

인공신경망을 이용한 드레이프성 예측

이소민 · 유동주 · 신보나 · 윤선영* · 심명희** · 윤창상†

이화여자대학교 의류산업학과,

*Dept. of Textile Engineering, Chemistry, and Science, North Carolina State University,

**한국섬유수출입협회

Prediction of Fabric Drape Using Artificial Neural Networks

Somin Lee · Dongjoo Yu · Bona Shin · Seonyoung Youn* ·
Myounghee Shim** · Changsang Yun†

Dept. of Fashion Industry, Ewha Womans University

*Dept. of Textile Engineering, Chemistry, and Science, North Carolina State University

**Korea Textile Trade Association

Received July 16, 2021; Revised (August 19, 2021; September 3, 2021); Accepted September 6, 2021

Abstract

This study aims to propose a prediction model for the drape coefficient using artificial neural networks and to analyze the nonlinear relationship between the drape properties and physical properties of fabrics. The study validates the significance of each factor affecting the fabric drape through multiple linear regression analysis with a sample size of 573. The analysis constructs a model with an adjusted R^2 of 77.6%. Seven main factors affect the drape coefficient: Grammage, extruded length values for warp and weft (m_{warp} , m_{weft}), coefficients of quadratic terms in the tensile-force quadratic graph in the warp, weft, and bias directions (c_{warp} , c_{weft} , c_{bias}), and force required for 1% tension in the warp direction (f_{warp}). Finally, an artificial neural network was created using seven selected factors. The performance was examined by increasing the number of hidden neurons, and the most suitable number of hidden neurons was found to be 8. The mean squared error was .052, and the correlation coefficient was .863, confirming a satisfactory model. The developed artificial neural network model can be used for engineering and high-quality clothing design. It is expected to provide essential data for clothing appearance, such as the fabric drape.

Key words: Fabric drape, Physical property, Multiple linear regression, Artificial neural network, Number of hidden neurons; 직물의 드레이프성, 역학적 특성, 다중선형 회귀분석, 인공신경망, 은닉층 뉴런의 수

I. 서 론

†Corresponding author

E-mail: cyun@ewha.ac.kr

본 논문은 2020년도 한국산업기술진흥원 산업기술기반 구축혁신사업의 지원을 받아 수행된 연구임(No. P114000 015).

직물의 외관을 규정하는 중요 인자에는 색감, 광택, 질감과 드레이프성이 있는데, 직물의 드레이프성은 자중에 의해 발생하는 3차원 변형이다(Sanad et al., 2012). 직물의 드레이프성은 1960년대 Cusick에 의해

많은 진보를 이루었으며, 대부분의 기관에서 Cusick의 드레이프 측정방법인 드레이프 미터법을 채택하고 있다(Carrera-Gallissà et al., 2017). 드레이프성 측정은 원형의 직물을 측정 실린더 위에 놓고, 위에서 내려다 보았을 때 드레이프된 직물의 면적을 계산함으로써 이루어진다(Jeong et al, 1999; Pattanayak et al., 2011). 이후 기술의 발달로 종이를 이용하여 측정하던 드레이프성을 컴퓨터의 이미지 분석을 통해 측정하는 방법이 주로 사용되고 있다(Jeong et al., 1999). 드레이프 계수는 0~1까지의 값을 가지며 드레이프 계수 값이 클수록 뻗뻗하고 드레이프 계수 값이 작을수록 하늘거리는 특징을 갖는다(Carrera-Gallissà et al., 2017). 드레이프성은 직물의 역학적 특성에 영향을 받는다는 연구가 다수 보고되어 왔으며(Chu et al., 1950; Morooka & Niwa, 1976), 드레이프성에 영향을 주는 요인에는 굵힘 강성, 압축성, 표면 마찰성 등이 있다(Peirce, 1930). 이후 여러 학자들에 의해 방추성, 두께 등도 함께 고려되어야 할 요인으로 논의되고 있다(Collier, 1991; Collier et al., 1989; Morooka & Niwa, 1976; Süle, 2012).

