Department of Business Administration, Tech University of Korea

Due to a number of local minimums, the gradient descent methods have difficulties in searching for the optimal weights of artificial neural networks (ANNs). To resolve this problem, recently, a number of scholars have conducted studies that utilize metaheuristics to optimize the weights of ANNs. Particularly, the swarm intelligence algorithm which is one of the metaheuristics has shown great potential in previous studies. In this study, we propose the hybrid metaheuristic algorithm that effectively optimizes the weight of ANNs by combining particle swarm optimization (PSO) and grey wolf optimizer (GWO), both of which are swarm intelligence algorithms. In the search process, the proposed algorithm resolves the convergence instability in the validation dataset using the swarm memory that was inspired by the habit of remembering the environment in which the swarm was suitable for survival. Numerical experiments demonstrate the proposed algorithm outperforms the existing swarm intelligence algorithms, stochastic gradient descent, and Adam Optimizer in terms of classification accuracy.

**Keywords:** Weight Optimization, Artificial Neural Network, Particle Swarm Optimization, Grey Wolf Optimizer Optimization, Swarm Memory

### 1. 서론

인공신경망은 생물의 신경망에서 영감을 얻은 통계학적 학습 알고리즘으로 금융(Qi *et al.*, 2020), 제조 공정(Huh and Park, 2019) 및 의학(Minnema *et al.*, 2018)을 포함한 다양한 산업 전반에 그 응용 분야를 넓히고 있다. 인공신경망은 인공 뉴런인 노드(node)로 구성되어 있으며 각 노드를 잇는 간선(edge)은 가중치를 지니고 있다. 학습을 통해 적절한 가중치를 찾아 문제를 해결하는 함수를 근사하는 것이 인공신경망의 목표이며,

학습은 일반적으로 경사 하강법이 사용된다. 그러나 경사 하강법은 현재의 위치에서 기울기가 급해지는 방향으로 이동하는 최적화 방식 때문에 국소 최적해에 빠질 수 있으며(Mun *et al.*, 2016), 고차원의 벡터에서 빈번히 등장하는 안장점(saddle point)으로 인해 수렴이 지체될 수 있다는 문제를 가지고 있다(Dauphin *et al.*, 2014).

이러한 문제를 해결하기 위해 메타휴리스틱을 인공신경망 가중치 최적화에 적용하는 연구가 진행 중이다. 메타휴리스틱은 자연 현상이나 물리 법칙 등을 모사하여 전역 최적해를 탐

이 논문은 2019년도 한국공학대학교 학술연구진흥사업에 의하여 연구되었으며, 한국연구재단과 정보통신산업진흥원의 지원을 받아 수행된 연구임 (2020R1G1A1007453, S0317-21-1002).

<sup>†</sup> 연락저자 : 허재석 교수, 15073 경기도 시흥시 산기대학로 237 정왕동 한국공학대학교 경영학부, Tel : 031-8041-0675,

E-mail : jshuh@tukorea.ac.kr

2021년 10월 14일 접수; 2021년 11월 24일 수정본 접수; 2022년 2월 8일 게재 확정.

색해 나가는 최적화 방법론이다. 메타휴리스틱은 경사 하강법과는 다르게 수렴(exploitation)뿐만 아니라 탐색(exploration)까지 균형적으로 수행하여 전역 최적해를 찾아 나가기 때문에 경사 하강법이 가진 국소 최적해 교착 문제를 효과적으로 해결한다(Mosavi *et al.*, 2016).

그러나 기존의 연구는 대부분 메타휴리스틱을 실험적으로 도입하는 수준에 머물러 있으며, 수렴 및 탐색 성능에 대한 고도화 연구는 부족한 실정이다. 또한, 메타휴리스틱을 인공지능 경망 학습에 보편적으로 사용되는 Adam(adaptive moment estimation; Kingma and Ba, 2014)과 비교 검증한 연구도 찾아보기 어렵다. 따라서 메타휴리스틱을 인공지능경망에 실질적으로 적용 가능한 최적화 기법으로 사용하기 위해서는 상기 한계를 보완하기 위한 연구가 필요한 상황이다.

따라서 본 논문에서는 기존의 메타휴리스틱 알고리즘들을 결합하여 인공지능경망의 가중치를 효과적으로 최적화할 수 있도록 고도화된 하이브리드 메타휴리스틱 알고리즘을 제안한다. 구체적으로는 군집 지능 알고리즘의 일종인 PSO(particle swarm optimization; Kennedy and Eberhart, 1995)와 GWO(grey wolf optimizer; Mirjalili *et al.*, 2014)가 가진 수렴양상의 특징을 분석하였고, 특징이 상호 보완적으로 극대화되도록 결합하여 2단계의 최적화 알고리즘을 제안하였다. 또한, 제안 알고리즘은 군집이 생존하기 적합한 환경을 기억하는 습성에서 착안한 군집 기억을 통해 메타휴리스틱 기반 가중치 최적화에서 발생하는 검증 데이터 셋에서의 수렴 불안정성 문제를 해결하였다. 본 연구의 실험에서는 기존의 메타휴리스틱 알고리즘 및 SGD(stochastic gradient descent; Robbins and Monro, 1951)뿐 아니라 Adam과도 비교함으로써 제안 알고리즘이 가진 최적화 성능을 검증하였다.

