

다중 인공 신경망의 Federated Architecture와 그 응용 - 선박 중앙단면 형상 설계를 중심으로

이경호*, 연운석**

Federated Architecture of Multiple Neural Networks : A Case Study on the Configuration Design of Midship Structure

Kyung-Ho Lee* and Yun-Seog Yeun**

ABSTRACT

This paper is concerning the development of multiple neural networks system of problem domains where the complete input space can be decomposed into several different regions, and these are known prior to training neural networks. We will adopt oblique decision tree to represent the divided input space and select an appropriate subnetworks, each of which is trained over a different region of input space. The overall architecture of multiple neural networks system, called the federated architecture, consists of a facilitator, normal subnetworks, and tile networks. The role of a facilitator is to choose the subnetwork that is suitable for the given input data using information obtained from decision tree. However, if input data is close enough to the boundaries of regions, there is a large possibility of selecting the invalid subnetwork due to the incorrect prediction of decision tree. When such a situation is encountered, the facilitator selects a tile network that is trained closely to the boundaries of partitioned input space, instead of a normal subnetwork. In this way, it is possible to reduce the large error of neural networks at zones close to borders of regions. The validation of our approach is examined and verified by applying the federated neural networks system to the configuration design of a midship structure.

Key words : Federated neural network, Oblique decision tree, Tile regions, Midship structure

1. 서 론

일반적으로 중앙단면 구조설계, 일반배치, 구획배치 설계, 선형설계 등을 포함하는 선박의 초기설계는 주어진 선주의 요구 조건에 따라 선박의 주요치수, 예를 들어 길이(LBP), 폭(B), 깊이(D), 형상계수(CB), 등을 결정하는 개념설계로부터 정보를 얻어 수행된다. 본 논문에서의 중앙단면은 선박 구조 중에서 중앙 평행부의 단면을 의미한다. 선박의 중앙 평행부는 선박 전체 길이의 70% 이상을 차지하므로 이 부분의 구조설계는 선박의 중량, 강도 등의 측면에서 매우 중요한 영향을 미친다고 할 수 있다. 이러

한 중앙단면을 결정하는 구조설계 작업은 단면의 형상 결정과 구조부재의 치수 결정 작업으로 나눌 수 있다. 단면형상 결정은 주로 개념설계로부터 결정된 배의 폭, 깊이 등의 주요치수를 바탕으로 이중저 높이, 탱크(호퍼 탱크, 원 탱크)의 형상 등을 결정하며, 부재 치수 결정 단계에서는 선박의 강도와 구조부재의 좌굴강도, 선급 규정 등을 고려한 판의 두께, 보강재 치수 등이 결정된다. 일반적으로 선박 중앙단면 형상설계는 만족시켜야 할 선급 규정들과 각종 제약 조건들을 설계시 쉽게 고려하기 위해서 지식기반에 의한 접근법이 많이 이루어져 왔다^[1]. 그러나 실제로 형상설계가 규칙과 같은 정형화된 지식에 의해 결정되지는 않고 주어진 상황과 조건에 따라 설계자의 주관적인 판단이 매우 중요한 요소로 작용한

*한국기계연구원 선박해양공학연구원 센터

**정희원, 대전대학교 기계설계공학과

다. 따라서 이를 고려한 기계학습에 의한 설계 시스템 구축 방법론이 대두되었다. 이 중에서 사례 기반 추론 기법(Case-Based Reasoning: CBR)은 과거의 유사 설계 사례를 바탕으로 새로운 문제의 해를 도출하는 기존의 설계 방법론과 유사하다는 점에서 유용한 방법이지만, CBR 기법의 가장 큰 장점이면서 또한 가장 해결하기 어려운 유사 사례를 주어진 문제에 맞게 adaptation을 수행해야 하는 문제를 안고 있다. 또 다른 방법론으로 많은 양의 설계 데이터의 학습으로부터 새로운 설계 해를 도출하고자 하는 인공 신경망은 알고리즘 자체가 매우 단순하지만 그 결과는 매우 유용하다. 그러나 일반적으로 중앙단면 형상설계에 있어서 입력 파라미터의 변화에 따라 설계 변수가 규칙적으로 결정되지는 않으며, 설계 구간 별로 많은 차이를 보임을 알 수 있다. 이러한 문제는 단순 인공 신경망을 이용한 학습보다는 설계 구간을 세분화하고 그 영역에 적합한 신경망 모델을 도입한 효과적인 학습을 통하여서 문제해결이 가능해진다.

본 논문에서는 앞서 언급한 구조설계의 두 가지 작업 중에서 중앙단면 형상설계에 초점을 맞추어, 중앙단면의 형상을 설계 초기 단계에 정확히 예측할 수 있도록 feed-forward neural network을 이용한 설계 지원 시스템을 개발하였다.