직물의 드레이프성과 역학적 특성의 관계는 복잡하고 비선형적 특성을 나타낸다(Pattanayak et al., 2011). 비선형적 특성으로 인해 전통적인 수학적 방법으로는 관계에 대한 설명이 어렵기 때문에, 기존의 선형적 방법과 다른 비선형적 구조를 통한 분석이 가능한 인공신경망을 통한 접근이 필요하다(Taieb et al., 2018). 인공신경망은 기본 데이터의 관계를 알 수 없는 경우 최적의 가중치를 찾고자 할 때 사용가능하다(Matusiak, 2015). 즉 인공신경망은 경험과 학습을 통해 유사성을 발견하고 데이터를 분류 및 일반화하여 인간의 개입 없이 컴퓨터가 스스로 특성이나 상관성을 예측할 수 있다(Kim, 2020).

인공신경망은 인공지능의 방법론으로써, 뇌의 구조를 모방한 방식으로 정보를 처리하는 알고리즘을 구현한다(Park, 2016). 인공신경망의 기본적인 구조는 생물학적인 신경세포와 유사하다. 기능적 측면에서 보면 수상돌기는 자극을 받아들이는 구조로써 입력모듈, 축삭돌기는 신호를 전달하는 구조로써 출력모듈, 세포체와 세포핵은 계산모듈에 해당한다(Park, 2016). 하나의 신경세포는 각 입력값에 가중치를 곱하여 받아들여지는데 세포핵에서 이루어지는 계산 기능을 담당하는 것이 활성화 함수가 된다(Park, 2016). 이를 처리식으로 나타내면 <Eq. 1>과 같다. 하나의 신경세포는

L개의 입력을 받아들일 때 가중치를 곱하여 받아들이는데 이 가중치 곱의 합이 활성화 함수인 $\Phi(u)$ 를 통해 전달된다(Park, 2016). 활성화 함수 증가장 널리 사용되는 형태는 시그모이드 함수이다. <Eq. 2>에서와 같이 활성화 함수는 임의의 입력 값에 대해 출력이 0에서 1까지의 범위를 갖도록 하는 표준화의 의미를 가지고 있다(Park, 2016).

$$u = \sum_{i=1}^L w_i x_i, \Phi(u) = \begin{cases} 1 & \text{if } u \geq 0 \\ 0 & \text{otherwise} \end{cases} \dots \text{Eq. 1.}$$

$$f = \frac{1}{1 + \exp(-x)} \dots \text{Eq. 2.}$$

인공신경망 모델은 다양한 프로그래밍 언어로 구현 가능한데(Park, 2016), 이를 가능토록 하는 인공신경망 분석 소프트웨어에는 TensorFlow, Pytorch, R 등이 있다. R을 이용하여 분석할 때는 neuralnet, nnet, rms와 같은 패키지가 주로 사용되는데, neuralnet 패키지의 이론인 다층 퍼셉트론은 신경망 모델과 회귀문제에서 가장 많이 사용되어지고 있다(Matusiak, 2015). 다층 퍼셉트론의 학습 알고리즘은 교사학습의 부류에 속하며(Park, 2016), 오류역전파 학습 알고리즘이 대표적이다. 학습의 과정은 크게 초기화, 전방향 계산, 역방향 가중치 수정, 종료 조건 확인으로 이루어지며 계산된 오차값이 희망오차보다 작을 경우 학습을 완료한다(Park, 2016).

직물과 관련하여 인공신경망을 이용한 연구사례로는 직물의 인장 특성 예측을 위한 인공신경망 적용에 대한 연구(Rolich et al., 2010), 인공신경망 및 통계모델을 사용한 폴리에스터/비스코스레이온 혼합 방직사의 불균일성 예측에 대한 연구(Demiryürek & Koç, 2009), 직물의 통기성 예측을 위한 인공신경망 적용에 대한 연구(Matusiak, 2015), 다양한 수분 함량에서 편직물의 내열성 예측 시 인공신경망의 적용에 대한 연구(Kanat & Özdil, 2018), 인공신경망을 사용해 섬유와 원사의 관계를 예측하는 연구(Admuth & Apte, 2010) 등이 있다. 드레이프 관련 인공신경망이 적용된 연구 사례로는 드레이프 계수의 예측 회귀모델과 인공신경망 모델의 비교분석에 대한 연구(Mitra et al., 2012), 직물이 드레이프된 이미지에서 굵힘성과 무게를 학습한 연구(Bi et al., 2018), 그룹화 된 동적 드레이프의 매개변수 추정을 위한 연구(Yang et al., 2018) 등이 있다.