본 논문의 구성은 다음과 같다. 제2장에서는 메타휴리스틱의 일종인 군집 지능 알고리즘과 이를 신경망 가중치 최적화에 적용한 선행 연구를 고찰하고, 제3장에서는 본 논문에서 고안한 제안 알고리즘의 아이디어와 해 탐색 과정 및 군집 기억을 자세히 기술한다. 제4장에서는 실험의 내용과 그 결과를 논의하며, 마지막으로 제5장에서 본 연구의 결론 및 한계점과 향후 연구를 제안한다.

## 2. 선행 연구

### 2.1 군집 지능 알고리즘

해집단 기반의 메타휴리스틱 알고리즘은 모사된 근원에 따라 진화적 알고리즘, 군집 지능 알고리즘, 물리 기반 알고리즘, 자연 발견적 알고리즘으로 분류되며 각 분류 내의 메타휴리스틱 알고리즘은 유사한 동작 방식과 특징을 갖는다(Dhiman, 2018).

Mousavirad *et al.*(2020)에서는 15개의 메타휴리스틱 알고리즘을 인공지능경망에 적용하여 8가지의 UCI 분류 데이터 셋에

서의 분류 정확도를 평가하였다. 실험결과에 따르면 군집 지능 알고리즘의 평균 성능은 5.8위, 자연 발견적 알고리즘은 8.8위, 진화적 알고리즘과 물리 기반 알고리즘은 각 9.5위와 11위로 집계되었으며, 군집 지능 알고리즘이 평균적으로 가장 좋은 성능을 보였다. 이는 집단적 행동을 하는 개체들을 통해 지능적인 전체 행동을 도출해내는 군집 지능 알고리즘의 특징에 기인한다. 이러한 특징 때문에, 군집 지능 알고리즘은 국소 최적해 탈출의 가능성을 높일 수 있으며, 우수하고 다양한 해를 도출할 수 있게 된다(Yang *et al.*, 2016).

한편, 군집 지능 알고리즘은 연속적인 해의 형태로 표현되는 문제에 적용하기 수월하므로 인공지능경망 가중치 최적화에 적용하기 적합하다. 따라서 본 연구에서는 다양한 메타휴리스틱 알고리즘 중 군집 지능 알고리즘을 연구 대상으로 선정하였다.

### 2.2 인공지능경망에 대한 군집 지능 알고리즘의 적용 연구

Kayarvizhy *et al.*(2014)은 인공지능경망에 군집 지능 알고리즘을 적용하여 객체 지향 시스템에서의 결함을 예측하였다. 실험에 사용된 군집 지능 알고리즘은 PSO와 ABC, FA(firefly algorithm; Yang, 2009) 그리고 ACO(ant colony optimization; Dorigo, 2006)이었으며, 모두 수렴속도와 정확도 측면에서 경사 하강법을 이용한 오차 역전파 학습법을 상회하는 성능을 보였다. Gundu and Simon(2021)은 인공지능경망의 한 종류이자, 딥러닝 기반 시계열 예측 기법인 LSTM에 PSO를 적용하여 기존의 기법보다 더 낮은 예측 오차로 전기 에너지 가격을 예측하였다. 상기 연구는 군집 지능 알고리즘을 인공지능경망의 가중치 최적화에 도입함으로써 군집 지능 알고리즘의 가능성을 확인하였다는 것에서 의의가 있으나, 인공지능경망 학습에 일반적으로 사용되는 고성능의 경사하강법인 Adam과는 비교하지 못했다는 한계가 존재한다.

PSO-GSA는 PSO와 물리 기반 알고리즘인 GSA(gravitational search algorithm)를 결합한 하이브리드 메타휴리스틱 알고리즘으로써(Mirjalili and Hashim, 2010), 이를 인공지능경망에 적용하면 PSO와 GSA보다 더 빠른 수렴속도와 높은 분류 정확도를 얻을 수 있었다(Mirjalili *et al.*, 2012). 그러나 Mosavi *et al.*(2016)의 실험에서는 인공지능경망의 분류 정확도 측면에서 PSO-GSA의 최적화 성능이 GWO를 밀도는 결과를 보였다는 점에서 한계가 존재했다.

또한, 메타휴리스틱의 가장 큰 특징점인 국소 최적해 탈출 능력은 오히려 검증 데이터에서의 수렴 불안정성을 초래할 수 있는 문제가 존재한다(Halim *et al.*, 2021). 이는 국소 최적해를 탈출하는 과정에서 가중치가 크게 뒤바뀌며 검증 데이터에서 의 해의 수렴이 방해되기 때문이다.

따라서 본 연구에서는 검증 데이터에서의 수렴 불안정성을 해결하는 장치를 고안하고, 기존연구에서 가능성을 보인 PSO에 PSO-GSA보다 더 높은 최적화 성능을 보였던 GWO를 결합함으로써 인공지능경망의 가중치를 더욱 효과적으로 최적화하는




Figure 1. Search Process of PSO



Figure 2. Search Process of GWO

하이브리드 메타휴리스틱 알고리즘을 제안한다. 또한, 이를 Adam과 같은 고성능의 경사 하강법과 비교하여 효용성을 검증함으로써 기존의 연구가 가진 한계점을 보완하고자 하였다.

