

## 신경망을 이용한 한국형 표준 신발금형설계

최정일<sup>1</sup> · 이정민<sup>2</sup> · 백상현<sup>3</sup> · 김병민<sup>4</sup> · 김동환<sup>#</sup>

### The Shoe Mold Design for Korea Standard Using Artificial Neural Network

J. I. Choi, J. M. Lee, S. H. Baek, B. M. Kim, D. H. Kim

(Received November 25, 2014 / Revised March 4, 2015 / Accepted April 7, 2015)

#### Abstract

In the current study, the design methodology has been developed to produce shoe mold for a suitable walking shoes of the general Korean using ANN (Artificial Neural Network). To design the suitable and comfortable shoes for the Korean, the shapes of foots were measured for 513 people. In this research, the foot length, breadth and ankle were considered as design parameters. In order to find the optimal foot shape for the average value of design parameters, the average value of design parameters and the other measurements were used as input and output to the ANN. After training, the various foot measurements were predicted by ANN. Base on the ANN results, the walking shoes were manufactured by considering these measurements and designing a shoe mold. From the results, the proposed method could give a more systematic and feasible means for manufacturing walking shoes with greater usefulness and better generality.

**Key Words** : Shoe Mold, Last, Artificial Neural Network , OCL Program, Walking Shoe, Hiking Shoe

#### 1. 서론

라스트(Last)는 신발 제조 시 발 형상을 대신하는 것으로 발의 모양과 형상, 치수와 같이 발을 대표하는 중요한 치수정보를 담아야만 한다. 라스트 형상이 최종 신발형상의 근거가 되며 이를 토대로 다양한 신발의 치수 및 내·외부 형상을 결정하는 역할을 한다[1]. 그러나 라스트는 발 형상을 기본으로 하지만 실제 발 형상과는 많이 다르다. 발과 신발의 적합도를 높이기 위해서 라스트를 실제 발 형상보다 좁히거나 늘이기도 한다. 발의 움직임을 제한하거나 허용하기 위해 똑바른 형태와 구부러진 형태의 라

스트를 설계하기도 한다. 실제 신발의 종류와 신발 사이즈, 남녀 용도구분, 나라별 인종 특성에 따라 라스트는 매우 다양한 치수와 형상을 가진다.

기존의 라스트 제작을 위한 연구결과를 보면 대부분 많은 사람들의 발의 치수를 측정한 후, 측정값의 평균으로부터 라스트 제작을 위한 기초 데이터로 사용하고 있는 실정이다. 그러나 표준발의 치수로 남성아동의 경우 235mm, 성인 남성의 경우 265mm 에 대하여만 발의 치수를 측정하여 라스트를 제작하고, 그 이상과 이하의 치수에 대해서는 오프셋 방식으로 라스트를 제작하고 있는 실정이다[2, 3].

본 연구에서는 이전에 제시한 신발 라스트에 대

1. 부산·울산중소기업청 산학협력팀  
2. 한국생산기술연구원 뿌리산업기술혁신센터  
3. 부경대학교 대학원 기계공학과  
4. 부산대학교 기계공학부  
# Corresponding Author : Dept. of Aircraft Parts Engineering, International University of Korea, E-mail:dhkim@iuk.ac.kr

한 3차원 측정 시험 및 그 결과로부터 기존의 단순 평균치 방식이 아닌 신경망을 이용한 가중치 방식으로 라스트 제작에 적용하고자 한다. 인공신경망(Artificial Neural Network: ANN)은 제어기, 예측기, 패턴 인식기 등의 역할을 하며, 형상 분류, 인식, 제어 및 함수근사 등의 분야를 해결하는 데 우수한 특성을 가지고 있어, 이미 여러 연구분야에 적용되어 오고 있다[4~8]. 신경망은 다차원 함수의 학습이 가능하며 학습으로 다차원 함수의 변수관계를 찾아내는 특성을 가지고 있다[9]. 그러나 신경망의 학습데이터를 선정할 때에는 주의를 요하며 학습 후, 미 해석된 입력데이터에 대한 출력데이터의 신뢰도를 높이기 위해서 보다 넓은 범위에서 정확한 데이터의 학습이 선행되어야 한다.