인공신경망을 통해 드레이프 계수를 예측하고 있는 연구가 진행되어 왔으나 역학적 특성과 정확한 관계가 밝혀진 바가 없다(Niwa & Seto, 1986; Pattanayak et al., 2011). 또한, 적은 수의 데이터를 기반으로 조사가 이루어졌으므로 다양한 시료로 검증이 필요하다(Matusiak, 2015). 따라서 본 연구에서는 회귀분석을 통해 드레이프 계수를 예측하는데 유의한 요인을 분석하고, 여기에서 도출된 주요 인자를 이용한 인공신경망 학습을 통해 정확한 출력을 도출해내고자 하였다. 이를 위해 573개의 시료의 드레이프성과 역학적 특성값을 이용한 자발적 학습을 통하여 인공신경망 모델을 제안하고자 한다.

II. 실험방법

1. 시료 특성

선행연구의 측정 데이터와 함께 추가 시료를 사용하여 총 573종의 직물을 이용하였다(Kim et al., 2021; Kim et al., 2020). 무게 측정은 ISO 3801:1997에 따라 저울을 이용하여 측정하였으며 단위는 g/m^2 이다(International Organization for Standardization [ISO], 1977). 드레이프성은 ISO 9073-9:2008에 따라 쿠식 드레이프 측정기를 이용해 측정하였으며, 반지름 15 cm의 시료를 이용하였다(ISO, 2008). 굽힘 특성은 캔틸레버를 이용하여 경사와 위사에 대해 밀어낸 길이(mm)를 측정하여 사용하였다. 인장 특성은 경사, 위사, 바이어스 방향에 대해 늘어난 길이(mm)에 대한 힘(kgf)을 측정하여 사용하였다.

2. 통계분석

통계프로그램(R, Bell Laboratories, USA)을 통해 드레이프성 영향인자를 예측 및 분석해 보고자 한다. 종속변수는 드레이프 계수, 독립변수는 무게, 두께, 경사와 위사에 대한 늘어난 길이(m_{warp} , m_{weft}), 경사, 위사 및 바이어스 방향에 인장-힘 2차 함수 그래프의 이차항의 계수(c_{warp} , c_{weft} , c_{bias}), 경사, 위사 및 바이어스 방향에 1%(2 mm) 인장에 필요한 힘(f_{warp} , f_{weft} , f_{bias})으로 설정하여 분석하였다.

선형 회귀분석을 진행하여 각 변수들의 유의확률을 확인한 다음, 직물의 역학적 특성으로부터 드레이프성을 예측할 수 있는 인공신경망 분석을 진행하였

다. 은닉층 뉴런의 수를 점차적으로 증가시키면서 프로그램의 학습 데이터의 행렬계산을 증가시킴으로써, 드레이프 계수에 대한 예측가능성을 확인하고자 하였다. 다수의 시료에 대한 회귀문제를 위한 신경망을 구현하는데 적합하다고 판단하여, 본 연구에서는 neuralnet 패키지를 사용하였다(Park, 2016). 본 연구에서의 인공신경망 모델링은 <Fig. 1>과 같은 단계를 통해 진행되었으며, 입력 및 출력 변수는 <Table 1>에 나타내었다. 데이터는 무작위로 훈련 데이터와 검증 데이터로 구분하였으며, 데이터 중 70%는 훈련 데이터로 30%는 검증 데이터로 활용하였다. 은닉층에서 뉴런의 활성화를 위해 로지스틱 함수를 사용하였다. 평균 제곱오차와 상관관계수 값의 비교를 통해 설계된 인공신경망 모델의 완성도를 평가하였다.

