

Deep Learning-based Approach for Classification of Tribological Time Series Data for Hand Creams

Ji Won Kim* · You Min Lee* · Shawn Han** · Kyeongtaek Kim*[†]

*Department of Industrial and Management Engineering, Hannam University

**Teraleader

딥러닝을 이용한 핸드크림의 마찰 시계열 데이터 분류

김지원* · 이유민* · 한상헌** · 김경택*[†]

*한남대학교 산업경영공학과

**^(주) 테라리더

The sensory stimulation of a cosmetic product has been deemed to be an ancillary aspect until a decade ago. That point of view has drastically changed on different levels in just a decade. Nowadays cosmetic formulators should unavoidably meet the needs of consumers who want sensory satisfaction, although they do not have much time for new product development. The selection of new products from candidate products largely depend on the panel of human sensory experts. As new product development cycle time decreases, the formulators wanted to find systematic tools that are required to filter candidate products into a short list. Traditional statistical analysis on most physical property tests for the products including tribology tests and rheology tests, do not give any sound foundation for filtering candidate products. In this paper, we suggest a deep learning-based analysis method to identify hand cream products by raw electric signals from tribological sliding test. We compare the result of the deep learning-based method using raw data as input with the results of several machine learning-based analysis methods using manually extracted features as input. Among them, ResNet that is a deep learning model proved to be the best method to identify hand cream used in the test. According to our search in the scientific reported papers, this is the first attempt for predicting test cosmetic product with only raw time-series friction data without any manual feature extraction. Automatic product identification capability without manually extracted features can be used to narrow down the list of the newly developed candidate products.

Keywords : Time Series Classification, Deep Learning, Tribology, Cosmetics

1. 서 론

화장품 시장은 2009년부터 2018년까지 연평균 4%씩 성장하였으며, 스킨케어 제품은 전체 화장품 시장 중 39%를

차지하며 시장 성장의 60%의 비중을 이루고 있다[27]. 화장품 신제품 개발 과정에서 여러 후보 제품이 만들어지며, 이 제품이 출시하기에 적합한지를 판단하는 과정에 사전 교육을 받은 전문가들의 관능 평가가 포함된다[19].

화장품 시장에서 성공에 영향을 끼치는 주요 요인으로는 사용감, 배송 속도, 포장 상태, 사은품, 가격 등이 있으며, 사용감이 가장 큰 영향을 끼친다[14, 23]. 사용감은 제품 개발자들이 기대했던 특성을 갖추고 있는지 여

Received 15 August 2021; Finally Revised 14 September 2021;

Accepted 15 September 2021

[†] Corresponding Author : kkim610@gmail.com

부뿐만 아니라, 그 특성을 사용자가 인지하는지도 중요하다. 사용자들이 느끼는 화장품의 사용감은 관능 평가를 바탕으로 표현된다. 이는 관능 평가가 각 제품의 성격을 규정하는 과정에 매우 중요한 요소임을 의미한다. 문제는 관능 평가는 재정적으로 비용이 많이 소요될 뿐만 아니라, 시간도 많이 소요된다는 점이다. 게다가 화장품 구성 개별 요소의 거의 무시할 만한 작은 변화에도 관능 평가의 과정 전체를 다시 실행해야 하기 때문에 전문가를 통한 관능 평가는 인력 낭비를 가중시킨다.

이러한 관능 평가를 비용과 시간이 적게 드는 다른 방법으로 대체하기 위하여, 화장품의 물성을 측정 장비를 통해 측정된 다음, 측정된 물성값을 이용하여 관능 평가의 결과값을 예측하는 방법이 꾸준히 시도되었다[5].

화장품을 이용한 실험의 거의 모든 자료 분석에서 사용한 통계적 분석 방법과는 달리, 본 논문에서는 인공지능망을 이용한 연관 관계 분석이 가능한지를 탐색한다. 본 논문에서는 반복 실험한 원자료(raw data)를 어떠한 변환 없이, 인공지능망의 입력으로 사용하여, 실험 시 발생하는 노이즈에도 불구하고 실험에 사용한 화장품의 종류를 얼마나 잘 구별하는지를 살펴본다. 신뢰성 있는 결과가 나온다면, 이 연구는 화장품 실험 결과 분석에 새로운 방법을 제시하는 이정표가 될 것으로 사료된다.