Feed-forward neural network은 모든 가능한 입력 값에 대해서 학습 데이터 세트를 바탕으로 출력 값에 정확히 매핑시켜 주는 근사적인 함수의 일종이라고 볼 수 있다. 일반적으로 학습 알고리즘은 신경망의 학습 오류(error)를 감소시킬 수 있는 목적 함수를 정의하고 이것을 최소화시키는 전형적인 최적화 문제에 해당된다. 그런데 신경망의 성능은 다양한 요인들로부터 영향을 받게 된다. 특히 실적선의 중앙단면 형상 데이터와 같이 문제 영역이 몇 개의 영역으로 구분되고, 각각의 영역은 서로 다른 패턴을 보일 때, 신경망의 성능은 크게 저하될 수 있다. 최근의 연구를 통하여 중앙단면의 형상설계를 위한 단독 신경망의 예측 성능은 유전적 프로그래밍(genetic programming)의 파서 트리(parser tree) 보다 떨어진다는 사실이 확인 되었다^[2]. 이러한 문제의 해결 방안으로 본 논문에서는 모듈화 된 신경망 시스템(modular neural network system)을 제안하였다.

2. Modular Neural Network System

최근 모듈화 된 혹은 다중 신경망에 대한 많은 연구가 수행되고 있으며, 신경망을 분할하고 재합성하

는 다양한 접근 방식이 제시 되고 있다^[3,9]. 이러한 접근 방식을 크게 두 가지로 대별해 볼 수 있는데, 첫째가 입력 공간(input space)을 몇 개의 작은 공간으로 세분화하는 것이고 둘째가 그렇지 않은 경우이다^[1]. 본 연구에서는 전자의 경우에 속하며, 입력 공간을 자동적으로 세분화하는 방법은 다루지 않고, 다중 신경망의 결과를 조합하여 최적의 결과를 도출할 수 있는 방안을 모색하였다. 모듈화 된 다중 신경망의 접근 방식은 신경망의 예측 성능을 향상시키고자 입력 데이터 영역(input space) 혹은 문제 대상을 적절히 세분화하고, 이렇게 세분화된 각각의 영역마다 해당하는 신경망을 학습 시키고 이들을 조합하여 최적의 결과를 얻고자 하는 "divide and conquer" 방식의 문제해결 전략이라고 할 수 있다.

본 논문에서는 문제를 단순화하기 위하여 각 신경망 모델이 하나의 출력 노드만을 갖고, 모든 학습 데이터는 실수(real number)인 경우로 제한하였다. 입력 데이터 영역은 선체설계 전문가의 지식을 통하여 몇 개의 작은 구간으로 세분화될 수 있고, 이에 따라서 각각의 작은 영역에 대응되는 subnetwork들의 집합으로 전체적인 다중 신경망 시스템이 구성된다. 이러한 시스템의 수행을 위한 필수적인 사항은 주어진 입력 데이터에 대하여 적절한 subnetwork를 선정할 수 있는 방안이 모색되어야 한다는 것이다. 이를 위해서 oblique decision tree를 이용하여 입력 데이터가 어느 영역에 속한지를 판별하고 이로부터 적절한 subnetwork를 선정하는 방안을 제시하였다. 비록 C 4.5^[10]와 같이 univariant decision tree가 가장 널리 사용되고 있지만 5 절에 설명되어 있듯이 local variable을 선정하기 위해서는 OC1과 같은 multivariant decision tree의 사용이 유리하다^[11,12].

본 논문의 접근 방식은 개념적으로 간결하고 시스템을 구현하기에도 매우 용이하다고 볼 수 있다. 그러나 이 방법은 decision tree의 예측 성능에 크게 의존하기 때문에 다음과 같은 문제점이 있다. 즉 입력 데이터가 분리된 영역의 경계 근처에 위치하면, decision tree의 예측이 틀릴 가능성이 매우 크고, 이에 따른 잘못된 subnetwork의 선정으로 인하여, 오히려 전체 입력 영역을 학습한 단독 신경망(single neural network)의 예측 오류보다 더 클 수 있다.

이를 해결하기 위한 하나의 방법으로 여기서는 경계선 주위 영역만을 학습시킨 tile network 개념을 도입하였다. 만일 입력 데이터가 세분화된 영역의 경계에 접근하면 일반적인 subnetwork 대신에 tile network를 사용하게 된다. 이러한 방식으로 전체 다중

신경망 시스템은 decision tree의 예측 성능에 비교적 큰 영향을 받지 않음과 동시에 전체적인 성능의 향상을 꾀할 수 있다.

본 논문에서는 크게 세 부분으로 나누어 학습 데이터로부터 tile 데이터를 생성하는 방법, multiple neural network 시스템의 통합 구조, modular neural network 시스템을 이용한 구조설계에의 적용 예에 대해서 다음 장부터 자세히 알아보도록 한다.