III. 결과 및 고찰

1. 드레이프성에 영향을 미치는 유의한 역학적 특성 인자 분석

역학적 특성값을 이용하여 드레이프성을 예측할 수 있도록 하기 위해 드레이프성을 종속변수로 하고

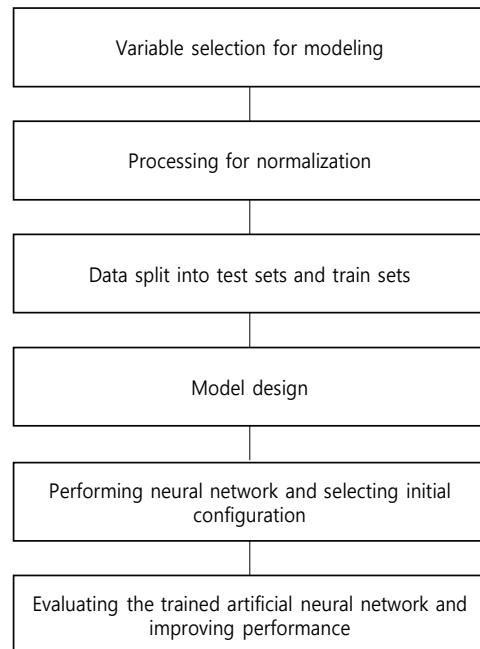


Fig. 1. Steps for artificial neural network analysis.

Table 1. Set of variables applied for modeling

Variable	Scale	Role
Grammage	Numerical	
m_{warp}	Numerical	
m_{weft}	Numerical	
c_{warp}	Numerical	Input
c_{weft}	Numerical	
c_{bias}	Numerical	
f_{warp}	Numerical	
Drapability	Numerical	Output

역학적 특성을 독립변수로 하는 회귀식을 구성하고자 하였으며, 설명력이 높은 회귀식을 구성하기 위해 다양한 조합을 사용하였다. 투입되는 인자 중 3가지(두께, f_{weft} , f_{bias})는 통계분석 시 유의하지 않아 탈락하였으며 최종적으로 7가지의 인자가 남게 되었다. 다중선형 회귀분석 결과, 무게, 경사와 위사에 대한 움직임 거리 값(m_{warp} , m_{weft}), 경사, 위사 및 바이어스 방향에 대한 인장-힘 2차 함수 그래프의 이차항의 계수(c_{warp} , c_{weft} , c_{bias}), 경사 방향에 1% 인장에 필요한 힘(f_{warp})을 독립 변수로 하고, 드레이프성을 종속변수로 하는 회귀식이 구성하였으며, 이의 결과를 <Table 2>에 나타내었다. 적합도가 높을 경우, 훈련 데이터에만 존재하는 특이한 연관성까지 불필요하게 반영되어 정확성이 떨어지는 ‘과적화’의 문제가 있기 때문에(Park, 2016), 이러한 모델을 기반으로 로지스틱 회귀분석을 진행하였으며, 77.6%의 Adjusted R²을 통해 적합도가 적절하다고 판단하였다. 요인 중에는 .05 이상인 값도 있었지만,

모델의 통계적 유의성을 결정하는 p 값이 2.2×10^{-16} 으로 .05보다 매우 작아, 유의수준 95%에서 도출된 회귀모델이 통계적으로 유의하다는 판단을 내렸다. 회귀분석의 예측모델을 통해 보았을 때, 무게와 바이어스 방향의 인장 특성(c_{bias})은 부적 영향을 미치는 반면, 무게, 경사와 위사에 대한 움직임 거리 값(m_{warp} , m_{weft}), 경사, 위사 방향에 인장 특성(c_{warp} , c_{weft}) 및 경사 방향 1% 인장에 필요한 힘(f_{warp})은 정적 영향을 미치는 것으로 나타났다. 이는 무게가 늘어남에 따라 드레이프 계수 값이 작아져, 직물이 늘어지는 특징을 갖게 되는 것을 의미한다. 또한 1% 신장에 필요한 힘의 크기가 커지고, 굽힘에 필요한 길이가 길어진 것과 움직임 거리 값이 커진 것 역시 모두 드레이프 계수가 커서 뻗뻗한 상태에서 일어나는 것으로 해석될 수 있다.