2. 배경

사용자가 느끼는 화장품에 대한 감성은 화장품의 rheology 특성 및 tribology 특성을 모두 포함한다. 대량의 화장품이 가지는 물리적 특성은 rheology로 측정되며, sliding하는 두 표면 및 그 사이의 얇은 화장품 층의 특성은 tribology로 측정된다[10].

따라서, 화장품을 바르는 첫 느낌은 피부의 상태보다는 제품의 rheology 특성의 영향을 받으며, 화장품을 얇게 바르기 위한 동작들이 진행되면서 마찰 특성이 나타나므로, tribology 특성의 영향을 받게 된다[10].

화장품의 rheology 특성과 관련된 모든 연구는 측정된 화장품의 물성값을 미리 규정된 여러 척도값으로 변환한 다음, 이 척도값과 각 관능 특성값과의 관계를 통계적인 방법으로 추정하는 방식으로 연구하였다[1, 2, 3, 4, 6, 16, 22, 24]. 측정치를 변환한 입력값으로 일부 관능 특성 출력값의 예측이 가능하다는 연구는 있으나 [1, 4, 6, 21, 22], 관능 평가를 대체하지 못하고 있다[12]. 화장품의 윤활 특성과 마찰 특성 등을 다루는 tribology 연구는 극히 제한적이다[3, 13, 17, 18].

실험 데이터로부터 출력을 예측하기 위한 새로운 분석 방법을 모색해보자. 주어진 실험 데이터에 대하여, 지

금까지 시도하지 않았던 새로운 변환 방식을 찾아내어 전통적 방법으로 연관 관계를 분석하거나, 통계적 방법이 아닌 완전히 새로운 분석 방법을 사용하는 방법이 있을 수 있다.

화장품의 물성 특성값으로부터 출력값을 추정하는 대부분의 연구는 Spearman 상관 계수를 구하거나, 선형 회귀 분석 혹은 비선형 회귀 분석을 사용하였다[1, 2, 4, 6, 16, 18, 22]. 다수의 물성 특성을 이용하여 분석하는 경우, 주성분 분석(Principal Component Analysis)을 통하여 소수의 주성분(Principal Component)을 독립 변수로 선택하여 분석하였다[10, 12, 24]. 연구에 따라 새로운 변수들로 변환하여 보다 나은 예측력을 보인 논문들도 있다. 그러나, 물성 특성값들로 만들 수 있는 조합은 기하급수적으로 많으므로, 출력값 대부분을 예측 가능하게 하는 물성 특성값들의 조합들을 지금과 같은 방법으로 찾아낸다면 예측력의 향상은 계속 될 것으로 보이지만, 신뢰성 있는 예측력을 갖기 위해서는 앞으로 많은 연구가 필요하다.

최근 인공지능망은 다양한 분야로 그 응용 분야를 확대하고 있으나 화장품에 대한 적용은 드물다. Nakano et al. [17]은 화장품 파운데이션을 sliding test에 적용하여 얻은 시계열 신호로부터 미리 정한 물성 특성값들을 추출하고, 이 물성 특성값들을 입력으로 받아 화장품의 5가지 촉각 특성값으로 결과를 배출하는 인공지능망을 구성하였다. 이 연구가 화장품 tribology 연구 분야에서 인공지능망을 사용한 유일한 연구이다.


인공지능망은 입력과 출력으로 네트워크를 훈련시키는 과정에서 비용 함수를 최소화하는 최적화 과정을 통하여 입력 변수로부터 특성 벡터(feature vector)를 스스로 추출하는 특성을 가진다. 자동으로 특성 벡터를 추출하는 기능을 가진 컴퓨터가 물체 인식 분야에서 2015년부터 인간보다 우수해졌으며[20], 이는 컴퓨터의 특성 추출 능력이 인간의 특성 추출 능력보다 앞서기 시작한 것으로 해석될 수 있다. 따라서, 화장품 실험 데이터에 대해서도 실험 분석자가 출력에 영향을 끼치는 물성 특성값들을 찾아낸 후, 그들의 최적 조합을 통계적으로 찾아내는 방법보다, 인간의 개입 없이 컴퓨터가 학습을 통하여 특성을 추출하고, 이를 바탕으로 결과를 예측할 때, 정확도가 통계적 방법보다 높은지 살펴보자.

3. 실험장치 및 실험방법


본 논문에서 수행한 실험에서 사용한 장비는 Tactile Electronic Sensing Actuator Neural Network(TESSAN, (주) 테라리더)이며, <Figure1>과 같이 구성되어 있다. 장비의 VCA(Voice Coil Actuator)는 수평의 힘(F_x)을 측정한다.