3. Decision Tree에 의한 Tile 데이터의 생성

선박의 구조 형상설계를 위한 학습 데이터 세트를 $X\{Y_i, O_i\}$ 라 할 때 $Y_i\{y_{i1}, \dots, y_{in}\}$ 는 선박의 주요치수(principal dimensions)와 설계 요구 조건을 나타내는 입력 값을 의미하며, $O_i\{o_i\}$ 는 설계하고자 하는 중앙단면의 구조부재를 나타내는 출력을 의미한다. 여기서 각각의 o_i 에 대해 도메인 지식(domain knowledge)에 기초한 클래스 라벨(class label) c_i 가 부여된다. 따라서 출력 집합 O 는 같은 클래스의 데이터를 포함하는 m 개의 subset(O_j)으로 나눌 수 있으며, 여기에 맞추어 학습 데이터 집합 X 도 m 개의 subset(X_j)로 세분화 된다.

본 연구에서는 설계하고자 하는 파라미터의 효과적인 추정을 위해서 설계 영역이 입력 공간의 어떤 영역에 속하는지를 먼저 찾아낸 다음, 그 영역에 맞게 학습된 subnetwork을 수행하여 결과를 얻게 된다. 여기서 학습 데이터의 영역이 어떤 영역에 속하는지를 알기 위해서 집합 $\{y_{i1}, \dots, y_{in}, c_i\}$ 을 대상으로 oblique decision tree을 생성하였다^[11]. 이 트리의 생성을 위하여 OC1이라는 귀납적 분류 시스템(inductive classification system)을 사용하였다. Fig. 1(a)는 2차원 공간에서 oblique decision tree에 의해 나누어진 입력 데이터 공간의 예이고 Fig. 1(b)는 decision tree의 구조를 보여 주고 있다. Fig. 1(b)에서 파악할 수 있듯이 주어진 데이터가 속한 영역 또는 클래스(class)를 판별하기 위해서 이 데이터의 값에 대한 hyperplane 식의 값을 계산하게 된다. 예를 들면, 만일 hyperplane F1의 값이 음수이면 이 데이터는 영역1에 속하고, 그렇지 않으면 다음 hyperplane F2의 값을 판정하게 된다. 이 과정이 데이터가 속한 영역이 파악될 때 까지 반복되는데, 만일 hyperplane의 값이 영(zero)에 근접하면 영역의 판별에 오류가 발생할 가능성이 매우 크다.

Fig. 1(a)에서 입력 점이 점A 근처에 주어졌을 때는 명백히 이 점은 영역4에 속함을 알 수 있으나 점




Fig. 1. A Partitioned input space by oblique decision tree in 2-D space. F1, F2, and F3 are hyperplane equations of decision tree.

B의 경우는 영역2에 속하는지 영역3에 속하는 지 판별하기 곤란하다. 더욱이 점C의 경우는 영역 1, 2, 또는 4 속할 수 있다. 이러한 문제를 해결하기 대안으로 다음과 같이 두 가지 방법을 고려해 볼 수 있다.

첫째는 Fig. 2와 같이 신경망을 분류된 영역뿐 아니라 hyper-plane을 따라 겹쳐진 영역까지 학습시키는 방법이다. 입력 데이터가 경계선 근처에 위치하여 decision tree의 예측이 틀릴 경우, 잘못된 subnetwork을 선정할 수 있지만 각각의 subnetwork은 이미 다른 영역의 경계까지 학습되어 있으므로 신경망의 오류를 줄여줄 수 있다. 그러나 이 방법은 mul-




Fig. 2. An overlapped region of partitioned input space.

multiple neural network system의 성능을 크게 저하시킬 수 몇 번의 실험을 통하여 확인 할 수 있었다.

