한국 CAD/CAM 학회 논문집
제 8권 제 4호 2003년 12월 pp. 222-230

학술논문

인공신경망을 이용한 고속철도의 최고속도 예측과 구성설계

이장용*, 한순흥**

Using Artificial Intelligence in the Configuration Design of a High-Speed Train

Lee, J. Y.* and Han, S. H.**

ABSTRACT

Artificial intelligence has been used in the configuration design stage of high-speed train. The traction system of a high-speed train is composed of transformers, motor blocks, and traction motors of which locations and number in the trainset should be determined in the early stage of the train conceptual design. Components of the traction system are heavy parts in the train, so it gives strong influence to the top speeds and overall train configuration of high-speed trains. Top speeds have been predicted using the neural network with the associated data of the traction system. The neural networks have been learned with data sets of many commercially operated high-speed trains, and the predicted results have been compared with the actual values. The configuration design of the trainset of a high-speed train determines the basic specification of the train and layout of the traction system. The neural networks is a useful design tool when there is not sufficient data for the configuration design and we need to use the existing data of other train for the prediction of trainset in development.

Key words : High-speed train, Configuration design, Trainset configuration

1. 서 론

산업혁명 이후, 대표적인 수송수단 이던 철도는 그 후, 자동차와 항공기의 급속한 발달로 역할이 축소되어 왔으나, 최근 10여 년 동안 도시 사이의 교통량이 급속히 증가함에 따라, 철도만이 가질 수 있는 대량수송 능력, 안정성, 정시성, 저 공해성 등으로 다시 세계적으로 재평가되고 있다.

일반적으로 300 km 이하의 단거리 수송의 경우에는 자동차를 이용하는 것이 유리하며, 600 km 이상의 장거리 이동에는 비행기를 이용함으로써 시간을 단축할 수 있는데, 운행거리가 300~600 km 사이일 때는 고속철도가 유리한 교통수단으로 알려져 있다.

이러한 고속철도는 일반적으로 최고속도 200 km 이상으로 운행되는 열차를 말하며 우리 나라는 국토의 남북한 전체 길이가 대략 900 km로서, 고속전철의 운행에 적합한 조건을 갖추고 있다[1].

현재 고속철도를 운행중인 나라는 일본, 프랑스, 독일, 이태리, 스페인 등이며, 건설을 추진중인 나라는 우리나라를 비롯하여 미국, 러시아, 이탈리아, 중국, 대만, 영국 등 10여 개국에 이른다. 특히, 일본, 프랑스, 독일이 운행하고 있는 고속전철 시스템 – 신간센, TGV, ICE – 은 각 나라의 첨단기술을 집대성한 고유의 기술적 특성을 갖고 있다. 예를 들면 열차의 구성에서, 견인력을 갖춘 철도차량이 열차 전체에 고르게 분포되어 있는, 동력 분산방식은 일본 신간센의 독특한 기술이며, 두 객차를 연결하는 관절 형 대차 형식은 프랑스 TGV만이 사용하고 있고, 공기저항을 최소화 하기 위한 열차 외관의 공력설계와, 대용량 비동기 견인전동기를 사용한 것은 독일 ICE의 특징이다.

이들 각 나라의 고속전철에 대한 단순한 기술수준 비교는 어려운 실정이며 각국의 제조사가 서로간의 장점을 채택하는 경향이 있는데, 근래 들어 ICE3가 신간센처럼 동력 분산방식을 채택하고 있다.

고속철도의 동력은 철로를 따라 설치된 가선으로부

*한국생산기술연구원
**한국과학기술원
- 논문투고일: 2002. 01. 11
- 심사완료일: 2002. 10. 29

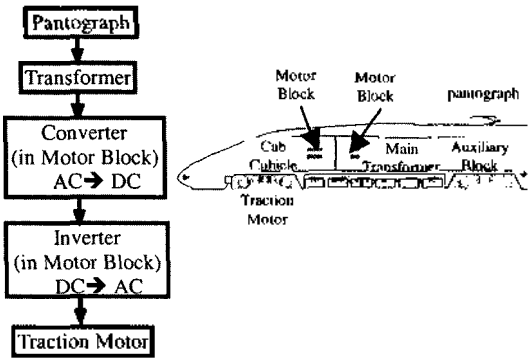

Fig. 1. 고속철도의 동력전달 계통.

터 얻게 되는데, Fig. 1과 같이 차량 외부에 설치되어 가선과 접촉하는 판토그라프에서 집전된 전기는, 변압기(Main transformer)와 모터블럭(Motor block)을 거쳐 대차에 장착된 견인전동기(Traction motor)에서 열차를 견인하는 기계적 에너지로 변형된다[2,3].

Fig. 1에 나타낸 이러한 구성요소 들을 전장품 – EMU(Electric Multiple Unit) – 또는 견인시스템(traction system)[4]이라고 하며, 철도차량 중에서 견인시스템 중 어느 하나라도 장착하고 있으면 동력차라고 부른다. 견인시스템은 고속철도의 개념설계를 할 때, 가장 먼저 고려되는 설계요소 중 하나로서, 구성요소들이 다른 구성 품에 비하여 무겁다[5].