## 2. 신경망을 이용한 표준 라스트 설계

### 2.1 발 형상의 측정

일반적으로 발의 세부적인 측정 부위는 신발에 따라 매우 다양하게 결정된다. 측면설계 시 중요 요소로서는 발목높이와 발등높이, 갑피굽힘점, 엄지발가락의 높이 등이 있으며 발목높이는 신발의 굽의 높이와 여유량을 고려하여 길이를 결정한다. 그러나 바닥면과 마찬가지로 측면 인자의 세부적인 값들은 신발에 따라 다양하게 변화한다. 심지어 라스트의 주요 부위 및 인자들도 신발종류에 따라 매우 다양하게 정의하고 있다. 그러나 결국 신발의 기능성은 인간의 발 형상에 가장 크게 의존하며 곧 신발의 품질을 결정한다. 최근 국내에서도 건강 기능성 신발의 수요가 증가하면서 신발 기능성에 대한 소비자의 요구가 점점 높아지고 있다. 그러나 국내 업체들은 한국인의 발 형상측정 데이터와 이를 이용한 기본 라스트 설계 경험이 없기 때문에 기능성 신발의 경우 국내 소비자의 품질 욕구를 만족시킬 수 없어 대부분 국외 메이저업체의 OEM사로 전락하고 있는 실정이다. 따라서 본 연구에서는 한국인 발 형상 측정을 통해 발 형상 표준을 제시하고 신경망 알고리즘을 이용하여 한국형 라스트 설계기법을 개발하고자 한다.

본 연구에서는 신경망을 이용한 표준마스터 제작을 위하여 265mm 신발을 신는 사람 513 명에 대한 발 치수 3 차원 스캔 데이터를 활용하였다. 사용된 중요 치수부는 (1)발직선 길이(Foot length), (2)발꿈치-

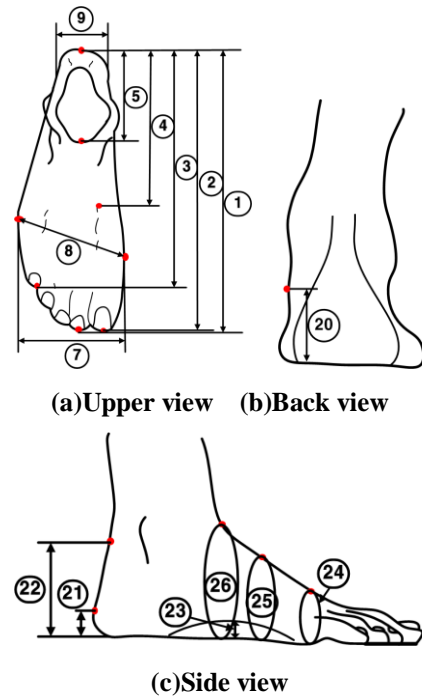




Fig. 1 Important data for manufacturing shoe mold

Table 1 Average value of measuring data

Name	Average	Deviation	Maximum value	Minimum value
(1)Foot length	264.744	1.44	267.5	262.5
(2)Heel to toe 1 length	260.520	3.05	269.6	249.0
(3)Heel to toe 5 length	214.254	6.26	229.6	114.7
(4)Heel to instep length	149.328	6.46	166.7	120.7
(5)Heel to ankle length	110.245	4.75	126	98.2
(7)Foot breadth, horizontal	102.906	4.07	114.5	90.5
(8)Ball distance	105.923	4.16	118.3	93.7
(9)Heel width	68.389	3.11	80.3	59.5
(20)Navicular height	41.774	3.97	55.9	30.3
(21)Heel height	24.326	3.31	35.4	0.7
(22)Height of upper point of heel point	59.886	10.97	80.6	28.2
(23)Arch height	9.007	4.10	51.0	1.2
(24)Ball circumference	256.785	9.32	287.5	229.7
(25)Instep circumference	256.085	10.38	288.2	225.2
(26)Perpendicular ankle circumference	282.923	34.32	971.8	250.6



(a) Input data of input layer in ANN



(b) Input data of output layer in ANN

Fig. 2 Input data as teaching signals for ANN training

엄지발가락 길이(Heel to toe 1 length), (3)발꿈치-새끼 발가락 길이(Heel to toe 5 length), (4)발꿈치-발등길이 (Heel to instep length), (5)발꿈치-발목길이(Heel to ankle length), (7)발너비 (Foot breadth, Horizontal), (8)볼거리 (Ball distance), (9)발꿈치 너비(Heel width), (20)발배뼈 점 높이 (Navicular height), (21)발꿈치점 높이(Heel height), (22)발꿈치위점높이 (Height of upper point of heel point), (23)아크높이 (Arch height), (24)볼둘레(Ball circumference), (25)발등둘레 (Instep circumference), (26) 발목수직둘레 (Perpendicular ankle circumference) 이다. 본 연구에서 사용된 측정 데이터 부위는 전체 26개 부위에서 발의 형상 및 라스트에 영향을 많이 주는 15개 데이터만을 이용하였다. 측정된 부위의 사진은 Fig. 1에 나타내었다. 측정 부위에 대한 상세한 설명은 Table 1에 나타내었다.

## 2.2 신경망의 학습

본 연구에서는 265mm 마스터 제작을 위하여 신발 265mm를 신는 513명에 대한 발 치수를 측정하였고, 중요 치수부 11개 부위를 잡아 신경망 학습을 위한 입력데이터와 출력데이터로 사용하고자 한다.