### 2.3 PSO와 GWO의 해 탐색 과정

PSO는 새나 벌레 등이 무리를 지어 행동하는 패턴에서 착안된 메타휴리스틱 알고리즘으로써 많은 최적화 연구에서 그 효용성을 입증하였다(Kameyama, 2009). 입자(particle)는 개별 해로, 군집(swarm)은 해집단에 대응되며, 각 입자는 그들 자신과 이웃 입자의 경험을 이용하여 최적의 위치를 찾기 위해 다차원 공간을 이동한다. 각 입자는 위치와 속도를 가지며, 다차원 공간상의 위치에 따라 적합도(fitness)라는 평가 값을 부여받는다. 각 입자는 적합도가 더 높은 곳으로 이동하기 위해 <Figure 1>과 같이 세 가지를 참고하여 다음 위치로 이동한다. 입자가 가지고 있던 관성(inertia), 각 입자가 반복을 통해 발견한 입자 최적해, 그리고 군집 내에서 발견된 전체 최적해가 이에 해당한다(Jain *et al.*, 2008). 이러한 일련의 과정을 반복하다가 종료 조건에 도달하면 군집 내의 전체 최적해를 반환하게 된다.

GWO는 회색 늑대 무리의 사회적 계층 및 사냥 방식을 모사하여 전역 최적해를 탐색한다. GWO 또한 선행 연구의 다양한 최적화 과제에서 우수한 성과를 보였다(Panda and Das, 2019). PSO와 마찬가지로 각 늑대는 개별 해에 대응되며, 적합도에 따라 계층 내의 계급을 부여받는다. 가장 적합도가 높은 늑대부터 순서대로 알파, 베타, 델타 늑대가 된다. 모든 늑대는 전역 최적해에 해당하는 먹잇감을 쫓기 위해 적합도가 더 높은 곳으로 이동한다. 이때 <Figure 2>와 같이 알파, 베타 그리고 델타 늑대를 참고하여 위치를 갱신한다(Mosavi *et al.*, 2016). 매 반복마다 해의 계급이 새롭게 부여되며, 종료 조건에 도달하면 알파 늑대의 해가 최종해가 된다.

## 3. 제안 알고리즘

### 3.1 수렴양상의 특징을 이용한 알고리즘 설계

PSO와 GWO를 결합한 하이브리드 메타휴리스틱 알고리즘을 설계하기 위해 PSO와 GWO의 수렴양상을 비교하여 각 알고리즘의 특징을 도출하였다. <Figure 3>은 PSO와 GWO의 수렴양상을 비교한 그래프로서, PSO는 초기 수렴성이 매우 뛰어나고, GWO는 탐색력 및 국소 최적해 탈출 성능이 더 좋다는 특징을 발견하였다.

이를 통해 고안된 제안 알고리즘은 초기 수렴성이 뛰어난 PSO를 통해서 초반부 탐색을 진행하고, 전환점에 도달하면 탐색력이 우수한 GWO로 전환하여 진행함으로써 각 알고리즘의 특징이 극대화되도록 설계하였다. 즉, 제안 알고리즘은 2단계로 구성되어 있고 단계의 전환을 결정하는 전환점은 초매개

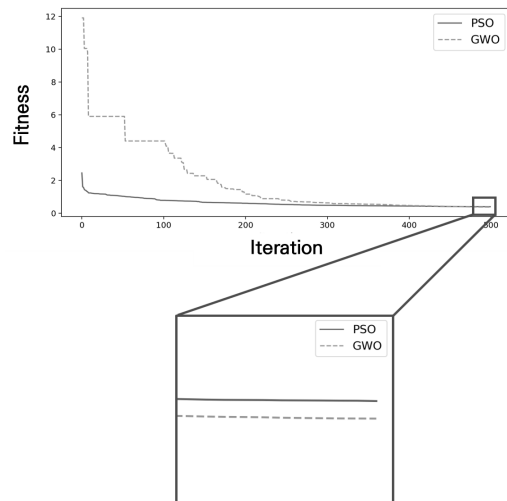


Figure 3. Comparison of Convergence Aspects of PSO and GWO

변수(hyper-parameter)로 조정된다. 초매개변수는 [0, 1]의 값을 가지며 전체 반복수와의 곱으로 전환점이 결정된다. 본 연구에서는 해당 값을 0.1로 하여 전환점을 설정하였다. 만약, 초기 수렴성이 중요한 문제라면 초매개변수를 더 큰 값으로 설정함으로써 제안 알고리즘의 초기 수렴성을 강화할 수 있다.

### 3.2 해 탐색 과정

본 절에서는 제안 알고리즘이 인공신경망의 가중치를 탐색하는 과정을 기술하며 <Figure 4>는 이를 그림으로 나타낸 것이다. 제안 알고리즘은 먼저 인공신경망의 가중치를 하나의 해로 규정하고, 이를 해집단의 크기만큼 무작위로 초기화하여 해집단을 구성한다. 이후, 적합도 함수를 통해 해의 적합도를 산출하여 PSO 탐색에 필요한  $pbest_i$ 와  $gbest$ 를 설정한다.  $pbest_i$ 는 각 해집단의  $i$ 번째 입자가 경험했던 최고 적합도 해의 위치이며,  $gbest$ 는 군집 전체의 경험에서 가장 적합도가 높았던 해의 위치를 나타낸다. 이는 <Figure 4>의 [Generate Weights] 단계에 해당하며 인공신경망의 가중치를 단일의 해로 표현하는 방법과 적합도 평가함수는 3.3에서 기술한다.