세계적으로 현재 운행중인 고속철도의 숫자가 많지 않고, 기술발전의 속도가 빠르기 때문에, 다양한 견인시스템의 배치 방법이 현재에도 시도되고 있다. 이에 따라 변압기, 모터블럭, 견인전동기의 숫자가 각 제조국별 열차에 따라 서로 다르게 된다. 견인시스템의 배치와 관련해서, 고속철도는 동력 집중식과 동력 분산식의 두 가지 형태로 나눌 수 있다. 견인시스템이 열차 전체에 고르게 분포되어서, 많은 수의 철도차량이 견인시스템을 갖추고 있는 형태가 동력 분산식이며, 반대로 견인시스템이 소수의 철도차량에 집중되어 있는 형태가 동력 집중식이다.

본 논문에서는 고속철도 구성설계[6-8]의 수행을, 수송하는 승객 수, 속도 등을 만족시키면서, 열차 전체에서 견인시스템의 배치를 결정하는 것에 국한시켰다. 이러한 견인시스템의 배치는 열차의 전체적인 성능에 큰 영향을 미친다.

또한 본 논문에서는 고속철도 견인시스템의 주요 설계변수 및 최고속도, 그리고 열차구성의 관계를 인공신경망을 통하여 서로 연결 하였으며[9,10], 이를 통하여 열차의 최고속도와 trainset구성을 예측하였다. 인공신경망의 학습에 사용된 데이터는 선진외국에서 제작되어 현재 상업적으로 운행되는 고속철도인 TGV, ICE, 신간센 자료와 한국형 고속철도인 KHST-K, KHST-11, KHST-21의 자료를 이용하였다.

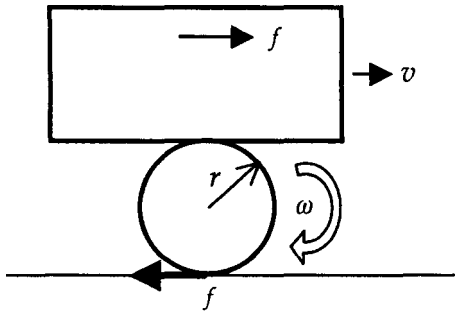

Fig. 2. 간이 철도차량 모델(One-axis train model).

2. 동력학 모델과 인공신경망

2.1 간이 철도차량 모델(One-axis train model)

Fig. 2에 간이 철도차량 모델을 나타내었다. 이 모델은 철도차량이 레일 위에서 이동하는 동역학적 특성을 단순화 하여 나타낸 것으로[11,12], 열차 속도의 근사치를 구하기 위해 사용된다.

Fig. 2에 나타낸 간이 철도차량 모델의 바퀴(wheel) 및 열차의 속도와, 바퀴와 레일 사이의 마찰력을 수식으로 나타내면 식 (1)~(3)과 같다.

$$J\frac{d\omega}{dt} = Te - f \cdot r - b \cdot \omega \tag{1}$$

$$w\frac{dv}{dt} = f - c \cdot v^2 \tag{2}$$

$$f = \mu \cdot W \cdot g \tag{3}$$

위의 수식에서 각 변수들은 다음과 같은 의미를 갖는다.

v : 철도차량의 속도

ω : 견인전동기의 회전속도

f : 점착력

μ : 마찰계수

식 (1)~(3)에 나타낸 다른 변수들에 대한 설명을 Table 1에 실었다.

차량 바퀴의 미끄러짐(slip) 현상은 바퀴와 열차의 속도에 차이가 있을 때 발생하며, 이러한 미끄러짐의 조건을 식 (4)와 같이 나타내었다. 한편 식 (3)에 사용된 마찰계수는 식 (4)에 나타낸 *slip* 변수를 사용하여

Table 1. 간이 철도차량 모델의 설계변수

기호	의미	단위
J	Wheel moment	Kg · m
Te	Input torque	N · m
r	Wheel radius	M
b	Viscosity resistance	kg · m/sec
W	Train weight	kg
c	Aerodynamic coefficient	m^3/sec
g	Gravity	m/sec^2

Table 2. 마찰계수 관련 변수

	α	β	γ	χ
Wet condition	0.54	1.2	0.29	0.29
Dry condition	0.54	1.2	1.0	1.0

식 (5)와 같이 표현된다.

$$slip = \omega \cdot r - v > 0 \tag{4}$$

$$\mu = \gamma \cdot \exp(-\alpha \cdot slip) - \chi \cdot \exp(-\beta \cdot slip) \tag{5}$$

식 (4), (5)의 α, β, γ, χ는 레일의 표면상태에 따라 결정되는 값으로서, 실험을 통하여 얻게 되는데, 그 예를 Table 2에 나타내었다.

열차의 최고속도는 열차의 추진력과 그에 따른 견인전동기의 회전속도와 열차의 중량, 그리고 식 (4)에 표현된 바퀴와 레일의 미끄러짐을 고려하여 결정되는데, 열차의 개념설계 단계에서, 아직 제작되지 않은 고속철도에 대하여 식 (1)~(5)에 표시된 계수를 정확히 얻어내기는 어려운 점이 많다. 이러한 문제를 해결하기 위해서, 본 논문에서는 인공신경망 이론 중에서 backpropagation 방법을 이용하여, 고속철도의 최고속도를 예측하였다.