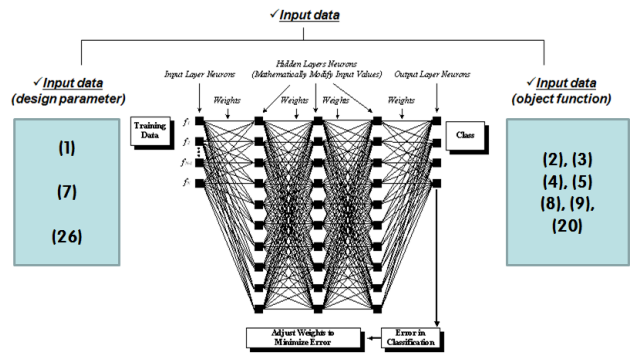


Fig. 3 Schematic drawing of input data in input and output layer for ANN training

Table 2 Input data for ANN training

Training of ANN		Training data			
		1	2	...	513
Input layer	(1)Foot length	262.5	262.5	...	267.5
	(7)Foot breadth, horizontal	104.0	101.5	...	105.1
	(26)Perpendicular ankle circumference	286.1	297.1	...	290.9
Output layer	(2)Heel to toe 1 length	260.0	260.6	...	263.8
	(3)Heel to toe 5 length	206.8	215.4	...	218.9
	(4)Heel to instep length	148.3	152.1	...	153.1
	(5)Heel to ankle length	112.0	108.2	...	107.0
	(8)Ball distance	110.9	104.7	...	108.3
	(9)Heel width	73.0	71.0	...	72.3
	(20)Navicular height	43.0	52.8	...	45.3

먼저 신경망의 입력데이터는 발 외관 크기를 결정하고 측정이 용이한 발의 치수부로 (1)발의 길이와 (7)폭 그리고 (26)높이로 설정하였다. 먼저 신경망 학습데이터로 사용된 부위는 아래의 Fig.2와 같다.

또한 신경망의 출력층에서 학습 될 목표값으로는 발꿈치-엄지발가락 길이(2), 발꿈치-새끼발가락 길이(3), 발꿈치-발등길이(4), 발꿈치-발목길이(5), 볼거리(8), 발꿈치 너비(9), 발배뼈점 높이(20) 으로 하였다. 신경망의 입력층과 출력층의 학습데이터 선정은 기존의 라스트 제작에서 비교적 중요 치수부에 해당되는 부분에서 선정하였으며, 입력층은 외관 크기를 결정하는 치수부로 하였고, 출력층은 측정하기는 다소 어려우나 신발의 편리함, 안락함과 기능성 신발

**Table 3 Predicted results using ANN after training**

Training of ANN		Training data					
		1		2		...	513
Input layer	(1)Foot length	262.5		262.5		...	267.5
	(7)Foot breadth, horizontal	104.0		101.5		...	105.1
	(26)Perpendicular ankle circumference	286.1		297.1		...	290.9
Output layer	<i>Trained Item</i>	<i>Target</i>	<i>ANN</i>	<i>Target</i>	<i>ANN</i>	<i>Target</i>	<i>ANN</i>
	(2)Heel to toe 1 length	260.0	258.7	260.6	258.9	...	263.8 263.4
	(3)Heel to toe 5 length	206.8	214.1	215.4	212.3	...	218.9 217.1
	(4)Heel to instep length	148.3	149.2	152.1	149.0	...	153.1 151.1
	(5)Heel to ankle length	112.0	108.9	108.2	106.6	...	107.0 109.3
	(8)Ball distance	110.9	107.2	104.7	104.9	...	108.3 107.4
	(9)Heel width	73.0	69.4	71.0	69.4	...	72.3 70.6
	(20)Navicular height	43.0	42.5	52.8	42.6	...	45.3 43.5

제작에 매우 중요한 치수부로 선정하였다. Fig. 2의 원형에 있는 부분 (1, 7, 26) 이 입력층의 입력데이터이며, 출력층의 입력데이터는 2, 3, 4, 5, 8, 9, 20의 측정부위이다.

본 연구에서는 역전파 학습알고리즘의 신경망 프로그램을 이용하였으며, 학습에 사용된 입력층의 뉴런(Neuron) 수는 3개에 각각 1, 7, 26 데이터를 입력하였고, 출력층 뉴런 8개에 각각 2, 3, 4, 5, 8, 9, 20 데이터를 입력하였다. 입력에 사용된 발 측정데이터는 513명에 해당되며 이에 대한 데이터를 간략히 정리하여 Table 2에 나타내었다. 신경망의 학습구조에 대하여 Fig. 3에 나타내었다. 신경망의 학습에 사용된 은닉층(Hidden layer)은 3개의 구조를 사용하였고, 몇 번의 시행착오를 통하여 수렴에 용이한 10, 10 그리고 5개의 뉴런 구조를 사용하였다. 또한 변환된 목표값과 학습된 결과값의 오차, 즉 신경망 학습의 수렴한계를  $10^{-7}$ 으로 지정하였다[7]. 발 형상 학습 데이터의 학습시간은 개인용 PC(Intel Core i7-3770 CPU)에서 약 1시간 미만이 소요되었다.