2. 인공신경망을 이용한 드레이프성 예측모델 개발

안정적인 인공신경망 모델을 구현해내기 위해서는 은닉층 뉴런의 수를 찾는 것이 첫 번째이며, 보통 한 개 이상의 은닉층 뉴런을 사용하였을 때 좋은 결과가 예상된다. 은닉층 뉴런의 수는 상관계수 값에 따라 선택되어야 하고, 그 값이 클수록 유의하다. 본 연구에서는 명목형 변수인 7가지 역학적 특성 값을 이용하여 드레이프성으로 만들어진 신경망 모델을 학습시키고, 이를 이용하여 역학적 특성 값을 알고 있는 시료들에 대해 드레이프 계수를 직접 측정하지 않더라도 예측할 수 있는 인공신경망 모델을 제안해 보고자 하였다. 입력 값 자체로 인공신경망을 학습시키는 경우, 셀 포화

Table 2. Regression analysis results for drapability

Dependent variable	Independent variables	Coefficients			Adjusted R ²	Model p-value
		Coefficients	Adjusted R ²	Model p-value		
Drapability	Intercept	4.520	2.682	-16.851	.776	<.001
	Grammage	-.001	.006	-.008		
	m_{warp}	1.045	.090	11.869		
	m_{weft}	1.286	.090	14.139		
	c_{warp}	.200	.200	.717		
	c_{weft}	2.884	1.497	1.927		
	c_{bias}	-.030	.030	-1.174		
	f_{warp}	.400	.200	1.893		

현상이 일어나 학습이 잘 이루어지지 않기 때문에, 인공신경망 구현 시 학습이 좀 더 쉽게 이루어질 수 있도록 전처리 과정을 추가하였다. 전처리 과정은 각 데이터의 값이 0에서 1 사이에 있도록 하는 정규화를 통해 이루어졌다(Park, 2016). 이후 입력 뉴런을 7가지(무게, m_{warp} , m_{weft} , c_{warp} , c_{weft} , c_{bias} , f_{warp})로 하고 출력 뉴런을 드레이프 계수로 설정하였다. 573개의 시료에 대해 70% 시료를 학습 데이터로 30% 시료를 검증 데이터로 사용하였으며, 처음 은닉층 뉴런의 수를 2로 설정하였을 때 은닉층 뉴런 수의 변화에 따른 오류와 수행한 횟수의 변화를 <Table 3>에서 확인할 수 있다. 프로그램에서의 63,556번 수행 중 34.072번의 에러를 보였으며, 이후 은닉층 뉴런의 수를 늘려 8로 설정하자 61,698번의 수행 중 20.906번의 에러를 보였다. <Eq. 3>을 통해 계산되는 MSE 또한 <Table 3>에 나타나 있는데, 여기서 주어진 오차값은 401개의 학습 데이터에 대한 제곱오차의 합이므로, 은닉층 뉴런이 3개인 경우 $31.615/401=.079$ 이며 은닉층 뉴런이 8개인 경우 하나의 데이터에 대한 평균 제곱오차는 $20.906/401=.052$ 이다. 은닉층 뉴런이 3개인 학습 데이터의 평균 제곱오차값인 .079와 비교해 은닉층 뉴런이 8개인 학습 데이터의 평균 제곱오차값은 .052로 더 작은 값이 확인되었다. 따라서 은닉층 뉴런의 수가 증가되는 경우 일반화가 더 잘 이루어졌다고 판단가능하다(Park, 2016).

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - o_i)^2 \quad \dots \text{Eq. 3.}$$

회귀문제의 경우 제곱오차와 상관계수를 이용하여 그 정확도를 평가하기 때문에(Park, 2016), <Eq. 4>와 같은 R 프로그램 내 cor 함수를 이용하여 신경망의 출

력 값과 목표 출력 값의 상관계수 값을 계산해 보았다. 은닉층 뉴런의 수가 2개인 경우 상관계수 값은 .859로 도출되었으며, 은닉층 뉴런의 수를 8로 설정한 경우 상관계수 값은 .863으로 도출되었다. 출력 데이터와 목표 데이터가 완벽한 의존관계를 가질 때 상관계수는 1.000이 되므로 .863은 신경망의 학습이 보다 안정적인 결과라는 해석이 가능하다. 따라서 인공신경망을 사용한 드레이프 계수의 예측모델이 실제 실험결과와 유사하게 나타나는 것을 확인할 수 있었다.

$$r = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{S_x} \right) \left(\frac{y_i - \bar{y}}{S_y} \right) \quad \dots \text{Eq. 4.}$$