2.2 Backpropagation 방법

Backpropagation은 인공신경망의 방법들 중에서 가장 많이 사용되고 있다[9,10,13,14]. 이 방법이 갖는 특성을 Fig. 3에 3개의 그룹으로 나누어 나타내었는데, 여기서 *Topology* 그룹은 인공신경망의 구조에 의한 구분을 의미하고, *Feedback* 그룹은 인공신경망 output node의 결과가 다시 input node의 입력 값으로 사용되는지의 여부에 따라 분류된다. 마지막으로 *Forms of learning* 그룹은 인공신경망을 학습하는 과정에서 목표 값이 이미 주어진 경우와, 그렇지 않은 경우를 서로 구분한다.

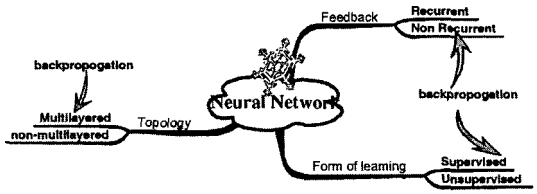

Fig. 3. Backpropagation의 특징.

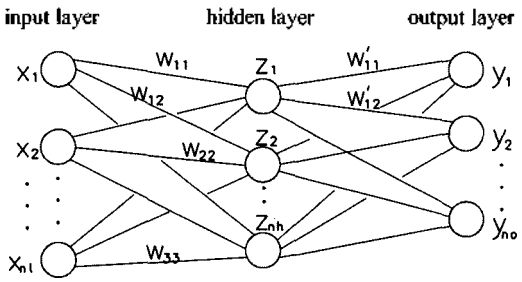

Fig. 4. 인공신경망의 3 Layer와 가중치.

각 그룹에 따른 Backpropagation의 특성에 대하여 설명하면, Backpropagation은 input, hidden layer와 output layer 등 3개의 layer로 구성되어 있어서 다층구조(multi-layered)를 갖고 있다.

Backpropagation이 수행되는 동안 Fig. 4에 나타낸 가중치(w_{ij})는 output layer의 값 y_i와 목표 값 t_i의 차이를 최소화 하기 위해서 반복적으로 수정된다. 이러한 반복적인 계산은 식 (6)에 나타낸 E_{RMS} 값이 일정 값 ε 이하로 될 때 종료된다. 이때 목표 값 t_i는 인공신경망을 학습시키기 위하여 설계자에 의하여 미리 정해진 값으로서, Backpropagation이 수행되는 동안 산출되는 output layer의 y_i 값과 비교되는데, 이것은 supervised learning method의 특징이다. 한편 가중치 w_{ij}가 식 (6)을 만족시킬 때까지 계속적으로 변화하는 동안, 각 layer의 node에 대한 입력 정보들은 변하지 않고 input layer에서 output layer 방향으로만 진행하는데, 이러한 특성을 non-recurrent feedback이라 한다 (Fig. 3 참조).

$$E_{RMS} = \frac{1}{2}\sum_j (t_j - y_j)^2 \le \varepsilon \tag{6}$$

3. 인공신경망을 이용한 속도의 예측

3.1 속도 예측 데이터

속도 예측을 위한 인공신경망의 학습은, 상업적으로 운행되고 있는 고속철도인 TGV, ICE 및 신간센

데이터를 활용한 경우와, 우리나라에서 프랑스와 기술제휴로 개발된 경부고속철도(KHST-K)와 독자 개발된 KHST-21, 및 KHST-11의 데이터를 활용하는 두 가지 경우로 수행되었다. 두 가지 경우는 입수가능 여부에 따라 학습에 사용된 데이터가 서로 다르다.

Table 3에 최고속도 예측을 위한 외국의 고속철도 데이터를 나타내었는데, 9개의 입력 값과 한 개의 목표 값(최고속도)을 보여준다. Table 4에 국내에서 개발된 한국형 고속철도의 데이터를 수록하였다. 모두 11개의 입력 값이 사용되었고, 여기서 출력 값으로 사용된 top speed는 열차의 설계 최고속도를 의미하는데, 이 값은 Table 3의 상용속도(top service speed)보다 빠른 값을 갖는다. 주어진 입력 값과의 연관성이 보다 높다는 가정 하에, 국내 고속철도의 경우 이러한 설계 최고속도를 입력 데이터로 사용하였다.

Table 4의 입력 값 중에서 주행저항은, GEC Alsthom에서 KHST-K를 위해 제안한 식 (7)을 활용하여 계산하였다.