전자저울(Weight Balance)은 Upper Silicon Tip(원형, Φ 10mm)이 피부와 유사하게 가공된 아래쪽 실리콘(사각형, 두께:3.5mm)을 누르는 수직의 힘(F_N)을 측정한다. 정확한 위치와 힘을 조절하기 위해 서보모터를 이용한 선형 액츄에이터가 사용되고, PC의 UI와 연결되어 작동하는 초고속 데이터 측정 장비이다.

Tribology 실험은 다음과 같이 진행된다. VCA가 정지된 상태에서 설정된 속도에 도달할 때까지 속도를 증가시키며 연속 실험한다. 마찰력은 F_N 방향으로 두 실리콘 면을 접촉시킨 후, 설정된 속도에 맞춰 F_N 의 방향으로 움직이면 1kHz의 sampling rate로 시계열 데이터의 VC load[N]로 저장된다. 단, 각 속도마다 VCA의 움직이는 거리는 1초에 갈 수 있는 거리의 70%만 움직이도록 설정하고, 최대 15mm까지 움직이게 한다. <Figure 2>는 tribology 실험을 통해 얻어진 시계열 데이터의 그래프를 보여준다.



<Figure 2> Time-varying Signal of VC Load Acquired from TESAN with a Cosmetic Sample



<Figure 1> Schematic Diagram of TESAN


4. 분석방법

4.1 딥러닝

실험을 통하여 얻은 마찰력 시계열 데이터는 매 실험마다 그 값에 변화가 있다. 이러한 변화에도 불구하고, 실험 데이터를 입력으로 주었을 때, 인공지능망을 통하여 실험에 사용한 화장품을 분류하는 것이 본 실험의 목적이다. 따라서 주어진 문제는 시계열 분류 문제로 정의할 수 있다. 시계열 분류 문제를 해결하기 위한 알고리즘은 수백 가지가 넘는다.

최근에 여러 연구에서 입력부터 출력까지 종단 간(end-to-end) 학습이 가능한 여러 딥러닝 방법이 제안되었다 [7, 9, 15, 25, 26]. 공개된 UCR/UEA의 시계열 데이터 셋을 이용하여, 제안된 여러 딥러닝 네트워크를 비교한 연구에서 Fully Convolutional Network(FCN)와 Residual Neural Network(ResNet)가 가장 성능이 좋은 것으로 보고되었다[8, 25]. 이에 본 연구에서는 FCN과 ResNet을 사용한다.

FCN은 세 개의 중첩 블록을 가지며, 각 중첩 블록은 <Figure 3>과 같이 중첩 레이어, 배치 정규화, ReLU 활성화



<Figure 3> Network Structure of FCN and ResNet[25]

함수로 구성된다. 중첩 레이어의 필터의 수는 차례로 128, 256, 128을 가지며, 필터의 사이즈는 중첩 레이어 순서대로 8, 5, 3이다. 세 번째 중첩 블록의 출력은 모든 시간에 대하여 평균을 취하는 Global Average Pooling(GAP) 레이어로 입력된다. GAP 레이어의 출력은 Softmax의 입력으로 들어간다.


중첩 뉴럴넷의 층(layer)을 더 쌓으면 성능이 향상된 아주 깊은 네트워크를 구현할 수 있다. 하지만, 실제로 어느 정도 이상 깊어진 네트워크는 오히려 Vanishing gradient 문제 때문에 역전파가 제대로 이루어지지 않아 성능이 더 떨어진다. 2015년에 발표된 ResNet[11]에서는 입력값을 출력값에 더해주는 지름길(shortcut)을 만들어 이러한 문제를 해결하였다. 본 연구에서 사용한 ResNet은 3개의 Residual 블록과 GAP 레이어 및 Softmax로 구성되어 있다. 각 Residual 블록은 <Figure 3>과 같이 3개의 중첩 레이어로 구성되며 블록의 출력은 그 블록의 입력과 더해져서 다음 Residual 블록의 입력이 된다. 각 블록에서 중첩 레이어의 필터 수는 동일하며, 차례로 64, 128, 128이다. 각 블록에서 필터 사이즈는 순서대로 8, 5, 3이다.