2.3 발 형상 치수 예측

**Table 4 Comparison results between average and predicted data**

Input data : Average value	(1)Foot length	264.74		
	(7)Foot breadth, horizontal	102.91		
	(26)Perpendicular ankle circumference	282.92		
Average value vs predicted data using ANN	<i>Prediction Item</i>	<i>Average value (513persons)</i>	<i>Predicted data using ANN</i>	<i>Gap</i>
	(2)Heel to toe 1 length	260.52	260.12	0.40
	(3)Heel to toe 5 length	<b>214.25</b>	<b>212.77</b>	<b>1.48</b>
	(4)Heel to instep length	149.33	149.00	0.33
	(5)Heel to ankle length	<b>110.25</b>	<b>109.23</b>	<b>1.03</b>
	(8)Ball distance	105.92	106.18	0.26
	(9)Heel width	68.39	69.36	0.97
	(20)Navicular height	<b>41.77</b>	<b>42.85</b>	<b>1.08</b>

신경망의 학습으로부터 학습 오차 및 목적값(Target value) 정확도를 판단하기 위하여 학습된 내용과 그 결과값을 Table 3에 나타내었다. 학습에 사용된 513개의 데이터는 (1)발의 길이와 (7)폭 그리고 (26)높이가 유사한 사람 중에서 발꿈치-엄지발가락 길이(2), 발꿈치-새끼발가락 길이(3), 발꿈치-발등길이(4), 발꿈치-발목길이(5), 볼거리(8), 발꿈치 너비(9), 발배뼈점 높이(20) 측정치는 매우 다양하다. 그리고 (1), (7), (26)의 데이터가 균일 증가하더라도 (2), (3), (4), (5), (8), (9), (20)의 치수가 무조건 균일 증가하지는 않는다. 정리하면 발의 길이가 같다 하더라도 세 부길이차이와 폭의 길이는 매우 다양하기 때문에 측정된 513의 혼돈의 데이터는 대표적인 (1), (7), (26) 치수를 기준으로 정리되어야만 활용의 가치가 있다고 판단된다. 혼돈의 데이터를 학습한 신경망의 예측치는 목적값과 4% 미만의 오차율을 가지며 양호한 결과를 보여준다.

다음으로 미 학습 입력 데이터에 대한 중요부 발 형상치수를 예측하기 위하여 513명의 265mm 발 형상 치수에 대한 신경망의 학습 후 뉴런사이의 연결가중치(Weight value)를 이용하였다. 먼저 513명에 대한 (1)발의 길이와 (7)폭 그리고 (26)높이 데이터의 평균치를 입력 데이터로 하고 이에 대한 (2), (3), (4), (5), (8), (9), (20) 결과치를 예측하였다. Table 4에는 (1) 발의 길이와 (7)폭 그리고 (26)높이 데이터의 평균치

에 대한 신경망이 예측한 결과값을 나타내었다. 또한 일반적인 평균값을 나타내고 그 값과의 차이를 비교하였다. 그 결과 발꿈치-새끼발가락 길이(3), 발꿈치-발목길이(5) 그리고 발배뼈점 높이(20)의 길이는 1mm 이상 차이가 나는 것을 알 수 있었다. 본 연구결과는 일반적인 평균값이 가지는 측정 오류의 일종이라 판단된다. 예를 들어 다섯 개의 수치를 비교할 때 첫 번째의 경우 4개의 데이터가 5이고 1개의 데이터가 10이면 그 평균값은 6이다. 두 번째의 경우 6, 5.5, 5.5, 7, 6 의 다섯 개 데이터 평균값 또한 6이다. 이 치수가 발 형상 치수라 가정하면 두 번째의 경우는 평균값 6을 기준으로 신발을 제작하면 최소 4명에게는 편안한 만족을 줄 수 있다. 그러나 첫 번째의 경우 평균값 6을 기준으로 신발을 제작하면 5명 전부가 불편함을 느끼는 치수가 된다. 오히려 첫 번째의 경우는 5에 가까운 수치로 제작되어야만 4명에게 편안함을 줄 수 있다.

따라서 특히 신체와 관련된 제품을 제작할 때에는 동일 그룹 내에서(예를 들자면 265mm 신발을 신는 사람) 많은 사람이 분포하는 치수데이터에 가중치를 주어야만 평균값이 갖는 오류를 해결할 수 있을 것이다.