Table 3. 최고속도 예측데이터 1(TGV, Shinkansen, ICE)

		input nodes								output node
	class	Weight (ton)	Length (m)	Power (kw)	Mass/seat (ton)	Power/ seat (kw)	No. of motor car/total train	No. of trailer/ total train	No. of traction motor	Top service Speed (km/h)
TGV	TGV-PSE	385	200	6450	1.046	17.527	0.20	0.80	12	300
	TGV-Atlantique	484	238	6450	0.998	13.299	0.17	0.83	8	300
	TGV-Reseau	386	200	8800	1.024	23.342	0.20	0.80	8	300
	TGV-EuroStar	752	394	12200	0.947	15.365	0.10	0.90	12	300
	TGV-Duplex	380	200	8800	0.697	16.147	0.20	0.80	8	300
	TGV-Thalys	385	200	8800	1.021	23.342	0.20	0.80	8	300
Shin kan-sen	500	1264	404	18240	0.955	13.776	1.00	0.00	64	300
	400	575.9	148.66	5040	1.443	12.632	0.86	0.14	24	240
	300	1037.4	402.1	12000	0.784	9.070	0.63	0.38	40	270
	200	1785	400.3	11040	1.451	8.976	0.88	0.13	48	240
	100	1428	402.1	11040	1.083	8.370	0.75	0.25	48	220
ICE	ICE-V	296.1	113.42	5600	3.567	67.470	0.40	0.60	8	350
	ICE 1	906.2	410.72	9600	1.405	14.884	0.14	0.86	8	280
	ICE 2	418	205.36	4800	1.130	12.973	0.13	0.88	4	280

Table 4. 최고속도 예측데이터 2(KHST-K, KHST-11, KHST-21)

	input nodes						output node
	Weight (ton)	Length (m)	Power (kw)	Mass/no. of seat (ton)	Power/no. of seat (kW)	No. of cars of a train	Top speed (km/h)
	No. of motor car/ total train	No. of traction motor	Propulsion resistance (주행저항) (kN at 350 km/h)	Traction force (kN at 350 km/h)	Adhesion coefficient (점착계수) (at 350 km/h)		
KHST-K	701	387.2	13200	0.82	14.1	20	330
	0.2	12	131.0	171.2	0.07		
KHST-11	458	218.9	13200	1.0	29.0	11	385
	0.36	12	81.6	132.4	0.07		
KHST-20	780	393.5	17600	0.86	19.3	20	385
	0.3	16	131.4	176.5	0.07		

$$R = 0.77\sqrt{10nM} + 0.008Mv + (0.02225 + 0.00352T)v^2 \times 10 \quad (7)$$

n : Number of axles of bogies in a train.
M : Weight of a train (ton)
T : Number of passenger cars including motorcar that has passenger seats.
v : Speed of a train (km/h)

3.2 인공신경망

최고속도 예측을 위해서 상업용 소프트웨어인 Qnet v2000을 사용하였다. 이 소프트웨어는 backpropagation을 포함한 여러 가지 인공신경망 이론을 프로그램화 하여 실제 문제에 적용할 수 있는 기능을 갖추고 있다[13].

최고속도 예측을 위한 인공 신경망의 구조는 Table 3에 나타낸 입력데이터를 사용할 경우 Input layer에서 8개의 데이터가 입력되고, 1개의 output node(최고속도)와 3개의 hidden layer가 있다. hidden layer는 16개의 node를 갖는 2개의 layer와 8개의 node를 갖는 1개의 layer로 구성된다. Hidden layer의 개수는 시행착오 끝에 처음 2개의 layer에서는 input node의 2배에 해당하는 node수를 갖고, 마지막 layer에서는 input node와 같은 수의 node로 구성 되었는데, 인공신경망의 구조가 필요 이상으로 복잡해 지지 않게 하였다.

마찬가지로 Table 4에 나타낸 데이터를 활용하여 최고속도를 예측하는 인공신경망은, 11개의 input node와 22개의 node로 이루어진 2개의 hidden layer와 11개의 node로 이루어진 1개의 hidden layer로 구성된다.

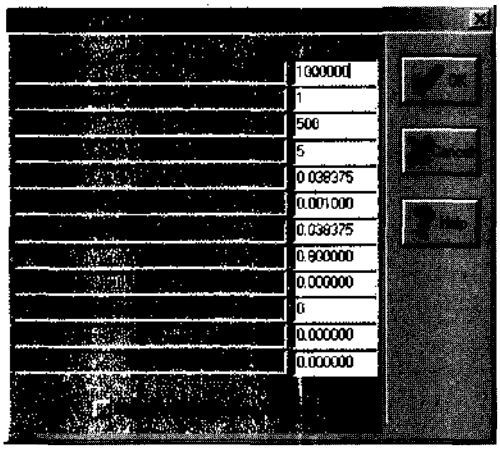

Fig. 5. 인공신경망의 학습을 위한 Qnet 소프트웨어의 변수.

sigmoid 함수가 두 경우에 대한 인공 신경망의 activation function으로 사용되었다[9,10,14].

인공신경망의 학습을 위하여 Qnet 소프트웨어에서 사용한 변수들을 Fig. 5에 나타내었다. 프로그램 사용자는 효과적인 학습을 위하여 이 변수들을 적절히 조절할 수 있다.