4.2 머신러닝

Tribology 실험에서 얻은 raw data로부터 다음과 같은 5가지 특성을 추출한다. 각 특성의 정의는 <Table 1>에 나타내었으며, <Figure 4>에 그림으로 나타내었다.

<Table 1> Definition of Manually Extracted Features

Extracted Features	Definition
Peak of VC load (PEAK)	Maximum of static friction force
Time to peak (PEAK-t)	Time to peak of VC load
Area under the curve 1 (AUC-1)	Area under the curve from start to the peak of VC load
Area under the curve 2 (AUC-2)	Area under the curve from the peak of VC load to the end of the curve
Increasing friction rate (IFR)	AUC-1 divided by PEAK-t



<Figure 4> Description of Manually Extracted Features

5가지 특성값을 입력으로 받아, 실험에 사용된 화장품을 예측하기 위한 머신러닝 방법으로 서포트 벡터 머신 (Support Vector Machine, SVM), k-최근접 이웃(k-Nearest Neighbors, k-NN) 알고리즘, 랜덤 포레스트(Random Forest, RF) 알고리즘, 그래디언트 부스팅(Gradient Boosting, GB) 알고리즘, 익스트림 그래디언트 부스팅 (eXtreme Gradient Boosting, XGBoost) 알고리즘을 이용한다. 각 머신러닝 기법은 다음과 같이 설명할 수 있다. SVM은 결정 경계 (decision boundary)와 서포트 벡터 사이의 마진(margin)을 최대화하는 초평면(hyperplane) 형태의 결정 경계를 찾는 방법이다. k-NN은 파라미터 k가 주어지면 데이터 간의 거리를 기반으로 가장 가까운 k개의 데이터들의 투표를 통해 분류를 진행한다. RF는 여러 개의 결정 트리를 생성한 다음 각 트리 예측값 중에서 가장 많은 선택을 받은 레이블로 예측하는 앙상블 학습방법이다. GB 및 XGBoost는 모두 부스팅(boosting) 기법을 활용한다. 부스팅은 이전 단계의 분류 방법을 보완해 나가며 성능을 강화하는 방법이다. GB는 경사하강법(Gradient Descent)을 이용해 가중치의 업데이트를 반복하며 오류를 최소화하는 분류를 찾아간다. XGBoost는 GB의 속도와 성능을 개선한 방법이다.

4.3 성능 평가 척도

머신러닝 및 딥러닝에서 분류(Classification) 기법은 주어진 입력 데이터를 학습하여 결과값에 따라 카테고리를 정하는 방법으로 두 개의 클래스로 분류하는 이진(binary) 분류와 셋 이상의 클래스로 분류하는 다중(multi-class) 분류로 나누어진다. 분류 문제에 대하여 모형을 적용하여 얻은 결과는 혼동 행렬(Confusion Matrix)로 요약하여 나타낸다. <Table 2>는 이진 분류 문제의 혼동 행렬을 나타낸다.

<Table 2> Confusion Matrix of Binary Classification Problem

Data Class	Predicted as True	Predicted as False
True	TP (True Positive)	FN (False Negative)
False	FP (False Positive)	TN (True Negative)

TP(True Positive)는 실제로 화장품 A로 실험했는데, 화장품 A로 실험한 것으로 올바르게 예측된 경우를 나타내며, FP(False Positive)는 화장품 A가 아닌 다른 화장품으로 실험했는데, 화장품 A로 실험한 것으로 잘못 예측된 경우를 나타낸다. 그리고, FN(False Negative)은 화장품 A로 실험했는데, 화장품 A가 아닌 다른 화장품으로 실험한 것으로 잘못 예측된 경우를 표현하며, TN(True Negative)은 화장품 A가 아닌 다른 화장품으로 실험했는데, 화장품 A가 아닌 화장품으로 실험한 것으로 올바르게 예측된 경우를 표현한다.

<Table 3> Metrics for Multi-class Classification

Metrics	Formula	Description
Precision	$\frac{1}{K} \sum_{i=1}^K \frac{TP_i}{TP_i + FP_i}$	An average per-class agreement of the data class labels with those of a classifiers
Recall	$\frac{1}{K} \sum_{i=1}^K \frac{TP_i}{TP_i + FN_i}$	An average per-class effectiveness of a classifier to identify class labels
F1-score	$\frac{2 \times precision \times recall}{precision + recall}$	The harmonic mean of the precision and recall

K denotes the number of class.