이후 단계인, [Search Weights] 단계에서는 전환점 도달 여부에 따라 PSO 혹은 GWO를 이용하여 탐색한다. PSO phase에서는 (1)의 수식을 통해 다음 시점  $i$ 번째 입자의 이동 속도  $V_i(t+1)$ 를 구하고, (2)의 수식을 따라  $i$ 번째 입자의 다음 시점 위치인  $X_i(t+1)$ 를 계산한다.  $w$ 와  $c_1, c_2$ 는 초매개변수이

며,  $r_1, r_2$ 는 [0, 1]의 무작위 값을 갖는다.

$$V_i(t+1) = w \cdot V_i(t) + c_1 \cdot r_1(pbest_i(t) - X_i(t)) + c_2 \cdot r_2(gbest(t) - X_i(t)) \tag{1}$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \tag{2}$$

GWO Phase에서는 (3), (4) 그리고 (5)의 수식에 따라  $X_i(t+1)$ 가 갱신된다.  $X_\alpha$ 와  $X_\beta, X_\delta$ 는 각각 알파, 베타 그리고 델타 늑대의 해를 나타내며 이들은 매 탐색마다 적합도 기준 상위 3개의 해로 결정된다.  $A$ 와  $C$ 는 각각 계수 벡터이며, (6)의 수식에서 설명된다.  $r_1, r_2$ 는 [0, 1]의 무작위 값이며,  $a$ 는 매 반복마다 2부터 0까지 선형적으로 감소하는 값이다.

$$\begin{cases} D_\alpha(t) = |C_1 \cdot X_\alpha(t) - X_i(t)| \\ D_\beta(t) = |C_2 \cdot X_\beta(t) - X_i(t)| \\ D_\delta(t) = |C_3 \cdot X_\delta(t) - X_i(t)| \end{cases} \tag{3}$$

$$\begin{cases} X_1 = X_\alpha(t) - A_1 \cdot D_\alpha(t) \\ X_2 = X_\beta(t) - A_2 \cdot D_\beta(t) \\ X_3 = X_\delta(t) - A_3 \cdot D_\delta(t) \end{cases} \tag{4}$$

$$X_i(t+1) = \frac{X_1 + X_2 + X_3}{3} \tag{5}$$

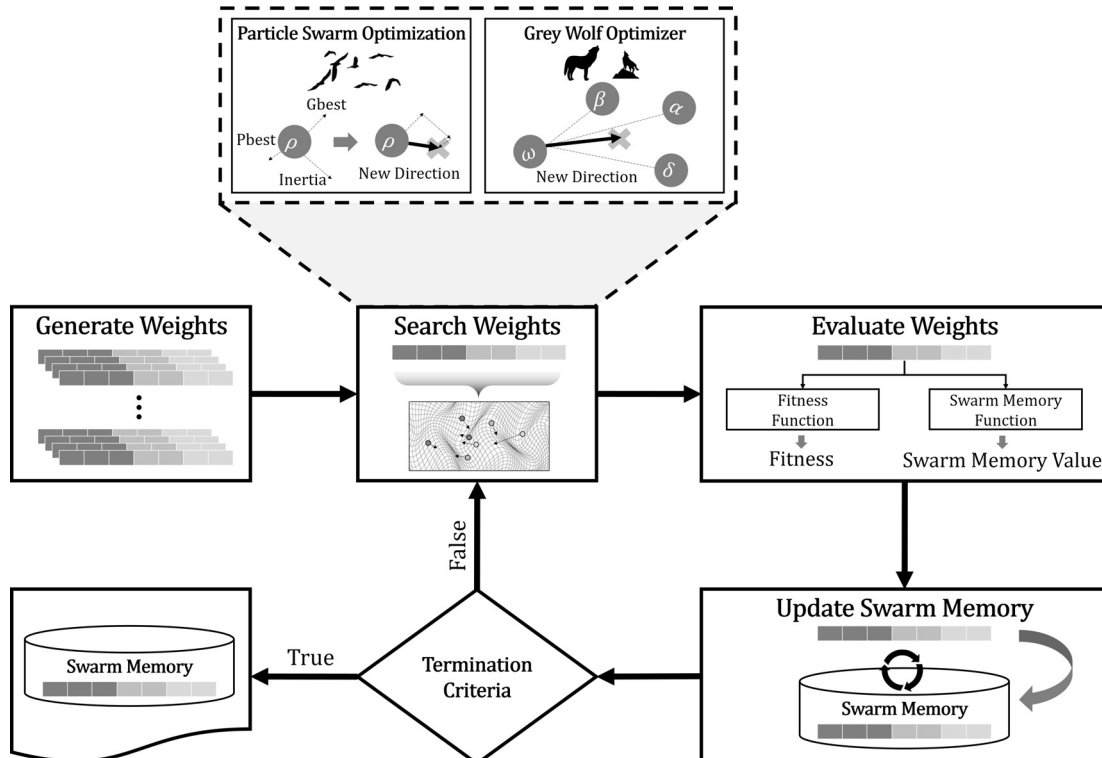


Figure 4. Proposed Framework for the Weight Optimization of Artificial Neural Networks