둘째 방법은 tile 영역의 도입이다. 여기서 tile 영역은 분할된 입력 데이터 영역에서 모서리(edges)와 정점(vertexes)으로 구성된 hyper-plane 주위의 영역을 말하는 것으로 각각의 tile 영역에서 subnetwork의 일종인 tile network이 학습되어 사용된다. Fig. 3은 분할된 2차원 입력 공간에서 영역4 주위에 정의된 tile 영역의 예를 보여주고 있다. 영역4 주위에는 그림과 같이 3개의 tile 영역이 존재하고, 이들 각각에 대해서 학습된 신경망 모델이 존재한다. Fig. 3 (b)에서 알 수 있듯이 tile 영역은 d_1, d_2, d_4, d_4' 등을 사용하여 정의해 주고 있다. 앞에서 설명되어 있듯이 decision tree는 hyperplane 식의 값을 계산을 통하여 데이터가 속한 영역 또는 클래스를 판별하는데, $d_i(i=1, 2, 4)$ 의 크기는 학습 데이터에 대한 hyperplane 식의 값을 계산하고 이것을 토대로 결정할 수 있다. 만일 주어진 데이터에 대한 hyperplane 식의 절대값이 d_i 보다 작으면 이 데이터는 tile 영역에 속하게 된다. d_i 의 크기를 산정하기 위해서 0에서 1 사이의 값을 갖는 두 종류의 gating ratio인 R과 B를 도입하였다. Fig. 3(b)에 표시된 d_1, d_2, d_4 의 크기는 각각 $R \cdot N_i(i=1, 2, 4)$ 값을 기준으로 결정할 수 있다. 여기서 N_i 는 영역1, 2, 4에 속한 학습 데이터의 수를 의미한다. 즉 $R \cdot N_i$ 의 반올림한 정수 값 $n_i(\text{round}(R \cdot N_i))$ 는 N_i 영역에 속한 학습 데이터 중 tile 영역에 포함될 데이터의 수가 된다. 이때 N_i 에 속한 모든 학습 데이터에 대하여 hyperplane 식의 절대값 계산하고, 이 값을 올림차 순으로 소팅(sorting)한다. 소팅된 이 값들 중 n_i 번째 값이 바로 d_i 의 크기가 된다. 이와 마찬가지로 d_4' 의 크기도 $B \cdot N_4(N_4$ 는 영역4의 학습 데이터 수) 값을 이용하여 구할 수 있다. Gating ratio B는 입력 데이터가 Fig. 3 (b)의 점 P와 같은 정점 주위에 주어져 두 개의 영역 이상에 속하게 될 때 사용됨으로 통상적으로 R 보다는 큰 값을 갖게 된다. 이러한 gating ratio의 결정은 주어진 응용 도메인과 분할된 입력 데이터 영역의 특성에 따라서 그 값을 적절히 선정해야 한다. 만일 입력 데이터 영역이 2차원 이상일 경우에는 앞서 언급한 방법과 유사하게 tile 영역을 나누지만 모서리나 정점으로 인한 복잡성 때문에 이를 위한 특별한 고려가 이루어져야 한다. 입력 데이터가 주어질 때, 항상 이 데이터가 세 분된 영역의 경계에 근접하는지 검사하고, 충분히 경계에 접근되어 있다고 판단되면 일반 subnetwork 대신에 해당 tile network을 수행하여 그 결과를 얻게




Fig. 3. Three "Tile" regions around a Region 4.

된다. 본 논문에서는 tile network을 채용한 다중 인공 신경망 시스템을 구축하고 중앙단면의 configuration 설계에 적용하여 본 방법의 유용성을 검증하였다.

4. Multiple Neural Network 구성을 위한 연합 구조(Federated Architecture)

Decision tree와 연합된 다중 인공 신경망 시스템의 전체 구조는 Fig. 4에 나타나 있다.

Fig. 4에서 facilitator는 decision tree와 적절한 tile network과 subnetwork을 선정하기 위한 프로그램 코드로 구성되어 있다. 입력 데이터가 주어지면, 이것은 먼저 facilitator에 전달된다. Facilitator는 decision tree를 이용하여 이 데이터가 속할 영역을 판정 한다.




Fig. 4. A federated architecture of multiple neural networks.

이때 동시에 이 데이터가 분할된 영역의 경계에 근접하고 있는 지, 즉 tile 영역에 포함되어 있는 지를 decision tree에서 생성된 정보를 사용하여 검토한다. 만일 경계에 충분히 접근하고 있다고 판단되면, 데이터는 해당 tile network에, 그렇지 않으면 해당 subnetwork에 전달된다. 그리고 데이터를 전달 받은 tile network 또는 subnetwork은 그 수행 결과를 facilitator에 전달하게 된다. 이러한 구조는 최근 들어 인공지능 분야에서 대두되고 있는 에이전트 시스템^(13,14)과 매우 유사한 구조를 갖고 있다. 신경망의 연합 시스템에서 facilitator의 역할도 에이전트 시스템의 facilitator 역할과 매우 비슷하다. 연합 신경망의 구조는 reflective agent 시스템⁽⁵⁾과 비교를 통해서도 그 특성을 파악할 수 있다. Reflective agent는 Worker와 Monitor로 구성된다. Worker들은 세분된 입력 공간 중 한 영역을 담당하는 신경망들이고, Monitor는 일종의 분류 신경망(classification neural network)으로 입력 데이터가 주어질 때, Work의 출력에 대한 신뢰도(confidence)를 산정한다. 즉 신뢰도가 가장 크게 산정된 Worker의 출력 값이 최종 reflective agent 시스템의 출력 값이 된다. 그런데 reflective agent 시스템 내에서는 Worker와 Monitor 간의 conflict가 발생할 가능성이 항상 존재한다. 신경망의 연합 구조에서 tile network을 포함한 모든 subnetwork은 Monitor와 같은 self-reflective 메커니즘을 갖고 있지 않다. 그 반면에 facilitator가 적절한 subnetwork을 선정하는 기능을 갖고 있다. Facilitator에서는 주어진 입력 값에 대응하는 subnetwork을 선정해 주기 위한 oblique decision tree의 정보들이 저장되어 있으며, 또한 경계선 근처에 주어진 입력 값에 대해서 적절한 tile network을 찾아주는 역할도 담당한다. 이렇게 함으로써 잘못된 subnetwork의 선정으로 인한 인공 신경망의 큰 예측 오류(error)를 감소시킬 수 있다. 여기서 알 수 있듯이 tile network의 도입은 본 연구의 핵