그러나, 다중 분류 문제에서 서로 다른 모형의 혼동 행렬을 비교하기는 쉽지 않으므로, 정밀도(Precision), 재현율(Recall), F1-점수(F1-score) 등의 척도를 사용하여 성능을 나타낸다. 각 class 별 sample의 수가 균형을 이루는 경우, 성능 척도의 정의와 수식은 <Table 3>에 나타나 있다.

5. 실험 및 분석

5.1 실험

시중에 판매 중인 핸드크림 9개(A ~ I)를 무작위로 골라 실험에 사용하였다. 단, 제품 A와 제품 B는 동일 회사 제품으로 향과 제형이 다른 제품이다. 그 외 제품은 서로 다른 회사 제품이다. 각 핸드크림 제품별로 6회 실험을 진행하였다. 한 핸드크림을 1회 실험한 결과로 속도와 이동 거리가 상이한 281개의 데이터 셋이 확보된다. 속도에 따른 데이터의 크기가 다르므로, 모두 동일하게 맞추기 위하여 시계열 데이터 개수를 2000개로 맞추었다. 실험을 통하여 확보한 데이터의 크기는 9 x 6 x 281 개의 데이터 셋이며, 각 데이터 셋은 2000개의 시계열 데이터로 이루어져 있다.

5.2 파라미터 세팅

FCN 및 ResNet을 사용할 때, Adam Optimizer를 사용하였으며, 학습률은 0.001이고, 만일 loss가 30 epoch 이내에 향상되지 않으면, 학습률을 0.5배 감소시키는 방법을 사용하여 90 epoch으로 훈련하였다. Google Colab에서 GPU를 사용하여 프로그램을 수행하였으며, 훈련에 FCN은 약 1시간, ResNet은 약 4시간이 소요되었다.

5.3 결과 및 비교

9가지의 핸드크림을 사용하여 마찰 시계열 데이터를 얻는 실험에서 마찰 시계열 데이터로부터 어떤 핸드크림을 사용하였는지를 예측하는 문제를 SVM, k-NN, RF, GB, XGBoost, FCN, ResNet 모형을 사용하여 수행하였다. SVM, k-NN, RF, GB, XGBoost 모형의 입력 자료로 마찰 시계열 자료로부터 추출한 5가지 특성치를 사용하였으며, 핸드크림에 따른 5가지 특성값의 평균과 표준편차는 <Table 4>에 나타나있다. FCN 및 ResNet 모형의 입력 자료로는 마찰 시계열 자료를 가공 없이 사용하였다. 각 모형을 수행한 결과에 대한 성능 지표를 <Table 5>에 나타내었다.


<Table 4> Statistics of Manually Extracted Features for Each Hand Cream Product

	Product	A	B	C	D	E	F	G	H	I
PEAK	Mean	0.2099	0.1637	0.1705	0.2821	0.1348	0.1555	0.1398	0.1210	0.1045
	SD	0.1180	0.1303	0.1187	0.2590	0.1109	0.1063	0.0844	0.0505	0.0575
PEAK-t	Mean	0.4673	0.5387	0.4916	0.5086	0.4965	0.5648	0.4749	0.4652	0.4681
	SD	0.2424	0.2758	0.2586	0.2602	0.2581	0.2932	0.2484	0.2587	0.2793
AUC-1	Mean	21.451	26.533	29.672	36.967	20.232	27.373	15.554	20.001	17.298
	SD	22.969	23.785	33.284	36.746	19.119	27.246	17.255	26.675	25.749
AUC-2	Mean	143.658	110.109	210.569	214.277	153.925	124.289	93.801	154.764	113.98
	SD	40.663	33.711	64.354	109.696	101.009	54.572	31.869	47.721	35.256
IFR	Mean	37.945	43.582	49.034	69.955	34.881	40.424	26.893	29.784	24.573
	SD	23.489	28.139	39.886	56.002	26.123	28.092	20.038	29.605	24.605

<Table 5> Performance Results of Each Model

Model	Precision	Recall	F1-score
SVM	0.5408	0.5020	0.5011
k-NN	0.4950	0.4950	0.4948
RF	0.8163	0.8160	0.8158
GB	0.6741	0.6728	0.6719
XGBoost	0.7787	0.7769	0.7771
FCN	0.8207	0.8054	0.8056
ResNet	0.9187	0.9161	0.9157