### 3. 라스트 설계

#### 3.1 OCL프로그램

3D 라스트는 자유곡면(Freeform surface)으로 이루어져 있다. 이는 라스트 측정 데이터만으로는 3D 라스트를 제대로 표현할 수는 없다는 것을 의미한다. 따라서 3D 라스트를 제대로 설계하기 위해서는 표준이 되는 3D 라스트(Master last)를 준비하여서 라스트 데이터에서 부족한 정보를 표준 라스트에서 가져와야 올바른 결과물을 기대할 수 있다. 이는 기존의 라스트개발 방식이 표준 3D 라스트에 살을 붙이거나 갈아내는 것과 같은 이치이다.

OCL(Offset Concept Last) 프로그램은 실제의 신발을 개발하는데 소요되는 비용과 시간을 줄여주고 가상의 신발 제품을 시뮬레이션 하기 위하여 개발된 3D 라스트설계 자동화 소프트웨어이다. 본 연구에서는 인공지능망의 발 형상 데이터베이스로부터 학습되어 추론된 한국형 표준 발 데이터를 본 프로그램으로 분석 및 설계하고, 실제 라스트로도 제작하여 봄으로서 프로그램의 유효성을 검증하였다.

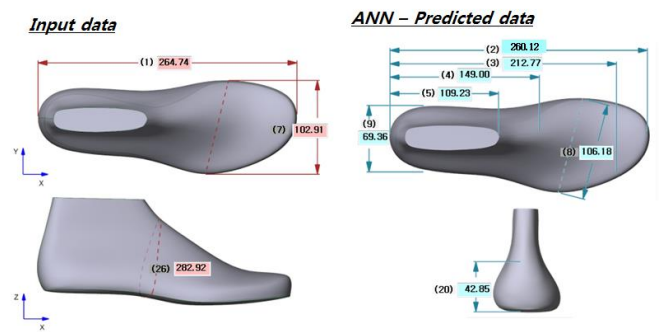


Fig. 4 The program of OCL for last design




Fig. 5 Regulating points in toe part




Fig. 6 Input data of input layer for OCL

사용된 OCL 프로그램은 Fig. 4와 같다.

#### 3.2 3D 라스트 설계 자동화 기법

OCL에서는 마스터(Master)라는 표준이 되는 라스트를 참조하여 설계를 하게 되는데, 마스터 표면(Master surface) 조정점의 개수를 결정하기 위해서는

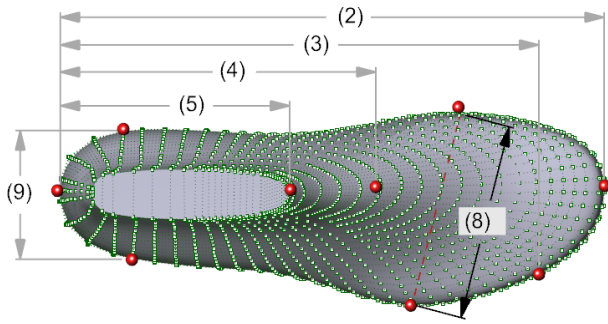


Fig. 7 Input data of output layer for OCL

고려해야 할 부분이 있는데, 조정점의 간격이 너무 조밀하게 되면 필요이상의 형상 표현력을 가지게 되어 라스트의 품질을 떨어뜨리게 되며, 반면 부족하다면 형상 표현 능력이 떨어져서 필요로 하는 정밀도의 3D 라스트 모델링을 할 수 없게 된다는 것이다. 따라서 적절한 수의 조정점(Regulating point)을 등 간격으로 배열시켜 고른 정밀도를 유지하여 줄 필요가 있다.

OCL에 사용된 마스터 표면은 1700개(Degree=3, U=68, V=25)의 조정점으로 구성되어 3D 라스트를 표현하고 있는데 이는 Fig. 5와 같이 발끝(Toe)부분 반경을 충분히 표현하기 위한 최소의 크기로 결정하였다. 신경망 엔진으로 추론된 입력 데이터에 맞게 이들 조정점들에 변형을 가함으로써 3D 라스트를 모델링을 할 수 있도록 프로그램 하였다. 한국형 표준 라스트를 설계하기 위해 입력된 데이터는 크게 두 가지로 분류하여 설계에 사용되었는데, 먼저 Fig. 6 같이 (1), (7), (20)번 데이터를 3차원 좌표계상에서 각각 X, Y, Z 축으로 Scale 적용하여 치수를 만족시켰고, 다음으로 Fig. 7와 같이 (2), (3), (4), (5), (8), (9)번 입력 데이터를 마스터의 일부 구간에만 적용을 하여 치수를 만족시켰다. 이로서 입력데이터를 만족하는 3D 라스트 설계가 가능하게 된다.