$$A = 2a \cdot r_1 - a \quad (6)$$

$$C = 2 \cdot r_2$$

해의 갱신이 모두 끝났다면 [Evaluate Weights] 단계로 진행하여 업데이트된 해를 평가한다. 이 때 적합도 함수를 통해 적합도를 다시 산정하는 것 외에도 본 연구에서 제안하는 군집 기억 함수(swarm memory function)를 이용하여 군집 기억 값(swarm memory value)을 계산한다. 이렇게 계산한 군집 기억 값은 다음 단계인 [Update Swarm Memory] 단계에서 군집 기억(swarm memory)을 갱신하는데 사용된다. 군집 기억과 군집 기억 함수 및 군집 기억 값에 대한 설명은 3.4에서 자세히 기술한다. 위 과정을 반복하다가 정해진 종료 조건에 도달하면 최종적으로 군집 기억에 저장되어 있던 해가 결과로 출력됨으로써 제안 알고리즘이 종료된다.

### 3.3 해 표현과 적합도 함수

인공신경망의 가중치를 단일의 해로 표현하기 위해 각 가중치와 편향(bias)을 순서대로 나열하여 1차원의 배열로 표현하였다. 이는 <Figure 5>에 표현되어 있다.

이렇게 표현된 해를 평가하기 위한 적합도 함수는 인공신경망의 가중치를 해로 동기화하고 훈련 데이터 셋을 입력시켜서 산출한 훈련 오차(training loss)를 사용하였다. 오차 함수는 인공신경망이 해결하고자 하는 과업에 따라 달라지며, 본 연구에서는 분류 과업을 수행하기 때문에 교차 엔트로피(cross-entropy)를 사용한다.

### 3.4 군집 기억

군집 기억은 검증 데이터 셋에서의 수렴 불안정성 문제를 해결하기 위해 군집이 생존하기 적합했던 환경이나 장소를 기억하는 현상에서 착안한 장치이며, 하나의 해를 기억하는 버퍼 장치이다. 군집 기억의 갱신 여부를 결정하기 위해 검증 데이터 셋에서의 해의 성능인 군집 기억 값과 이를 측정하는 군집 기억 함수를 도입하였다.

군집 기억 함수는 적합도 함수에서 훈련데이터 셋이 아닌 검증 데이터 셋을 이용한다는 차이점만 존재하며, 군집 기억 함수를 통해서 측정된 검증 데이터 셋에서의 오차는 군집 기

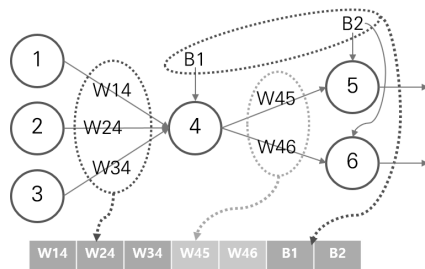


Figure 5. Solution Representation

억 값이 된다. 매 탐색마다 군집 기억 함수를 통해 군집 기억 값을 측정하고, 군집 기억의 군집 기억 값과 비교함으로써 더 좋은 품질의 해를 찾았다면 군집 기억에 해당 해를 갱신한다. 종료 조건에 도달하여 탐색이 끝나면 최종적으로 군집 기억에 저장된 해를 출력한다. 군집 기억을 사용하면 검증 데이터 셋에서의 수렴 불안정성이 발생하더라도 가장 최고 성능의 해가 저장되어 출력되기 때문에 결과의 분산이 감소하고 성능이 향상된다는 장점이 있다.

## 4. 실험

### 4.1 실험 설계 및 평가 방법

제안 알고리즘의 인공신경망 가중치 최적화 성능을 평가하기 위해 UCI machine learning repository(Dua and Graff, 2019)에서 공개된 다섯 가지의 분류 데이터 셋에 대해 분류 성능을 측정하였다. 각 데이터 셋의 정보는 <Table 1>에 기술되어 있다.

각 데이터 셋 별 인공신경망의 구조는 다수의 층에서도 효과적인지 검증하기 위해 은닉층이 2개 존재하는 완전 연결 신경망(fully-connected neural network)으로 구성하였으며, 은닉층 노드의 수는 각 데이터 셋의 크기와 입력층 노드의 수를 고려하여 편성하였다. 인공신경망의 활성화 함수로는 비선형 함수인 ReLU와 다중 분류를 위한 softmax를 사용하였다. 인공신경망에 입력되는 데이터들은 평균 0, 표준 편차 1로 스케일링되었으며, 인공신경망 가중치는 균등분포 [-1, 1]의 확률분포로 초기화하였다.

제안 알고리즘을 기존의 메타휴리스틱 알고리즘 및 경사 하강법과 비교하기 위해, 각 방법으로 인공신경망의 가중치를 최적화하는 실험을 20회 진행하여 산출된 분류 정확도의 평균 값을 비교하였다. 학습을 위한 반복 수는 모두 500회로 설정하였으며, 비교를 위한 경사 하강법은 SGD와 Adam을 채택하였다. 또한, 분류 정확도 곡선(accuracy curve) 비교를 통해서 제안 알고리즘의 장점인 빠른 수렴 능력과 국소 최적해 탈출 성능 및 군집 기억의 수렴 불안정성 해결 능력을 검증하였다. <Figure 6>는 분류 정확도 비교 실험 결과를 나타내며, 분류 정확도 곡선은 <Figure 7>와 <Figure 8>에 표현되어 있다. <Figure 7>는 제안 알고리즘을 기존의 군집 지능 알고리즘과 비교한 것이며, <Figure 8>는 제안 알고리즘을 경사 하강법과 비교한 것이다. <Table 2>는 각 알고리즘이 실험에서 소요된 계산 시간의 평균값을 비교한 것이다.