9가지 핸드크림 제품 중에서 실험에 사용한 제품을 맞추는 문제에 대한 분석 모형의 성능을 F1 점수로 살펴보면 ResNet 모형이 0.9157로 가장 우수하였다. 다음으로 RF 모형이 0.8158이고, FCN 모형이 0.8056, XGBoost 모형이 0.7771 순서이다. 3가지 성능 지표(즉, 정밀도, 재현율, F1-점수) 모두에서 ResNet 모형이 가장 우수하였으며, RF 모형과 FCN 모형, XGBoost 모형이 다음으로 우수하였다. 머신러닝 모형보다, 딥러닝 모형이 상대적으로 우수하였다. 가장 우수한 ResNet 모형을 적용한 결과에 대한 혼동 행렬을 <Figure 5>에 나타내었다.



<Figure 5> Confusion Matrix of ResNet Model

마찰 시계열 데이터로부터 데이터 획득에 사용한 핸드크림을 신뢰성 있게 예측하는 모형을 찾아냈으므로, 이를 이용하여 신제품의 tribology 특성과 가장 유사한 특성을 갖는 기존 제품이 어떤 제품인지 예측하는 추가 분석을 실행하였다. 제품 A를 신제품이라 가정하고, 제품 B부터 제품 I를 기존 제품이라 가정하였다. 추가 분석에는 앞에서 상대적으로 우수한 모형으로 밝혀진 RF 모형, XGBoost 모형, FCN 모형 및 ResNet 모형을 사용하였다. Training data 및 Validation data로 기존 제품으로

가정한 8개 제품(B~I)의 마찰 시계열 데이터를 사용하고, Test data로 제품 A의 마찰 시계열 데이터를 사용하였다. 그 결과는 <Table 6>에 나타냈다.

<Table 6> Classification Results of a New Product A

Product	RF	XGBoost	FCN	ResNet
B	0.31	0.28	0.18	0.16
C	0.21	0.22	0.08	0.09
D	0.02	0.04	0.11	0.05
E	0.03	0.05	0.00	0.00
F	0.08	0.08	0.06	0.03
G	0.18	0.16	0.34	0.31
H	0.07	0.07	0.15	0.19
I	0.09	0.08	0.07	0.15

<Table 6>은 RF 모형의 결과와 XGBoost 모형의 결과가 유사하고, FCN 모형의 결과와 ResNet 모형의 결과가 유사함을 보여준다. RF 모형과 XGBoost 모형은 결정 나무를 기반으로 한 후, 추가적인 방법을 사용하여 성능을 높였기 때문에 추가 실험 결과에서 서로 유사성을 가지는 것으로 보인다. RF 모형과 XGBoost 모형에서는 제품 B가 제품 A와 가장 유사했고, FCN 모형과 ResNet 모형에서는 제품 G가 가장 제품 A와 유사하다는 결과를 확인하였다.

6. 결론

화장품의 물성을 이용한 실험 결과 데이터로 화장품의 관능 검사 결과 값을 예측하려는 시도는 오랫동안 계속 되어 왔으나, 일부 물성의 조합이 일부 관능 특성의 예측에 사용할 수 있다는 수준에 머무르고 있다. 이러한 예측에 사용된 대부분의 분석방법은 통계적 분석으로 한정 되어 있다.

이에 본 연구에서는 머신러닝 모형과 딥러닝 모형을 사용하는 분석 방법의 가능성을 살펴보았다. 본 연구에서는 새로 개발한 핸드크림 신제품의 마찰 특성이 기존의 어떤 제품과 유사한지 판단하는 문제에 딥러닝 모형 및 머신러닝 모형의 적용 가능성을 검토하였다. 딥러닝 모형(FCN 및 ResNet 모형)에서는 특성 추출 없이 원자료를 입력으로 사용하였으며, 머신러닝 모형(SVM, k-NN, RF, GB, XGBoost 모형)에서는 실험을 통하여 얻은 마찰 시계열 데이터로부터 5가지 특성을 추출하여 입력으로 사용하였다. 각 모형을 적용한 결과로부터 혼동 행렬을 얻고, 이로부터 3가지 성능 지표를 추출하여 비교한 결과, 3가지 성능 지표 모두에서 ResNet 모형이 가장 우수하였으며, 다음으로 RF 모형, FCN

모형 및 XGBoost 모형이 우수하였다. 이는 딥러닝의 특성 추출 능력이 인간의 특성 추출 능력보다 앞선다는 여러 연구의 결과와도 일치한다. 이러한 성능을 바탕으로 새롭게 개발된 제품의 tribology 특성을 머신러닝 모형과 딥러닝 모형에 적용하여 기존의 제품 중 가장 유사성을 띠는 제품을 예측할 수 있음을 보여 주었다.