Fig. 5에 나타낸 변수들 중에서, 설계자가 조절할 수 있는 주요한 변수는 Learn rate와 momentum인데, 이 변수들은 인공신경망의 학습과정에서 가중치의 변화량을 조절하는 역할을 한다.

n번째 학습단계에서 가중치의 변화량을 나타낸 식 (8)에서, η와 α가 각각 learn rate와 momentum을 나타낸다.

$$\Delta w^{(n)}_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} + \alpha \cdot \Delta w^{(n-1)}_{ij} \quad (8)$$

본 논문에서는 최고속도 예측과 고속철도의 구성설계를 위한 인공신경망을 학습시킬 때, 수렴조건은 식 (6)에 표현된 방법을 사용하지 않고, Fig. 5에 나타낸 바와 같이 반복횟수(Max Iteration)를 충분히 큰 수(=1,000,000)로 정해주어서, 가중치 w_{ij}의 수정이 1,000,000만큼 진행되면 인공신경망의 학습이 끝나도록 하였다. 이런 방법이 가능한 이유는, 대부분의 경우 최고속도 예측용 인공신경망의 RMS error가, 주어진 백만 번의 반복횟수에 훨씬 못 미쳐서 0의 값으로 수렴하며, 수렴시간도 길지 않기 때문이다.

Fig. 6에 나타낸 RMS error의 감소곡선은, 최고속도를 예측하는 인공신경망이 빠른 속도로 주어진 목표 값(t_i)에 수렴하고 있음을 나타내 준다.

3.3 최고속도의 예측

인공신경망을 이용한 고속철도의 최고속도 예측 값

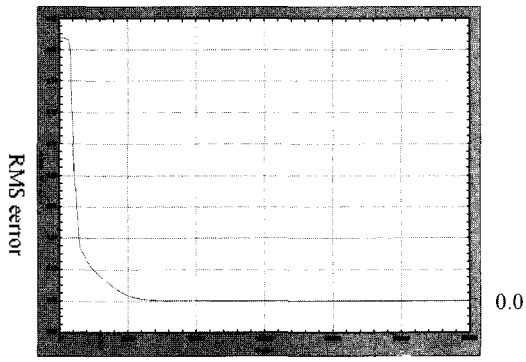

Fig. 6. RMS error의 변화곡선.

Table 5. 최고속도 예측(같은 열차의 데이터로 학습)

	예측값	실제값	정확도(%)
신간센 700 계열	267.1	285	93.7
ICE 3	348.6	330	105.6
TGV-K	300.0	300	100.0

Table 6. KHST-21의 최고속도 예측(신간센, ICE, TGV 데이터로 학습)

	예측값	실제값	정확도(%)
신간센	308.6	350	88.2
ICE	314.6	350	89.9
TGV	300.0	350	85.7
동력 집중식 열차 그룹	326.4	350	93.3

과 그것의 실제 값을 Table 5에 나타내었는데, TGV-K, ICE3, 신간센700의 최고속도 예측은, 각각 자신과 같은 종류의 열차 데이터로 학습한, 3개의 인공신경망에 의하여 이루어 졌다. 예를 들어 TGV-K는 인공신경망 학습을 위하여 TGV 열차들의 데이터를 이용하였다.

Table 5의 결과에서 보여지듯이, 예측된 열차와 학습데이터를 제공한 열차가 서로 공통점이 많아서, 예측된 최고속도의 정확도가 상당히 높다.

2002년 한국에서 개발된 차세대 고속철도(KHST-21)는, 최고속도 350 km/h가 설계 목표치이다. Table 3에 나타낸 데이터를 이용하여 학습한 인공신경망을 통해 KHST-21의 최고속도를 예측하였고 그 결과를 Table 6에 나타내었다.

Table 6에서 ICE-V, ICE 1, TGV Eurostar와, TGV-K가 견인시스템의 특성에 따라 동력 집중식 열차로 선택되었다. 예를 들어 TGV-K는 총20량의 열차 중에서 견인시스템은 4개의 차량에 집중되어 있고, 반대로 동력분산식 열차인 신간센 700은 총 16량의 열차 중에서 12개의 차량에 견인시스템이 분산되어 있다.

KHST-21는 총 20량의 차량 중 6개의 차량에 견인시스템이 있으므로 동력 집중식 열차로 분류할 수 있으며, 이러한 유사성 때문에, Table 6에서 나타나듯이, 동력 집중식 열차 그룹의 데이터로 학습한 인공신경망이 KHST-21의 최고속도를 보다 정확히 예측하였다.

한편 학습에 사용된 TGV 열차들의 최고속도가 모두 300 km/h이므로, 이 데이터로 학습된 인공신경망의 예측 값도 300 km/h를 벗어나지 못했다. 이것은

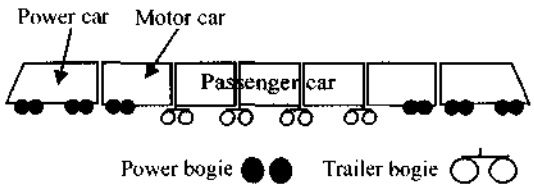

Fig. 7. Test train A of KHST-21.