#### 4. 시험결과 및 고찰

##### 4.1 신발의 치수등급

본 연구에서는 265mm 라스트의 마스터를 제작하기 위하여 신발 265mm를 신는 513명에 대한 발 치수를 측정하였고, 중요부위 15개의 평균 및 편차 등을 분석하였고 이중 중요부위 10개를 잡아 신경망 학습을 위한 입·출력데이터로 사용하였다. 신경망

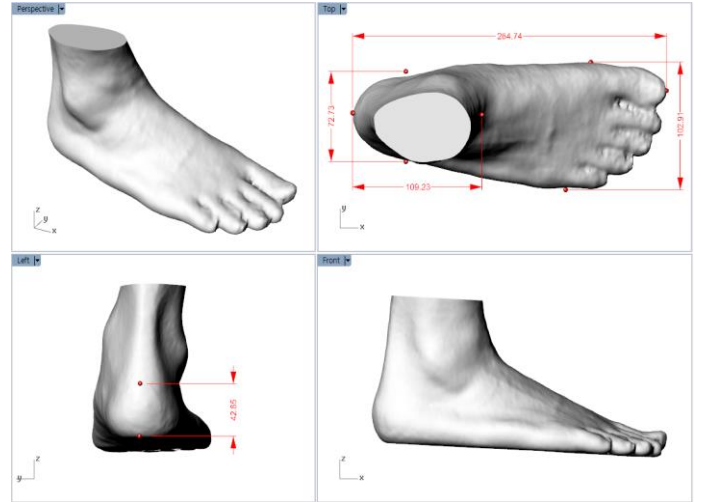


Fig. 8 The manufacturing of foot using ANN data

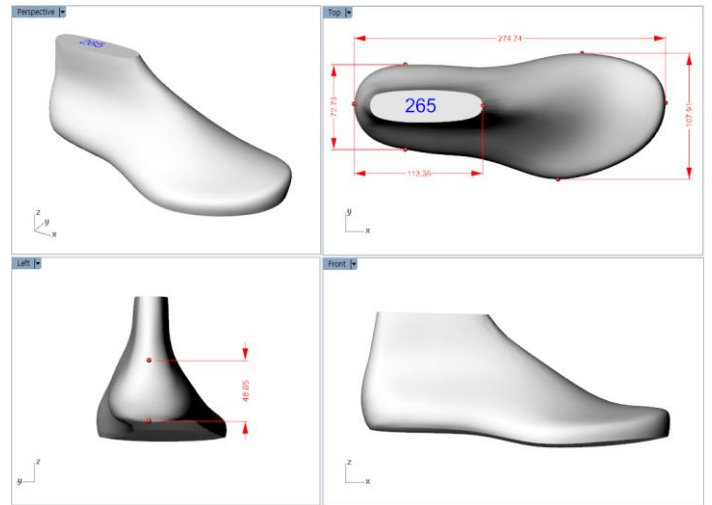


Fig. 9 The grading shape for walking shoe (265mm)




Fig.10 The grading shape for hiking shoe (265mm)

학습을 위해 입력층의 뉴런(Neuron) 수는 3개, 출력층의 뉴런 수는 7개 부위를 설정하였고, 은닉층(Hidden layer)은 3개의 구조를 사용하였으며, 수렴에 가장 용이한 뉴런 수는 10개 또는 5개의 뉴런 구조로 나타났다. 수렴의 한계를 목표 값과 학습된 결과 값의 오차를  $10^{-7}$  까지 하였다. 또한 현재 국내 라스트 생산업체 대부분 통상적으로 사용하는 기준문대 신발사이즈인 265mm에 대해 기존 라스트와 신경망으로 예측된 표준 발의 치수로 개발된 라스트를 치수등급(Grading) 여유값을 발직선길이(X)로 5mm, 발너비(Y)로 1.2mm, 발배뼈점높이(Z)로 0.5mm로 하여 남자 워킹화를 260mm, 270mm으로 각각 확대 축소시킨 후 적용이 가능하다. 또한 본 연구에서 제시된 결과는 기존 등산화 치수등급을 고려하여 적용된다면 보다 실용적인 등산화 제작도 가능하다[10]. 이에 본 연구에서는 워킹화와 등산화에 대하여 신경망의 데이터를 기본으로 하여 OCL 프로그램을 이용해 워킹화와 등산화의 3차원 라스트 모델을 Fig. 8~10에 나타내었다.