본 연구는 화장품의 물성 실험 결과를 새로운 특성 변수들로 변환한 후 통계적 분석을 해 왔던 기존 연구와는 달리, 원자료를 가공 없이 딥러닝 모형의 입력으로 사용하여 분석한 결과가 훨씬 우수함을 보여준 최초의 논문이다. 이는 딥러닝 모형이 화장품 실험 결과를 분석하는 신뢰도가 높은 새로운 방법임을 시사한다.

본 연구는 사용자의 화장품을 바르는 행동을 모방하는 것에 한계를 가진다. 사용자가 화장품을 바를 때, 본 논문처럼 가속 후 일정한 속도로 바르는 경우는 없다. 대부분의 사용자는 가속, 등속, 감속 등 접촉 속도를 달리 한다. 아울러, 화장품을 바르는 부위에 따라 직선 운동, 원운동 등 다양한 패턴으로 화장품을 펴 바른다. 이러한 속도의 변화와 패턴을 반영하여 소비자의 행동을 모방하는 tribology 실험을 한다면 본 연구보다 실제 소비자 행동에 조금 더 가까운 실험 결과를 얻을 수 있을 것으로 기대된다.

Acknowledgement

This research was supported by R&BD Program through the INNOPOLIS funded by Ministry of Science and ICT (2020-IT-RD-0240).

References

- [1] Adejokun, D.A. and Dodou, K., Quantitative Sensory Interpretation of Rheological Parameters of a Cream Formulation, *Cosmetics*, 2020, Vol. 7, No. 1, <https://doi.org/10.3390/cosmetics7010002>.
- [2] Ahuja, A., Lu, J., and Potanin, A., Rheological Predictions of Sensory Attributes of Lotions, *Journal of Texture Studies*, 2019, Vol. 50, No. 4, pp. 295-305.
- [3] Alisa, E., Jasmina, H., Ognjenka, R., and Edina, V., Measuring the Feeling: Correlations of Sensorial to Instrumental Analyses of Cosmetic Products, 2017, *Proceedings of the International Conference on Medical and Biological Engineering*, 2017, pp. 425-428.
- [4] Bae, J.-E., Ryoo, J.-Y., and Kang, N.-G., Effects of Linear and Nonlinear Shear Deformation on Measurement for Stickiness of Cosmetics Using Rotational Rheometer, *Korea Journal of Cosmetic Science*, 2020, Vol. 2, No. 1, pp. 33-46.
- [5] Baki, G., Szoboszlai, M., Liberatore, M.W., and Chandler, M., Application of Check-all-that-apply (CATA) Questions for Sensory Characterization of Cosmetic Emulsions by Untrained Consumers, *Journal of Cosmetic Science*, 2018, Vol. 69, No. 2, pp. 83-100.
- [6] Calixto, L.S., Infante, V.H.P., and Campos, P.M.B.G.M., Design and Characterization of Topical Formulations: Correlations between Instrumental and Sensorial Measurements, *AAPS PharmSciTech*, 2018, Vol. 19, pp. 1512-1519.
- [7] Cui, Z., Chen, W., and Chen, Y., Multi-Scale Convolutional Neural Networks for Time Series Classification, ArXiv 1603.06995, 2016.
- [8] Fawaz, H.I., Forestier, G., Weber, J., Idoumghar, L., and Muller, P.-A., Deep Learning for Time Series Classification: a Review, *Data Mining and Knowledge Discovery*, 2019, Vol. 33, pp. 917-963.
- [9] Geng, Y. and Luo, X. Cost-Sensitive Convolution based Neural Networks for Imbalanced Time-Series Classification. ArXiv 1801.04396, 2018.
- [10] Guest, S., McGlone, F., Hopkinson, A., Schendel, Z. A., Blot, K., and Essick, G., Perceptual and Sensory-Functional Consequences of Skin Care Products, *Journal of Cosmetics, Dermatological Sciences and Applications*, 2013, Vol. 3, No. 1, pp. 66-78.
- [11] He, K., Zhang, X., Ren, S., and Sun, J., Deep Residual Learning for Image Recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770-778.
- [12] Huynh, A., Garcia A.G., Young, L. K., Szoboszlai, M., Liberatore, M. W., and Baki, G., Measurements meet Perceptions: Rheology-Texture-Sensory Relations when using Green, Bio-derived Emollients in Cosmetic Emulsions, *International Journal of Cosmetic Science*, 2021, Vol. 43, pp. 11-19.
- [13] Kwon, Y.-H., Kwon, H.-J., Rang, M.-J., and Lee, S.-M., A Study on Correlation between Frictional Coefficients and Subjective Evaluation while Rubbing Cosmetic Product on Skin, *Science of Emotion and Sensibility*, 2005, Vol. 8, No. 4, pp. 385-391.
- [14] Lee, J.H. and Kim, J.J., A Study on the Influence of Package Design of Female Cosmetics on Purchasing Preference, *Journal of the Society of Korea Industrial and Systems Engineering*, 2004, Vol. 27, No. 3, pp.