Table 7. Prediction of top speeds(test train A of KHST-21)

	예측값	실제값	정확도(%)
Test train A	372.7	385	96.8

상업적으로 운행되는 TGV열차들의 최고속도가 모두 같았기 때문에 일어난 현상으로서, TGV 열차 데이터 자체만으로는 학습데이터로서 별다른 가치가 없지만, ICE 및 신간센과 같이 활용될 경우엔 나름대로 최고속도 예측에 기여하는 바가 있다고 판단된다. 동력 집중식 열차 그룹의 경우에는, 서로 최고속도가 다른 열차들로 구성하여 같은 동력 집중식인 KHST-21의 최고속도를 예측하였다.

시험제작차(시제차)는 개발하려는 고속철도의 성능을 시험 및 검증하기 위하여 제작된다. Fig. 7에 우리나라에서 개발된 KHST-21열차의 시제차 A(Test train A)를 나타내었다. 모두 7량의 차량으로 구성된 시제차량은 각각 2량의 동력차(Power car) 및 동력객차(Motor car)와 3량의 객차(Passenger car)로 구성되었다.

한국형 고속철도 데이터를 (Table 4 참조) 이용하여 학습한 인공신경망에서 시제차 A의 최고속도를 예측하였고, 그 결과와 실제 값을 Table 7에서 나타내었다.

시제차의 경우는 인공신경망의 학습 데이터로 사용된 고속철도의 차량과 동일한 차량으로 구성되었으므로, 사용된 인공신경망은 주어진 시제차의 열차 구성에 대하여 보다 정확하게 속도를 예측할 수 있다. 또한 외국의 고속철도의 경우에 비하여 국내 철도차량의 경우에는 기술적인 데이터를 보다 많이 확보할 수 있으므로, 인공신경망을 통한 속도 예측은 개념설계 단계에서 시제차를 구성할 때 유용하게 사용될 수 있다.

4. 인공신경망을 이용한 열차의 구성 설계

구성설계는 이미 존재하고 있는 구성 요소들을 조합하여, 설계자의 목적에 부합하는 시스템을 형성해 내는 것을 의미한다[3,15,16]. 이러한 구성설계는 제품의

개념설계 단계에서 수행되는 것으로, 설계범위도 설계자에 따라 다소간 다르게 지정될 수 있다.

본 논문에서는 열차 구성설계의 범위를, 열차의 길이, 중량 및 견인시스템의 배치와 관련된 사항 만으로 제한하였다. 예를 들어, 동력차 및 견인전동기의 숫자와, 열차 전체의 동력 및 길이, 중량을 결정하는 것이다.

고속철도의 구성설계는 개념설계 단계에서, 기존에 운행해온 고속철도의 설계 데이터를 참고하여, 최고속도를 얻기 위한 견인시스템의 용량 및 수량을 정하고, 이를 전체 열차에 걸쳐 배치하는(trainset configuration) 것이 지금까지의 일반적인 순서였다.

인공신경망을 이용한 구성설계를 위하여 2개의 input node와 6개의 output node, 3개의 hidden layer를 갖는 인공신경망을 작성하여 backpropagation을 수행하였고, 이를 위하여 Qnet 소프트웨어가 이용되었다.

이러한 인공신경망의 input node와 output node의 의미를 Table 8에 나타내었다. Input node의 내용은, 열차운행을 위한 상업적 요구 조건인, 최고속도 및 승객 수가 되었고, output node는 열차의 전체적인 구성과, 견인시스템의 배치와 관련한 값들로 이루어졌다.

구성설계 과정을 단순화 하고 간단한 결과만을 도출하기 위해서, Table 8과 같이 인공신경망의 학습을 위해서 비교적 적은 수의 입력 값이 사용되었으나, 동력 집중식과 동력 분산식의 데이터로 각각 학습한 인공신경망은 구성설계의 결과로서, 서로 다른 견인시스템의 배치를 분명하게 보여준다.

인공신경망을 이용하여 신간센 700계열 열차의 구성설계를 수행한 결과를 Table 9에 나타내었는데, 인공신경망의 학습 데이터는 700 계열 열차를 제외한 신간센 열차들의 데이터로 이루어졌다.

Table 9에 보여진 바와 같이 인공신경망에서 예측된 신간센 700 계열 열차의 중량 및 견인전동기의 숫자가 실제의 값보다 더 큰 이유는, 700 계열 열차가 기존까지의 신간센 열차들보다 에너지를 효율적으로 사용하여, 보다 적은 용량의 견인시스템으로 동일한 최고속도를 실현하며, 같은 수의 승객을 실어 나를 수 있기 때문이다. 즉 신간센700 계열 열차의 견인시스템이 기술적으로 기존의 신간센 견인시스템 보다 진보했기 때문에, 예측된 결과보다 적은 수의 견인시스템이 사용되었다.

신간센 데이터와 동력 집중식 열차 그룹의 데이터를 이용하여 학습된 서로 다른 2개의 인공신경망에서 각각 얻어진 KHST-21의 구성설계 결과를 Table 10에 나타내었다.

동력 분산식 열차인 신간센으로 학습한 인공신경망의 구성설계 결과는, 동력 집중식 열차그룹의 인공신경망에 비하여 견인전동기와 동력차가 훨씬 많았다. 이러한 이유는 동력 분산식 열차가 같은 최고속도 구현을 위하여, 동력 집중식에 비해 용량은 작고, 숫자는 많은 견인시스템으로 구성되어 있기 때문이다.