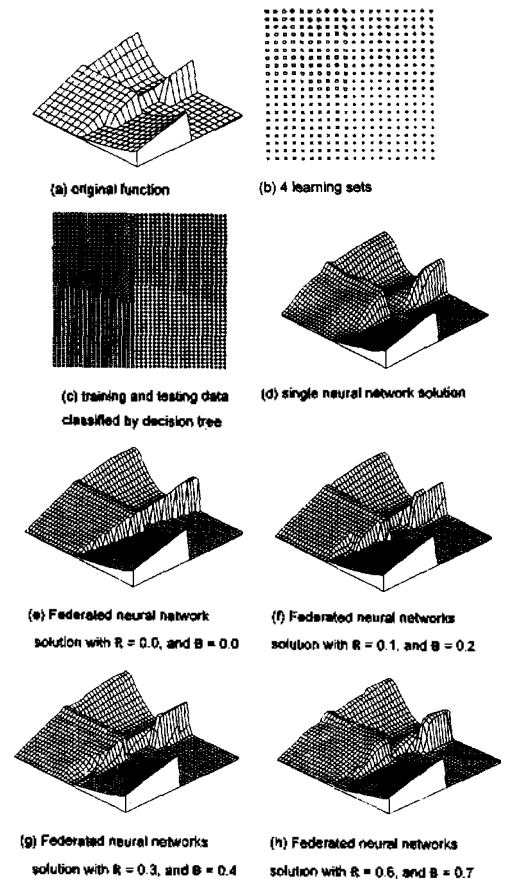


Fig. 5. Solutions of the federated neural networks.

심적인 사항 중에 하나이다. tile network의 정확도는 주어진 문제 영역과 gating ratio, 학습 데이터 수, 분할된 영역 수, 등의 다양한 요인에 영향을 받을 수 있다. 연합 신경망의 성능을 검증하기 위해서 Fig. 5와 같이 입력 공간이 4개의 패턴으로 명확하게 구분되는 함수에 대하여 400개의 학습 데이터와 1200개의 테스트 데이터를 사용하여 gating ratio의 변화에 따른 연합 신경망의 거동을 살펴 보았다. Fig. 5 (a)는 학습시키고자 하는 원래 함수이고, (b)는 학습을 위한 4개의 영역으로 구분된 데이터 집합이다. 이러한 분할된 데이터 영역에서의 연합 신경망 시스템을 구축하기 위해서는 4개의 영역에서 각각 학습된 4개의 subnetwork와 8개의 tile network이 필요하다. 또한 facilitator와 tile network을 구축하기 위해서는 decision tree가 필요한데, 학습 데이터 중에서 30%를 임의로 선택하여 생성된 decision tree의 크기를 적절히 감소시켰다. 학습된 decision tree의 크기를 줄이는 이 과정은 decision tree의 과다 학습을 방지하여

Root Hyperplane $1.000000 \times [1] + 9.500000 = 0$ l Hyperplane $0.050121 \times [1] + 0.150818 \times [2] + 1.657906 = 0$ r Hyperplane $0.0225339 \times [1] + 0.076175 \times [2] + 1.091229 = 0$

Fig. 6. Oblique decision tree generated by OC1.