- 52-58.
- [15] Mittelman, R., Time-Series Modeling with Undecimated Fully Convolutional Neural Networks. ArXiv 1508.00317, 2015.
- [16] Moravkova, T. and Filip, P., Relation between Sensory Analysis and Rheology of Body Lotions, *International Journal of Cosmetic Science*, 2016, Vol. 38, No. 3, pp. 558-566.
- [17] Nakano, K., Horiuchi, K., Soneda, T., Kashimoto, A., Tsuchiya, R., Yokoyama, M., A Neural Network Approach to Predict Tactile Comfort of Applying Cosmetic Foundation, *Tribology International*, 2010, Vol. 43, No. 11, pp. 1978-1990.
- [18] Nakano, K., Kobayashi, K., Nakao, K., Tsuchiya, R., Nagai, Y., Tribological Method to Objectify Similarity of Vague Tactile Sensations Experienced during Application of Liquid Cosmetic Foundations, *Tribology International*, 2013, Vol. 63, pp. 8-13.
- [19] Pensé-Lh eritier, A.-M., Recent Developments in the Sensorial Assessment of Cosmetic Products: a Review, *International Journal of Cosmetic Science*, 2015, Vol. 37, No. 5, pp. 465-473.
- [20] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., and Li, F.-F., ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision*, 2015, Vol. 115, pp. 211-252.
- [21] Ryoo, J.-Y., Bae, J.-E., and Kang, N.-G., Optimization of In Vivo Stickiness Evaluation for Cosmetic Creams Using Texture Analyzer, *Journal of the Society of Cosmetic Scientists of Korea*, 2020, Vol. 46, No. 4, pp. 371-382.
- [22] Savary, G., Gilbert, L., Grisel, M., and Picard C., Instrumental and Sensory Methodologies to Characterize the Residual Film of Topical Products Applied to Skin, *Skin Research and Technology*, 2019, Vol. 25, No. 4, pp. 415-423.
- [23] Shin, Y.S. and Baek, D.H., A Methodology for Customer Core Requirement Analysis by Using Text Mining : Focused on Chinese Online Cosmetics Market, *Journal of Society of Korea Industrial and Systems Engineering*, 2021, Vol. 44, No. 2, pp. 66-77.
- [24] Vergilio, M. M., de Freitas, A. C. P., da Rocha-Filho, P. A., Comparative Sensory and Instrumental Analyses and Principal Components of Commercial Sunscreens, *Journal of Cosmetic Dermatology*, 2021, Early View (Online Version of Record before inclusion in an issue) as of 2021/09/17.
- [25] Wang, Z., Yan, W., and Oates, T., Time Series Classification from Scratch with Deep Neural Networks : A Strong Baseline, ArXiv: 1611.06455, 2016.
- [26] Zhao, B., Lu, H., Chen, S., Liu, J., and Wu, D., Convolutional Neural Networks for Time Series Classification, *Journal of Systems Engineering and Electronics*, 2017, Vol. 28, No. 1, pp. 162-169.
- [27] <https://www.loreal-finance.com/en/annual-report-2018/cosmetics-market-2-1/> (2021.7.1 access).

ORCID

- Ji Won Kim | <http://orcid.org/0000-0002-7955-2750>
 You Min Lee | <http://orcid.org/0000-0002-0324-0400>
 Shawn Han | <http://orcid.org/0000-0002-3418-5344>
 Kyeongtaek Kim | <http://orcid.org/0000-0002-5636-2487>