Table 1. Descriptions of Experiment Datasets

	Iris	Seeds	Telescope	Satellite	Bean
Samples	150	210	19,020	6,435	13,611
Features	4	7	10	36	15
Labels	3	3	2	6	7

4.2 실험 결과

<Figure 6>를 통해 실험에 사용된 모든 군집 지능 알고리즘은 SGD보다 더 높은 최적화 성능을 지닌 것으로 나타났으며, 제안 알고리즘으로 최적화한 인공신경망은 기존의 군집 지능 알고리즘인 GWO와 PSO로 최적화한 인공신경망보다 더 높은 분류 정확도를 보이는 것이 검증되었다. 특히, 제안 알고리즘은 전체 5개의 데이터 셋 중 4개의 데이터 셋에서 Adam보다 높은 정확도를 기록하였으며, 실험에 사용된 모든 최적화 알고리즘 중에

서 가장 높은 성능을 나타내는 것으로 검증되었다.

또한, <Figure 7>에서는 PSO의 초기 수렴성과 GWO의 국소 최적해 탈출 능력이 제안 알고리즘에서 동시에 나타나는 것으로 확인되었으며, 각 특징이 상호 보완적인 양상을 띠며 긍정적인 효과를 끌어내는 것으로 확인되었다. <Figure 8>에서 볼 수 있듯이 제안 알고리즘은 경사 하강법보다 가파르게 분류 정확도가 상승한 것에서 초기 수렴성이 매우 강하다는 것을 확인할 수 있으며, 전환점 이후 국소 최적해 탈출을 통해 정확도가 크게 향상되는 것으로 확인되었다. 추가적으로, 최대 반




Figure 6. Classification Accuracy Results for All Algorithms

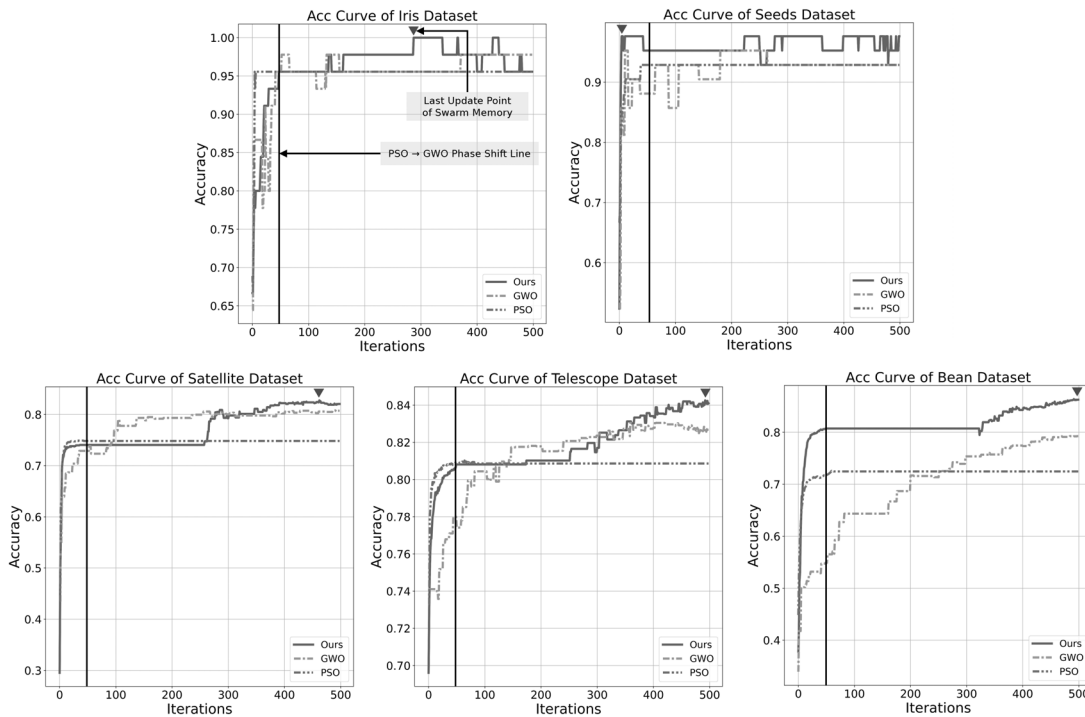


Figure 7. Comparisons of Accuracy Curve for Proposed Algorithm, GWO and PSO

Table 2. Comparisons of Computation Time (sec) for All Algorithms

	Ours	PSO	GWO	SGD	Adam
Iris	3.341	7.804	3.001	0.397	0.516
Seeds	3.811	8.685	3.534	0.424	0.550
Telescope	22.081	46.803	17.956	3.370	3.848
Satellite	41.329	92.313	35.183	2.828	3.056
Bean	55.857	128.059	53.365	5.298	5.578