예측 성능을 향상 시키기 위한 방법으로 흔히 pruning 과정이라고 불리운다. Fig. 5(c)는 학습 데이터와 테스트 데이터에 대한 분류된 영역을 나타내고 있고, Fig. 6은 OC1에 의해서 생성된 실제 decision tree를 보여 주고 있다. 일반적으로 오류역전파(error back-propagation) 알고리즘이 가장 많이 사용되지만, 본 논문에서는 학습 방법으로 conjugate gradient 알고리즘을 채용하였다^[15]. Conjugate gradient 알고리즘은 오류역전파 알고리즘 보다 학습 시간이 매우 빠르고, 학습된 신경망의 성능이 더 우수하다. Fig. 5(d)는 단독 신경망의 결과를 보여 주고 있는데, 일반적으로 Fig. 5(a)에 나타난 형태의 함수에 대하여 그 매핑 능력이 떨어진다. 그러나 오류역전파 알고리즘의 결과를 고려하면 보다 Fig. 5(d)에 나타난 결과는 매우 우수하다고 할 수 있다. Fig. 5 (e)-(h)는 gating ratio의 변화에 따른 연합 신경망의 결과를 가시화한 것이다. Fig. 5 (e)와 같이 gating ratio가 0으로 주어질 때 tile network은 존재하지 않고, 이에 따라 경계선 근처의 영역에서는 당연히 좋은 결과를 기대하기가 어렵다. Fig. 5(h)는 gating ratio가 매우 큰 경우로 연합 신경망의 거동은 단독 신경망의 거동에 근접해가는 것을 살펴 볼 수 있다. 일반적으로 문제 영역에 따라 최적의 gating ratio가 존재하며 적절한 gating ratio를 찾으면 기존의 단독 신경망의 성능보다 매우 우수할 수 있음을 Fig. 5를 통하여 쉽게 파악할 수 있다.

5. 적용 예 : 선박 중앙단면 형상설계

선박의 중앙부는 선박 전체 길이의 70%이상을 차지하는 평행한 부분으로 이 단면의 형상은 선박의 구조나 강도, 선가(船價) 등에 결정적인 영향을 미치게 된다. 따라서 중앙단면의 형상설계는 설계 단계에 있어서 매우 중요한 단계라고 할 수 있다. 이러한 중앙단면의 형상이 결정되면 설계 규정집에 따라 보강재의 배치나 철판의 두께 등을 결정하는 scantling 작업

을 수행하게 된다. 이는 선박이 설계될 때 강도나 안전 측면에서 선급 회사로부터 검사를 받게 되는데 설계시 이러한 선급 규정에 따라 설계를 수행한다. 선급 규정은 고려해야 할 항목이 매우 많고 이러한 항목들이 서로 복잡하게 연결되어 있어 지식 기반 시스템에 의한 접근이 최근 들어 많이 이루어지고 있다.

본 논문에서는 연합 신경망 시스템을 이용하여 살물선(bulk carrier)의 중앙단면 형상을 결정하는 것을 목표로 하였다. 그러나 불행하게도 각 조선소별로 과거의 실적선은 각 사 고유의 설계 노하우를 포함하고 있기 때문에 대외 비로 취급되고 있어서 충분한 학습 데이터를 마련하는 것이 사실상 거의 불가능한 일이다. 따라서 50개의 입수된 실적선 데이터 외에 나머지 부족한 학습 데이터는 선박 개념설계 시스템(BASCON-III)을 20번 수행하고 그 결과들을 이용하여 방법을 모색하였다^[16]. 총 70 개의 데이터 중 45개는 학습 데이터로 사용하고 나머지는 테스트 데이터로 사용하였다. 문제의 복잡성을 줄이기 위해서 입력 파라미터(Table 1)를 8개로 제한하였으며, 출력은 하나로 하여 필요한 설계변수 각각에 대해서 학습을 수행하였다. 그러나 학습 데이터의 수와 비교하여 입력 데이터의 차원이 아직도 큰데, 이러한 경우 신경망의 견실한 예측 성능을 기대하기 어렵다. 이 문제점의 해결 방안으로 local variable 선정 기법이 있다. 이것은 전체 입력 공간의 차원보다 적고 최적의 신경망 성능을 줄 수 있는 몇 개의 입력 변수를 선정하는 것인데, 잘 알려진 분류 시스템인 C4.5도 이 기법을 채용하고 있다. 본 연구에서는 많은 실험을 통하여 최적의 입력 변수들을 선정하였다. 생성된 decision tree가 학습 데이터에 대하여 80% 이상의 예측 정밀도를 보임과 동시에 신경망의 학습 오차가 최소가 되도록 선정 기준을 잡았다. 생성된 decision tree에 대한 pruning 과정을 수행하기 위하여 20% 학습 데이터가 임의로 선정되어 사용되었다. Fig. 7은 전형적인 선박의 중앙단면을 나타내는 형상이고, 이들 각 설계 항목에 대해서 연합 신경망 시스템을 이용하여 얻은 결과를 단독 신경망에 의한 결과와 비교하여 Table 1에 나타내었다. 그러나 실제의 설계 지식과는 다소 차이가 있음을 알 수 있다. 예를 들어, 선박의 재화중량(dead weight : DWT)은 대부분의 설계변수에 큰 영향을 미치지만 여기서는 몇 개의 설계변수만이 영향을 받는 것으로 나타났다. 이러한 경향은 학습 데이터가 몇 개의 조선소 그리고 설계 프로그램 등 다양한 출처로부터 나온 것에서 기인 할 수 있다. 즉 조선소 마다 고유의 노