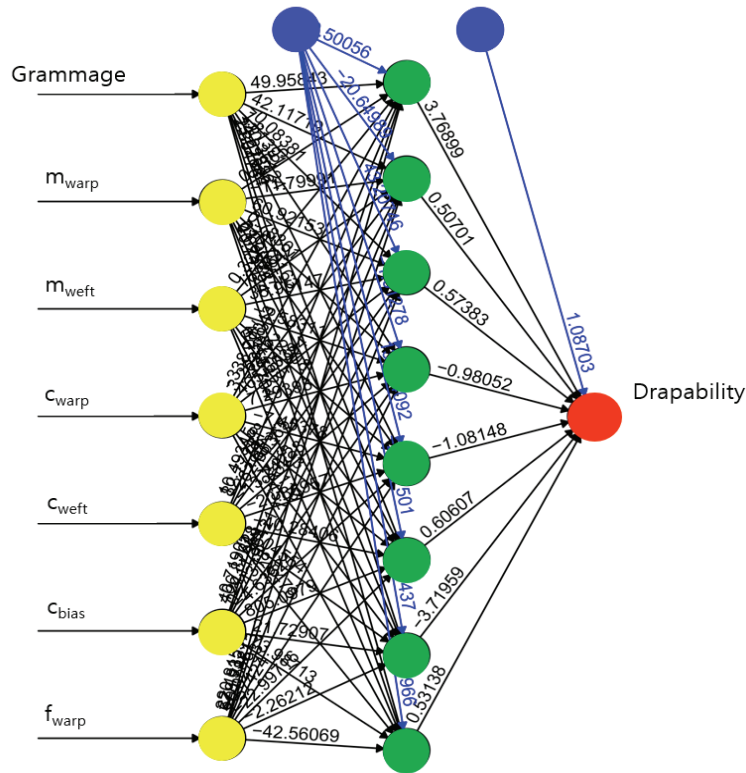
<Fig. 2>는 은닉층 뉴런의 수를 8로 설정하여 목표 데이터인 드레이프 계수를 학습시켰을 때의 출력 모습이다. 도식화 결과, 노란색으로 표시된 7개의 입력 변수와 초록색으로 표시된 은닉층 내 8개의 뉴런, 그리고 숫자로 기술되어 있는 각각의 가중치 값과 파란색으로 표시된 상수 뉴런, 빨간색으로 표시된 출력층을 확인해 볼 수 있었다. 예측모델 구현 시 무게, m_{warp} , m_{weft} , c_{warp} , c_{weft} , c_{bias} , f_{warp} 까지 총 7개의 인자를 이용하여 인공신경망 예측모델을 구성할 수 있음을 확인하였다.

IV. 요약 및 결론

드레이프 계수와 역학적 및 역학적 변수와의 관계가 비선형적으로 나타나는 점을 고려하여, 본 연구에서는 인공신경망을 이용한 드레이프 계수 예측모델을 제안하고자 하였다. 변수 선택을 위한 다중선형 회귀 분석에서, 드레이프 계수를 종속변수로 하고, 무게, 경

Table 3. Artificial neural network results for drapability according to number of hidden neurons

Dependent variable	Independent variables	Number of hidden neurons	Error	Steps	MSE
Drapability	Grammage	2	34.072	63,556	.078
	m_{warp}	3	31.615	47,595	.079
	m_{weft}	4	29.388	30,488	.730
	c_{warp}	5	28.869	28,004	.719
	c_{weft}	6	26.301	49,480	.065
	c_{bias}	7	25.277	54,972	.063
	f_{warp}	8	20.906	61,698	.052



Error: 20.90668, Steps: 61,698

Fig. 2. Neural network for drapability.