이러한 견인시스템이 장착된 동력 분산식 열차는, 동력차에도 승객을 실을 수가 있으므로, 그렇지 못한 동력 집중식에 비하여 전체 열차의 숫자는 보다 적게

Table 8. 열차의 구성설계를 위한 인공신경망의 입력 값

Input nodes	승객 수
	최고 속도
Output nodes	열차 중량
	열차 길이
	동력
	동력차의 전체 열차에 대한 비율
	전체 열차에서 동력 대차의 수
	전체 열차 수

Table 9. 신간센 700 계열의 구성설계 결과(신간센 데이터로 학습)

	예측된 열차 구성 결과	실제 열차 구성
Weight	1136	1120
Length	403.0	404.7
Power	15989	13200
Motor car/total train	83%	75%
No. of traction motors	55	48
No. of total trains	16	16

Table 10. KHST-21의 구성설계 결과(신간센과 동력 집중식 열차그룹 데이터로 학습)

	사용된 학습 데이터		실제
	신간센	동력 집중식 열차그룹	
Weight	1341.6	687.5	712
Length	407.6	385.5	394.6
Power	19809.4	13475.8	17600
Motor car/total train	100%	25%	30%
No. of traction motors	69	12	16
No. of total trains	16	20	20

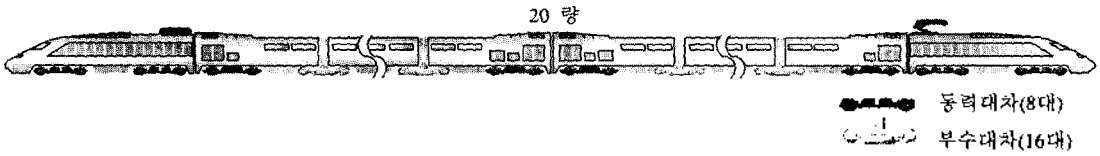

Fig. 8. KHST-21 열차의 구성.

예측되었다.

KHST-21와 동력 집중식 열차 그룹의 견인시스템 배치의 유사성 때문에, 동력 집중식 열차 그룹의 KHST-21에 대한 구성설계 결과는, Table 10에서 나타나듯이 실제 구성에 보다 근접해 있다.

KHST-21의 실제 열차 구성을 Fig. 8에 나타내었다. KHST-21은 좌우 대칭인 구성에 총8개의 동력대차가 있으며, 각 동력대차에 두개의 견인전동기를 장착하고 있다.

5. 결 론

인공신경망은 비교적 적은 수의 데이터와 불완전한 입력 값을 가지고도 결과 값을 빠르게 제공하는 장점을 가지고 있으므로, 고속철도의 개념설계 단계에서 유용한 도구가 된다. 실험 데이터를 모두 확보하지 않고도, 인공신경망을 이용하여 중요한 설계목표 중 하나인 최고속도를 예측할 수 있다. 따라서 현재 운영되고 있는 고속철도 견인시스템의 데이터를 이용해 학습한 인공신경망을 가지고, 개발하려는 열차의 최고속도 및 trainset 구성을 손쉽게 예측할 수 있다. 또한 주어진 예측값을 위한 인공신경망의 학습 데이터 세트가 변화하여도, 쉽게 새로운 인공신경망을 구성하여 새로운 결과를 도출할 수 있다. 실제로 다양한 학습 데이터 set에 대한 비교분석이 수행되었다.

설계 대상이 되는 열차와 같은 종류(신간센, ICE, TGV, KHST-21)의 열차 데이터를 이용해 학습한 인공신경망은, 그렇지 않은 경우에 비해 보다 높은 정확도로 최고속도를 예측했는데, 이는 최고속도와 견인시스템 데이터 사이의 상관관계가 서로 비슷하기 때문이다.

특히 시험제작 차량의 경우는, 인공신경망의 데이터로 이용된 차량과 같은 열차로 구성되었고 trainset의 구성만 다르기 때문에, 최고속도 예측의 정확도가 그렇지 않은 경우와 비교해서 높다. 인공신경망을 이용한 시제차량의 속도예측은 여러 가지 trainset 구성에 대한 가상실험을 할 때, 유용하게 사용될 수 있을 것이다.

인공신경망을 통한 열차의 구성설계 결과로서, 열차를 구성하는 철도차량의 개수, 동력차 및 견인전동기의 개수, 열차의 전체동력 등을 결정하였다.

인공신경망으로 열차의 구성설계를 수행하기 위해서는, 설계할 열차의 견인시스템이 동력 집중식과 동력 분산식 중에서 어떤 방식을 수용할지를 미리 결정하고, 그에 상응하는 데이터로 학습한, 인공신경망을 통해 구성설계를 수행하는 것이, 설계자의 의도에 맞는 설계 결과를 보여준다. 이러한 구성설계 결과로부터, 설계자는 고속철도의 개념설계 단계에서, 동력차의 숫자 및 전체 열차에서 배치되는 위치, 판토그라프의 위치, 변압기와 견인전동기의 숫자 등을 보다 현실적으로 조정할 수 있다.