Table 1. Solutions of single and federated neural networks with $r=0.3$, and $b=0.5$. Note that for convenience, the same gating ratios are used for all regions of divided input space

Symbol	Selected Local Variables							Single neural network		Federated neural network			
	D W T	V O L	Vs	L	B	D	Cb	T	Learning Error	Testing Error	No. of Regions	Learning Error	Testing Error
① BRDS	○				○				1.01E-2	1.33E-2	2	8.96E-3	9.79E-3
② HTKH		○		○	○				8.03E-3	1.10E-2	3	6.31E-3	7.95E-3
③ HTKB		○		○	○				5.41E-3	1.15E-2	3	3.34E-3	5.98E-3
④ UWTH	○				○				6.63E-3	1.20E-2	3	5.79E-3	7.50E-3
⑤ UWTB		○		○					8.63E-3	9.59E-3	3	3.25E-3	6.84E-3
⑥ CMBH		○	○	○	○				4.26E-3	2.76E-2	2	1.28E-2	1.29E-2
⑦ HCMH	○								2.34E-2	2.03E-2	2	1.53E-2	1.55E-2
⑧ HUGH		○	○		○	○			9.91E-3	1.83E-2	2	3.69E-3	1.44E-2
⑨ DBH	○	○		○					6.27E-3	6.66E-2	3	2.21E-3	5.88E-3

where, NN : Neural Network, Learning and Testing Error : RMSE, DWT : Dead Weight(ton3), VOL : Volume(ton3), Vs : Service Speed(knot), L : Length between perpendiculars, T : Draft(m), V : Breadth(m), D : Depth of Ship(m), Cb : Block Coefficient, BRDS : Bilge Radius(m), UWTB : Upper Wing Tank Breadth(m), UWTH : Upper Wing Tank Height(m), HTKB : Hopper Tank Breadth(m), HTKH : Hopper Tank Height(m), HCMH : Hatch Coaming Height(m), CMBH : Camber Height(m), HUGH : Hatch Under Girder Height(m), DBH : Double Bottom Height(m)




Fig. 7. A midship structure of bulk cargo ship.

하수가 있어, 실제선 자료가 조선소 마다 차이 있음을 확인할 수 있다. 다양한 출처에서부터 온 학습 데이터로 학습된 신경망은 이러한 사실을 반영할 수 없다. 학습 데이터 중 몇몇은 재화중량은 거의 동일하나 용적(volume)이 다른 경우가 있어, 이것 또한 신경망의 거동에 영향을 미칠 가능성이 있다. 그럼에도 불구하고 본 논문에서 제안된 시스템은 은닉층의 개수, weight의 초기값 등의 인자에 따라 결과에 영향을 많이 받는 단독 신경망에 비해 예측 오류가 작아 일관성 있는 좋은 결과를 보여주고 있음을 알 수 있다.

6. 결 론

본 논문에서는 oblique decision tree를 기반으로 하여 연합 신경망 시스템을 개발하고 그 유용성을 검증하기 위해서 선박의 중앙단면 형상설계에 연합 신경망 시스템에 적용하였다. 먼저 기존의 신경망 모델의 문제점을 해결하기 위해 입력 데이터 영역을 분할하고, 분할된 영역의 경계 부분에서의 신경망 예측 효율을 증대시키기 위해 tile network 개념을 도입하였다. 여기서 제안된 신경망의 연합구조(federated architecture)는 기존의 단독 신경망의 문제점을 보완하기 위한 것으로서 설계영역에 있어서 그 예측 성능을 향상시킬 뿐 아니라 일관성 있는 해를 도출해 주는 등의 여러 가지의 장점을 가지고 있다. 또한 facilitator를 두어 oblique decision tree에 의해 결정된 문제 영역을 찾아 적절한 subnetwork 또는 tile network를 실행시킴으로써 신뢰성 있는 설계 결과를 도출할 수 있다. 그러나 이 시스템의 성능은 gating ratio에 상당히 의존적이며 이에 따른 적절한 gating ratio를 어떻게 결정하느냐 하는 것이 매우 중요하다. 연합 신경망 시스템을 구축하는 기본적인 전략은 대부분의 분리된 입력 공간에 일반적인 subnetwork를 사용하여 전체적인 시스템의 성능 향상을 꾀하고, 동시에 세분화된 영역의 경계 부분은 subnetwork의 일종인 "tile" network를 사용하는 것이다. 따라서 "tile" network의 성능이 중요한 변수인데, 최소한 단독 신경망의 성능과 비교하여 그 성능이

떨어지지 않으면 만족한 결과를 얻을 수 있다. 그러나 "tile" network의 성능이 단독 신경망의 성능보다 떨어진다고 해도 그 효과는 다른 subnetwork에 과급되지 않기 때문에 적절한 gating ratio를 사용하여 구축된 연합 신경망의 전체적인 성능을 크게 저하시키지는 않는다.