사와 위사에 대한 밀어낸 길이 값(m_{warp} , m_{weft}), 경사, 위사 및 바이어스 방향에 인장-힘 2차 함수 그래프의 이차항의 계수(c_{warp} , c_{weft} , c_{bias}), 경사 방향에 1% 인장에 필요한 힘(f_{warp})을 독립변수로 넣어서 예측식을 만들었다. 다중선형 회귀분석 결과 77.6%의 Adjusted R^2 을 통해 모델의 적합도가 적절하다고 판단하였으며, 유의수준 95%에서 도출된 회귀모델이 통계적으로 유의하다는 판단을 내렸다. 회귀분석을 통해 선택된 변수를 기반으로 neuralnet 패키지를 이용해 인공신경망 모델을 만들어 실제 측정 데이터와 비교해 보았다. 최종적으로 은닉층 뉴런이 8개인 모델이 평균 제곱오차값이 가장 작았으며 상관계수 값이 .863으로 안정적인 모델로 도출되었다. 이에 따라 직물의 무게, 경사와 위사에 대한 밀어낸 길이 값(m_{warp} , m_{weft}), 경사, 위사 및 바이어스 방향에 인장-힘 2차 함수 그래프의 이차항의 계수(c_{warp} , c_{weft} , c_{bias}), 경사 방향에 1%(2 mm) 인장에 필요한 힘(f_{warp})으로 직물의 드레이프 계수를 예측할 수 있

는 모델을 구성할 수 있었다. 본 연구에서 개발된 인공신경망 모델은 엔지니어링 및 고품질 의류 디자인에 사용되어질 수 있으며 동시에 의류 외관을 얻는데 중요한 데이터를 제공할 수 있다. 추가적인 연구를 통해 역학적 특성이 다른 직물과 편물을 구분하여 드레이프 예측모델을 구성함으로써, 좀 더 완성도가 높은 인공신경망 예측모델이 완성될 것으로 생각된다. 또한, 은닉층 뉴런의 수가 늘어날수록 기술기 소실문제나 학습 데이터 양이 부족하거나 계산이 오래 걸리는 문제가 발생할 수 있기 때문에, 신경망의 계층을 다층으로 구성하고 데이터의 특징을 다단 추출하여 정확한 판단이 가능한 드롭아웃(dropout)법과 ReLU 함수를 이용한 심화 연구가 필요하다.