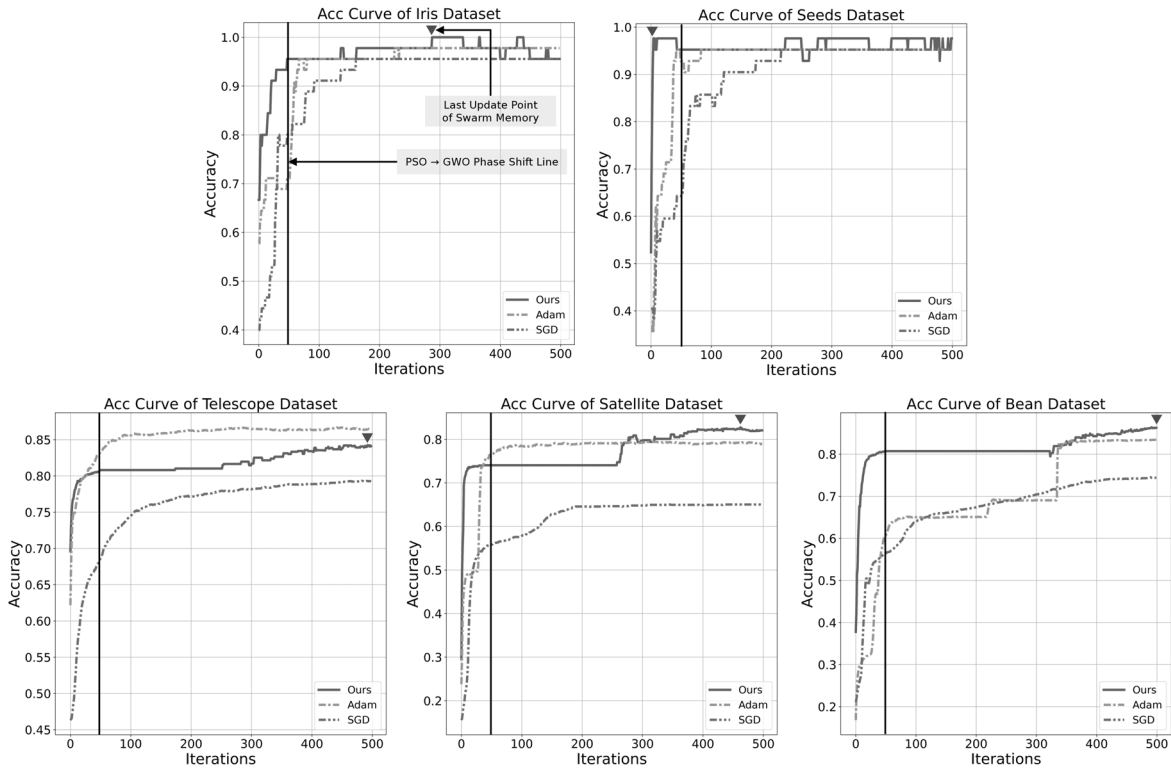


Figure 8. Comparisons of Accuracy Curve for Proposed Algorithm, SGD and Adam

복헝수 이전에 나타나는 최고 성능의 해가 군집 지능에 저장됨으로써, 수렴 불안정성 문제가 해결되며 성능 향상에도 영향을 미치는 것을 확인할 수 있었다.

그러나 <Table 2>에 의하면 제안 알고리즘은 경사 하강법에 비해 매우 긴 계산 시간이 소요되는 것으로 관찰되었다. 이는 메타휴리스틱 알고리즘의 높은 계산 복잡성에도 기인하지만, 경사 하강법이 컴퓨터 공학적으로 최적화된 라이브러리로 구현되었기 때문에 더 큰 격차를 발생시킨 것으로 보인다.

### 5. 결론

본 논문은 군집 지능 알고리즘인 PSO와 GWO를 결합한 2단계의 하이브리드 메타휴리스틱 알고리즘을 제안하였으며, 검증 데이터 셋에서의 수렴 불안정성 문제를 해결하기 위해 군집 기억이라는 방법을 도입하였다. 제안 알고리즘으로 최적화한 인공신경망은 분류 정확도 측면에서 기존의 군집 지능 알고리즘 및 SGD를 상회하는 결과를 보였으며, Adam과는 5개의 데이터 셋 중 4개의 데이터에서 더 좋은 성능을 보였다. 본 연구는 선행 연구의 한계점으로 지목되었던 고도화 연구 부족 및 Adam과의 비교 연구 미흡을 보완하였으며, 메타휴리스틱이 경사 하강법을 대체하거나 보완할 수 있다는 가능성을 확인하였다는 것에 의의가 있다.

그러나 본 연구는 아직 다양한 종류의 메타휴리스틱 알고리즘과의 결합 가능성이 남아 있으며, Adam과 비교했을 때 계산

시간이 더 많이 필요하다는 한계가 존재했다. 향후 연구에서는 군집 지능 알고리즘 뿐 아니라 더 다양한 영역의 메타휴리스틱 알고리즘까지 확대하여 제안 알고리즘을 고도화할 계획이며, 제안 알고리즘에 분산처리 및 알고리즘 최적화를 적용하여 긴 계산 시간을 단축시킬 것이다.

### 참고문헌

Dauphin, Y., Pascanu, R., Gulcehre, C., Cho, K., Ganguli, S., and Bengio, Y. (2014), Identifying and attacking the saddle point problem in high-dimensional non-convex optimization, arXiv preprint, arXiv: 1406.2572.