#### 4.2 신발금형의 제작

본 연구에서 수행된 워킹화의 제작과정을 Fig. 11에 나타내었다. 먼저 신발제작에 앞서 신발 디자인을 수행하는데 사용 용도에 맞게 신발의 갑피와 솔의 구조를 설계한다. 이후 라스트의 설계와 3차원 모델링을 수행한 후 라스트(NC가공)를 제작한다. 라스트 3차원 모델링을 바탕으로 단순 신발 디자인 상태 도안을 2차원 도면과 3차원모델링 상태로 변환한다. 이 때 신발의 갑피와 솔도 모델링 하는데 라스트의 형상에 따라서 갑피와 솔의 위치와 사이즈, 전체적인 신발의 형상이 결정된다. 신발창, 즉 솔(Sole)은 위치와 재료에 따라 인솔(In Sole), 미드솔(Mid Sole) 그리고 아웃솔(Out Sole)이 있고 3차원 모델링을 통해 CNC가공 데이터를 추출하여 목업(Mock-up)을 만들어 전반적인 형상을 검토한다. 솔은 대부분 발포 방식으로 제작되며 제작방식에 따라 금형도 다양한 방식으로 제작된다. 미드솔은 일반적으로 사출기계를 통해 제작되기 때문에 인젝션(Injection) 금형을 사용하며 방전과 CNC가공을 통해 금형이 제작되므로 상대적으로 아웃솔 금형에 비해 고가이다. 반면에 아웃솔은 보통 재료를 캐비티(Cavity)에 직접 투입하는 방식이며 주조 공법으로 금형이 제작된다. 이후 갑피 제단과 제봉을 통해 신발 갑피를 제작하고



Fig.11 Manufacturing processes for walking shoe



Fig.12 Last and shoe made in this study

라스트를 이용하여 갑피와 솔의 접착 및 건조 공정을 거쳐 워킹화가 제작된다. 등산화도 동일한 방법으로 제작된다. 본 연구에서는 신경망을 이용하여 265mm에 대한 워킹화와 등산화를 제작하였으며, 최종 제작된 워킹화를 Fig. 12에 나타내었다.

#### 4.3 신발의 착화시험

신발 제작 후 신발의 기본적인 테스트인 접착박

5. 결론

본 연구에서는 보다 편안한 한국형 표준 신발금형 및 라스트 설계를 위하여 신경망을 이용한 설계기법을 제시하였다. 신발의 표준 라스트는 일반적으로 가장 많이 신는 신발 치수를 기준으로 하여 일반인을 대상으로 발 치수를 측정하고 이 데이터의 평균값을 근거로 라스트를 제작하게 된다. 본 연구에서는 평균값이 가지는 오류를 보완하고 보다 편안함을 주는 신발을 제작하기 위하여 신경망의 결합허용시스템기능과 가중치에 근거한 학습기능을 이용하였다. 그리고 신경망의 예측결과로부터 라스트를 설계하였고, 워킹슈즈와 등산화에 대한 신발치수 적용방법을 제시하였다. 본 연구결과를 요약하면 아래와 같다.

(1) 본 연구에서는 한국형 표준 신발금형설계를 위하여 265mm 신발을 신는 513명 일반인을 대상으로 발의 치수를 측정하였다. 측정된 발 치수로부터 기본적인 세가지 치수 부위(발 길이, 발 폭, 발 등 높이)를 설계인자로 하고 기타 7개의 중요부 치수를 목적값으로 하여 신경망 프로그램을 학습을 하였다. 학습 후 기본 세가지 치수부위에 대한 중요부 7개의 치수를 예측하였고, 그 결과 단순 평균치와는 다른 가중치를 고려한 치수를 예측할 수 있었다.

(2) 학습된 신경망이 예측한 치수로부터 OCL 프로그램을 이용하여 라스트를 설계하였고, 3D 라스트 설계 자동화 기법을 제시하였다.

(3) 본 연구에서는 제시된 기법을 토대로 워킹화와 등산화에 대하여 260mm, 265mm 그리고 270mm에 대한 치수 등급화하는 기법을 제시하였다.

(4) 한국형 신발에 대한 길이와 발등 부분에 대한 일반인 90명 대하여 착화시험을 실시하였다. 그 결과 미국의 N사, 유럽의 A사 보다 적합도가 양호한 것으로 나타났다.

이상의 결과로부터 본 연구에서 제시된 신경망을 이용한 한국형 표준 라스트 신발금형 제작 방법은 매우 효과적임을 알 수 있었고, 워킹화 및 등산화 신발에 적용이 가능하다는 것을 확인 할 수 있었다. 향후 다양한 신발제작에도 적용된다면 편안한 신발 제작에 크게 기여할 것으로 판단된다.