References

Admuth, L. S., & Apte, S. (2010). Adaptive neuro-fuzzy infe-

- rence system with subtractive clustering: A model to predict fiber and yarn relationship. *Textile Research Journal*, 80(9), 841–846. doi:10.1177/0040517509355344
- Bi, W., Jin, P., Nienborg, H., & Xiao, B. (2018). Estimating mechanical properties of cloth from videos using dense motion trajectories: Human psychophysics and machine learning. *Journal of Vision*, 18(5):12. doi:10.1167/18.5.12
- Carrera-Gallissà, E., Capdevila, X., & Valldeperas, J. (2017). Evaluating drape shape in woven fabrics. *The Journal of the Textile Institute*, 108(3), 325–336. doi:10.1080/00405000.2016.1166804
- Chu, C. C., Cummings, C. L., & Teixeira, N. A. (1950). Mechanics of elastic performance of textile materials: Part V: A study of the factors affecting the drape of fabrics—The development of a drape meter. *Textile Research Journal*, 20(8), 539–548. doi:10.1177/004051755002000802
- Collier, B. J. (1991). Measurement of fabric drape and its relation to fabric mechanical properties and subjective evaluation. *Clothing and Textiles Research Journal*, 10(1), 46–52. doi:10.1177/0887302X9101000107
- Collier, B. J., Paulins, V. A., & Collier, J. R. (1989). Effects of interfacing type on shear and drape behavior of apparel fabrics. *Clothing and Textiles Research Journal*, 7(3), 51–56. doi:10.1177/0887302X8900700308
- Demiryürek, O., & Koç, E. (2009). Predicting the unevenness of polyester/viscose blended open-end rotor spun yarns using artificial neural network and statistical models. *Fibers and Polymers*, 10(2), 237–245. doi:10.1007/s12221-009-0237-z
- International Organization for Standardization. (1977, September). ISO 3801:1977 Textiles — Woven fabrics — Determination of mass per unit length and mass per unit area. *ISO*. Retrieved from <https://www.iso.org/standard/9335.html>
- International Organization for Standardization. (2008, April). ISO 9073-9:2008 Textiles — Test methods for nonwovens — Part 9: Determination of drapability including drape coefficient. *ISO*. Retrieved from <https://www.iso.org/standard/41375.html>
- Jeong, Y. J., Min, B. G., & Lee, J. S. (1999). A study on the repeatability of fabric drape. *Journal of the Korean Society for Clothing Industry*, 1(1), 50–55.
- Kanat, Z. E., & Özdil, N. (2018). Application of artificial neural network (ANN) for the prediction of thermal resistance of knitted fabrics at different moisture content. *The Journal of The Textile Institute*, 109(9), 1247–1253. doi:10.1080/00405000.2017.1423003
- Kim, H. J., Youn, S., Choi, J., Kim, H., Shim, M., & Yun, C. (2021). Indexing surface smoothness and fiber softness by sound frequency analysis for textile clustering and classification. *Textile Research Journal*, 91(1-2), 200–218. doi:10.1177/0040517520935211
- Kim, J., Kim, Y. J., Shim, M., Jun, Y., & Yun, C. (2020). Prediction and categorization of fabric drapability for 3D garment virtualization. *International Journal of Clothing Science and Technology*, 32(4), 523–535. doi:10.1108/IJCST-08-2019-0126
- Kim, J. S. (2020). *빅데이터 분석을 위한 R 프로그래밍* (2nd Edition) [R programming for big data analysis (2nd ed.)]. Seoul: Kame.
- Matusiak, M. (2015). Application of artificial neural networks to predict the air permeability of woven fabrics. *FIBRES & TEXTILES in Eastern Europe*, 23(1(109)), 41–48.
- Mitra, A., Majumdar, A., Majumdar, P. K., & Banerjee, D. (2012). Comparative analysis of regression and ANN models for predicting drape coefficient of handloom fabrics. *Indian Journal of Fibre & Textile Research*, 37(4), 313–320.
- Morooka, H., & Niwa, M. (1976). Relation between drape coefficients and mechanical properties of fabrics. *Journal of The Textile Machinery Society of Japan*, 22(3), 67–73. doi:10.4188/jte1955.22.67
- Niwa, M., & Seto, F. (1986). Relationship between drapability and mechanical properties of fabrics. *Sen'i Kikai Gakkaishi (Journal of the Textile Machinery Society of Japan)*, 39(11), T161–T168. doi:10.4188/transjtmjsj.39.11_T161
- Park, H. (2016). *신경회로망을 이용한 데이터 분석* [Data analysis using neural networks]. Seoul: CHAOS BOOK.
- Pattanayak, A. K., Luximon, A., & Khandual, A. (2011). Prediction of drape profile of cotton woven fabrics using artificial neural network and multiple regression method. *Textile Research Journal*, 81(6), 559–566. doi:10.1177/0040517510380783
- Peirce, F. T. (1930). 26—The “handle” of cloth as a measurable quantity. *Journal of the Textile Institute Transactions*, 21(9), T377–T416. doi:10.1080/19447023008661529
- Rolich, T., Šajatović, A. H., & Pavlinić, D. Z. (2010). Application of artificial neural network (ANN) for prediction of fabrics' extensibility. *Fibers and Polymers*, 11(6), 917–923. doi:10.1007/s12221-010-0917-8
- Sanad, R., Cassidy, T., & Cheung, V. (2012). Fabric and garment drape measurement - Part 1. *Journal of Fiber Bioengineering and Informatics*, 5(4), 341–358. doi:10.3993/jfbi12201201
- Süle, G. (2012). Investigation of bending and drape properties of woven fabrics and the effects of fabric constructional parameters and warp tension on these properties. *Textile Research Journal*, 82(8), 810–819. doi:10.1177/0040517511433152

- Taieb, A. H., Mshali, S., & Sakli, F. (2018). Predicting fabric drapability property by using an artificial neural network. *Journal of Engineered Fibers and Fabrics*, 13(3), 87–93. doi:10.1177/155892501801300310
- Yang, S., Pan, Z., Amert, T., Wang, K., Yu, L., Berg, T., & Lin, M. C. (2018). Physics-inspired garment recovery from a single-view image. *ACM Transactions on Graphics*, 37(5): 170. doi:10.1145/3026479

이 소 민

이화여자대학교 의류산업학과 대학원생

유 동 주

이화여자대학교 의류산업학과 박사수료

신 보 나

이화여자대학교 의류산업학과 대학원생

윤 선 영

Ph.D. Student in Fiber and Polymer Science,
Dept. of Textile Engineering, Chemistry, and Science,
North Carolina State University

심 명 희

한국섬유수출입협회 이사

윤 창 상

이화여자대학교 의류산업학과 조교수