Dhiman, G. and Kaur, A. (2018), Optimizing the design of airfoil and optical buffer problems using spotted hyena optimizer, *Designs*, **2**(3), 28.

Dua, D. and Graff, C. (2019), *UCI Machine Learning Repository* [http://archive.ics.uci.edu/ml]. Irvine, CA: University of California, School of Information and Computer Science.

Dorigo, M., Birattari, M., and Stutzle, T. (2006) Ant colony optimization, *IEEE Computational Intelligence Magazine*, **1**(4), 28-39.

Gundu, V. and Simon, S. P. (2021), PSO-LSTM for short term forecast of heterogeneous time series electricity price signals, *Journal of Ambient Intelligence and Humanized Computing*, **12**(2), 2375-2385.

Halim, A. H., Ismail, I., and Das, S. (2021), Performance assessment of the metaheuristic optimization algorithm: An exhaustive review, *Artificial Intelligence Review*, **54**(3), 2323-2409.

Huh, J.-S. and Park, J.-H. (2019), Artificial neural network based

- multi-objective rule selection dispatcher for re-entrant multiple-chip product assembly lines, *The Journal of Korean Institute of Information Technology*, **17**(2), 1-11.
- Jain, N. K., Nangia, U., and Jain, J. (2018), A review of particle swarm optimization, *Journal of The Institution of Engineers (India)*, Series B, **99**(4), 407-411.
- Kameyama, K. (2009), Particle swarm optimization-a survey, *IEICE Transactions on Information and Systems*, **92**(7), 1354-1361.
- Kang, B-S. and Kim, S-S. (2017), Combined artificial bee colony for data clustering, *Journal of Society of Korea Industrial and Systems Engineering*, **40**(4), 203-210.
- Kayarvizhy, N., Kanmani, S., and Uthariaraj, R. V. (2014), ANN models optimized using swarm intelligence algorithms, *WSEAS Transaction on Computers*, **13**(45), 501-519
- Kennedy, J. and Eberhart, R. (1995), Particle swarm optimization, In *Proceedings of ICNN 95-international conference on neural network*, **4**, 1942-1948
- Kingma, D. P. and Ba, J. (2014), Adam: A method for stochastic optimization, arXiv preprint, arXiv:1412.6980.
- Mirjalili, S. and Hashim, S. Z. M. (2010), A new hybrid PSO-GSA algorithm for function optimization, *International Conference on Computer and Information Application*, 374-377
- Mirjalili, S., Hashim, S. Z. M., and Sardroudi, H. M. (2012), Training feedforward neural networks using hybrid particle swarm optimization and gravitational search algorithm, *Applied Mathematics and Computation*, **218**(22), 11125-11137
- Mirjalili, S., Mirjalili, S. M., and Lewis, A. (2014), Grey wolf optimizer, *Advances in Engineering Software*, **69**, 46-61.
- Minnema, J., van Eijnatten, M., Kouw, W., Diblen, F., Mendrik, A., and Wolff, J. (2018), CT image segmentation of bone for medical additive manufacturing using a convolutional neural network, *Computers in Biology and Medicine*, **103**, 130-139.
- Mosavi, M. R., Khishe, M., and Ghamgosar, A. (2016), Classification of sonal data set Using neural network trained by Gray Wolf Optimization, *Neural Network World*, **26**(4), 393.
- Mousavirad, S. J., Schaefer, G., Jalali, S. M. J., and Korovin, I. (2020), A benchmark of recent population-based metaheuristic algorithms for multi-layer neural network training, In *Proceedings of the 2020 Genetic and Evolutionary Computation Conference Companion*, 1402-1408
- Mun, S-E., Jang, S-B., Lee, J-H., and Lee, J-S. (2016), Technology trends in machine learning and deep learning, *Information and Communications Magazine*, **33**(10), 49-56.
- Panda, M. and Das, B. (2019), Grey wolf optimizer and its applications: a survey, In *Proceedings of the Third International Conference on Microelectronics, Computing and Communication Systems*, 179-194
- Qi, S., Jin, K., Li, B., and Qian, Y. (2020), The exploration of internet finance by using neural network, *Journal of Computational and Applied Mathematics*, **369**, 112630
- Robbins, H. and Monro, S. (1951), A stochastic approximation method, *The Annals of Mathematical Statistics*, 400-407.
- Yang, X. S. (2009), Firefly algorithm for multimodal optimization, In *International Symposium on Stochastic Algorithm*, 169-178
- Yang, X. S., Deb, S., Fong, S., He, X., and Zhao, Y. X. (2016), From swarm intelligence to metaheuristics: Nature-inspired optimization algorithms, *Computer*, **49**(9), 52-59.

## 저자소개

**고광종** : 한국공학대학교에서 2022년에 IT경영학과와 컴퓨터공학전공의 학사학위를 취득하였다. 현재 고려대학교 산업경영공학과 석.박사통합과정에 재학 중이다. 연구분야는 메타휴리스틱과 기계학습을 이용한 제조시스템 최적화이다.

**허재석** : 서울대학교 산업공학과에서 2013년 학사, 2019년 산업공학 박사학위를 취득하였다. 현재 한국공학대학교 경영학부의 조교수로 재직 중이며, 2021년부터는 Gauss Labs Inc.의 자문교수로서 제조AI를 연구하고 있다. 연구분야는 제조 시스템 최적화, Scheduling/Dispatching, AI 산업응용이다.