REFERENCES

[1] K. C. Adrian, 1991, American Last Making, Brown

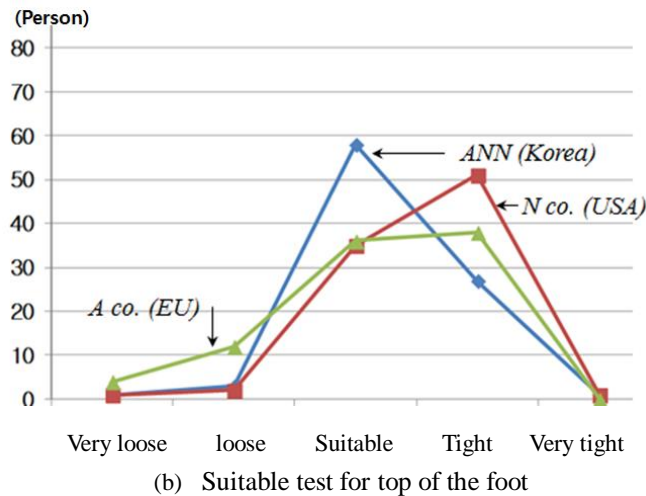
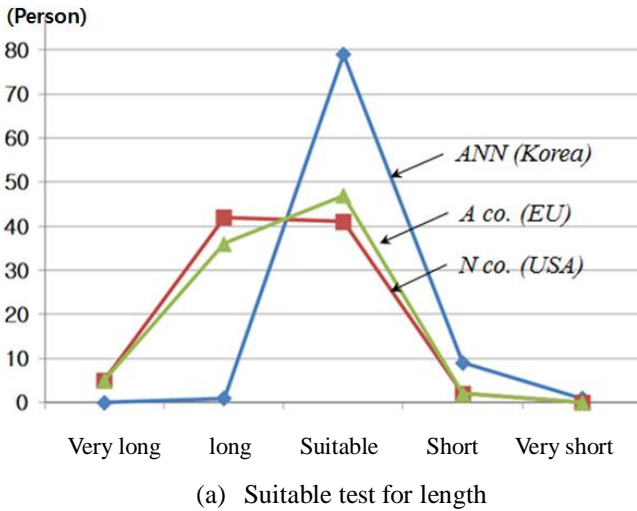


Fig.13 Result of sensitivity fitting test for foot length

리강도, 걸창 마모내구성, 갑피 마모 내구성 그리고 굴곡내구성과 반복 압축내구성 시험도 실시하였고 그 결과 모든 데이터는 만족할 수준 이상이었다. 그리고 본 연구에서 제시된 신경망을 이용한 한국형 표준 라스트 남성용 워킹화 265mm에 대하여 착화 시험을 수행하였다. 착화시험은 신체구조 및 보행방법에 별다른 문제가 없는 사회생활이 많은 연령대 (30~50대)남자 90명을 대상으로 실시하였다. 착화기간은 15일로 하였다. 본 연구를 통하여 제작된 신발의 유효성 검정을 위해 A, B사의 도움을 받아 기존 브랜드 N사(미국) 및 A사(유럽)에 대한 착화시험 결과와도 비교하였으며 그 결과를 Fig. 13에 나타내었다. 그 결과 본 연구에서 제시된 신경망기법으로 만들어진 워킹화의 만족도가 가장 양호한 것으로 나타났다.



- Shoe Company, No. 1.
- [2] Kifft, 2007, Development of the Korean-type Through The Measurement of The Foot Specialty Running Shoes and Tennis Shoes Last, Ministry of Commerce Industry and Energy, Regional Industrial Technology Development Project Report.
- [3] Kifft, 2008, Korean Type of Children, Elderly, Shoes and Standards Development Dimension a Boot Tree, Ministry of Knowledge Economy, Standard Technology Improves Project Report.
- [4] R. P. Lippmann, 1987, An Introduction to Computing With Neural Nets, IEEE ASSP Magazine, Vol. 2, pp. 4~22.
- [5] S. P. Abhijit, B. M. Robert, 1996, Pattern Recognition With Neural Networks in C++, CRC Press.
- [6] D. E. Rumelhart, G. E. Hinton, R. J. Williams, 1986, Learning Internal Representations by Error Propagation, Parallel Distribution Processing Cambridge MA:MIT press, pp. 318~362.
- [7] D. H. Kim, 2002, An Innovative Scheme for Process Design in Metal Forming Using FEM and Intelligent Computational Optimization, Ph. D in Pusan National University.
- [8] H. T. Fan, S. M. Wu, 1995, Case Studies on Modeling Manufacturing Process Using Artificial Neural Networks, J. Manuf. Sci. Eng., Vol. 117, No. 3, pp. 412~417.
- [9] D. H. Kim, D. J. Kim, B. M. Kim, J. C. Choi, 1998, Process Design of Multi-step Drawing Process Using Artificial Neural Network, Trans. Mater. Process., Vol. 7, No. 2, pp. 127~138.
- [10] H. S. Park, 2007, A Study on Verification of Shoe Last Grading System Based on Foot Measuring Data, J. Soc. Kor., Vol. 26, No. 1, pp. 71~77.