인공신경망을 통한 이러한 결과는 기존 고속철도의 성능에서 얻게 되는 근사값이다. 따라서 이러한 구성설계 결과를 실제 설계에 그대로 적용하는 것은 어려운 점이 있다. 특히 구성설계를 위한 인공신경망이 설계에 의미 있는 결과를 도출하기 위해서는, 출력 값의 결과가 trainset의 구성을 보다 명확히 제시 해야 할 필요가 있다. 이를 위해서는 입력데이터를 더 추가하고, (예를 들어 집중식과 분산식을 나타내는 데이터를 추가할 수 있다) 출력 값도 보다 자세히 세분해야 할 것이다.

본 논문에서 제안한 인공신경망은 기존의 고속철도 견인시스템의 기술적 성능 추이를 바탕으로 하여, 설계하려는 고속철도의 최고속도를 신속히 예측하고, 견인시스템을 두 가지 측면(동력 집중식과 동력 분산식)에서 빠르고 쉽게 구성설계 하여, 서로간의 장단점을 분석 하는데 유용하게 사용될 수 있다. 특히 성능계산을 위한 방법이 확립되어 있지 않아서, 이론적인 수식으로 예측하기 곤란한 경우에 (예를들어 열차운행시, 습도에 따른 속도 변화를 예측), 사용하는 것이 바람직하다.

감사의 글

논문심사위원들의 지적을 통해 논문의 내용이 충실해 질 수 있었습니다. 본 논문을 심사해 주신 심사위원 분들께 감사를 드립니다.

참고문헌

1. 김선호, "철도시스템의 이해," 자작아카데미, 1997.
2. Andrews, H. I., "Railway Traction", Elsevier Science Publishers, 1986.
3. 이장용, 한순홍, "기능 분해와 TRIZ 이론을 이용한 철도 대차의 구성설계," 대한산업공학회지, Vol. 29, No. 3, pp. 230-238, 2003.
4. Hagiwara, Y., Tanaka, M. and Ueno, M., "Evaluation of Advantages of High-speed EMU in Case of Series 700 Shinkansen High-speed Train with IGBT Applied Traction Systems," Proceedings of the World Congress on the Railway Research '2001, 2001.
5. Ito, Satoru, and Heumann, Klemens, "Optimal Formation of Trainset," Proceedings of the World Congress on the Railway Research '99, pp. 961-966, 1999.
6. Murdoch, T. N. S. and Ball, N. R., "Machine Learning in Configuration Design," *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, Vol. 10, pp. 101-113, 1996.
7. 구도연, 한순홍, "급지기구설계 전문가시스템에서 구성설계 방법론," CAD/CAM학회 논문집, 제1권, 제2호, pp. 163-172, 1996.
8. Koo, D-Y., Han, S-H. and Lee, S-H., "An Object-oriented Configuration Design Method for Paper Feeding Mechanisms," *International Journal of Expert Systems with Applications*, Vol. 14, pp. 283-289, 1998.
9. Munakata, Toshinori, "Fundamentals of the New Artificial Intelligence," Springer-Verlag, 1998.
10. Hoffmann, Achim Gunther, "Paradigms of Artificial Intelligence," Springer-Verlag, 1998.
11. Garg, K. Y. and Dukkipati, R. V., "Dynamics of Railway Vehicle Systems," Academic Press, 1984.
12. Ishikawa, Y. and Kawamura, Asuo, "Maximum Adhesive Force Control in Super High Speed Train," Proceedings of the World Congress on the Railway Research '99', pp. 951-954, 1999.
13. 서태설, 한순홍, "인공지능에 기반한 단계적 의사결정 방법: 베어링 설계에의 적용," CAD/CAM학회 논문집, 제4권, 제2호, pp. 100-109, 1999. 6.
14. Russell, S. J. and Norvig, P., "Artificial Intelligence - A Modern Approach," Prentice Hall, 1995.
15. Snavely, Gary L., "An Abstraction-based Methodology for Mechanical Configuration Design," PhD thesis, University of Michigan, 1992.
16. Snavely, Gary L. and Papalambros, Panos Y., "Abstraction as a Configuration Design Methodology," ASME, Vol. 1, pp. 297-305, 1993.

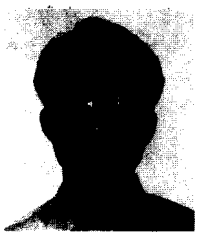

이 장 용

1987년 연세대학교 기계공학과 학사.
1989년 연세대학교 기계공학과 석사.
1991년~현재 한국생산기술연구원. 선임연구원
관심분야: CAD/CAM, Expert system, TRIZ

한 순 홍

1977년 서울대 조선공학과 학사
1979년 서울대 조선공학과 석사
1985년 영국 Newcastle대 석사
1990년 미국 Michigan대 박사
1979년~1992년 해사기술연구소(현재 기계연구원)
1993년~1995년 한국과학기술원 자동화 및 설계공학과
1996년~현재 한국과학기술원 기계공학과 교수
관심분야: CAD 모델 표준(STEP), Intelligent CAD, 설계전문가 시스템, 형상모델링 커널