본 연구를 통하여 앞으로의 연구과제나 나타난 문제점을 요약하면 다음과 같다.

연합 신경망의 성능은 gating ratio에 큰 영향을 받기 때문에 gating ratio를 체계적으로 결정할 수 있는 방안이 모색되어야 한다. 또한 본 연구의 접근 방법이 유효한 경우는 분리된 입력 공간이 decision tree 형태로 잘 표현될 수 있어야 하며, decision tree의 예측 성능이 우수해야 된다. 만일 분리된 공간의 수가 많으면 "tile" network의 증가에 따른 많은 sub-network이 필요하다는 단점이 있다.


감사의 글

본 연구는 한국과학재단의 1996년도 특정 기초 연구 과제 (과제번호 : 96-0200-01-01-3) 결과의 일부임을 밝혀 둔다.

참고문헌

1. Lee, K.H. and Lee, D.K., "Object-Oriented Approach to a Knowledge-Based Structural Design System", *Expert Systems with Applications*, Vol.10, No. 2, pp.223-231, 1996.
2. 양영순, 연운석, "유전적 프로그래밍을 이용한 중앙 단면 설계 지식의 추출", 대한조선학회 '96 추계 학술회의 논문집, pp.86-89, 1996.
3. Waibel, A., "Modular Construction of Time-Delay Neural Networks for Speech Recognition", *Neural Computation*, Vol.1, pp.39-46, 1989.
4. Happel, B. and Murre, J.M.J., "Design and Evolution of Modular Neural Network Architecture", *Neural Networks*, Vol. 7, pp.985-1004, 1994.
5. Smieja, F.J., "The Pandemonium System of Reflective Agents", *IEEE Transactions on Neural Networks*, Vol.7, No.1, January, 1996
6. Pratt, L.Y., Kamm, C.A., "Improving a Phoneme Classification Neural Network through Problem Decomposition", *IJCNN-91*, 1991.
7. Jacobs, R.A. and Jordan, M.I., "Learning piecewise control strategies in a modular neural network architecture", *IEEE Transactions on System, Man, and Cybernetics*, Vol.23, No.2, pp.337-345, 1993.

8. Jacobs, R.A. and Jordan, M.I., "Adaptive Mixtures of Local Experts", *Neural Computation*, Vol.3 No.1, 1991.
9. Zhang, X., Mesirov, J.P. and Waltz, D.L., "Hybrid System for Protein Secondary Structure Prediction", *Journal of Molecular Biology*, pp. 1049-1063, 1992.
10. Quinlan, J.R., *C4.5: Programs for Machine Learning*, Morgan Kaufmann Publishers, 1993.
11. Murthy, S.K., Kasif, S. and Salzberg, S., "A System for Induction of Oblique Decision Trees", *Journal of Artificial Intelligence Research*, Vol.2, pp. 1-32, 1994.
12. 이경호, 연운석, "초기설계 단계에서 Decision Tree를 이용한 선박의 설계정보 추출", 한국전문가시스템학회 '96 추계 학술대회 논문집, pp.189-195, 1996.
13. Genesereth, M.R., Singh, N.P. and Syed, M.A., "A Distributed and Anonymous Knowledge Sharing Approach to Software Interpretation", *Proc. Of the Int. Symposium on Fifth Generation Computing Systems*, pp. 125-139, 1994.
14. Genesereth, M.R. and Ketchpel, S.P., "Software Agents", *Communication of the ACM*, Vol.37, No.7, 1994.
15. 양영순, 한상민, 지능형 선상 가열 시스템 개발, 서울대학교 조선해양공학과 기술보고서, 1996.
16. Lee, D.K., Lee, K.H. and Han, S.H., "Development of the Adaptable User-Oriented Conceptual Ship Design System", *Proc. of 9th International Conference on Computer Applications in Shipbuilding*, pp.11.61-11.71, 1994.



이 경 호

1988년 서울대학교 조선해양공학과 학사
 1990년 서울대학교 조선해양공학과 석사
 1990년 ~ 현재 한국기체연구원 선임연구원
 1995년 ~ 현재 서울대학교 조선해양공학과 박사과정
 관심분야: Intelligent CAD, Artificial Intelligence in Design, Conflict Resolution in Multi-Agent System



연 운 석

1989년 서울대학교 조선해양공학과 학사
 1991년 서울대학교 조선해양공학과 석사
 1995년 서울대학교 조선해양공학과 박사
 1993년 대전대학교 기계설계공학과 전임 강사
 1995년 ~ 현재 대전대학교 기계설계공학과 조교수
 관심분야: Integrated Computer-Aided Engineering, Artificial Intelligence in Engineering Design, Inductive Program Discovery, Evolutionary Computations for Engineering Design, Multi-Agent Systems