

<http://dx.doi.org/10.17703/JCCT.2024.10.5.163>

JCCT 2024-9-19

신경망분석기법을 이용한 패션 아이웨어 구매결정요소에 관한 연구

Neural Network Analysis of Determinants Affecting Purchase Decisions in Fashion Eyewear

김지민*

Kim Ji Min*

요약 본 연구는 30~40대 여성의 패션 아이웨어 구매결정 요인을 분석하기 위해 신경망 분석 기법을 적용하여 전통적인 모수적 분석 기법과 비교하였다. 패션 분야에서 신경망 등 머신러닝 기법은 맞춤형 패션 추천시스템에 많이 적용되는데, 국내 연구사례는 아직 미흡하다. 본 연구는 2017년에 전통적 계량기법으로 수행된 연구를 신기술로 다시 분석하여, 양자를 비교함으로써 신경망 기법의 유용성을 확인하고자 한다. 본 연구는 L-BFGS-B 신경망을 하이퍼볼릭 탄젠트로 활성화 시킬 때, 소비자들이 선호하는 디자인형태에 대한 분류정확도가 86.2%로 가장 좋았다. 소비자의 직업과 새로운 스타일에 대한 추구가 가장 중요한 구매결정요인이었다. 한국의 선글라스 소비자들은 "안전한 변화"를 가장 선호하는 것으로 해석된다. 이런 분석 결과는 선글라스 프레임 및 렌즈에 있어서도 동일하게 나타난다. 전통적인 계량분석의 결과물은 소비자가 어떤 집단에 속하는지 여부에 따라 선호하는 선글라스의 종류가 다르다고 본다. 이에 비해 신경망분석의 결과물은 각 개인별로 선호하는 선글라스를 개인별로 예측해준다. 이것이 기여하는 바는 개인별 맞춤형 선글라스 추천 시스템을 개발할 수 있게 해준다.

주요어 : 패션 아이웨어, 신경망기법, 다층 퍼셉트론, 소비자선호, 선글라스 디자인

Abstract This study applies neural network analysis techniques to examine the factors influencing the purchasing decisions of fashion eyewear among women in their 30s and 40s, comparing these findings with traditional parametric analysis methods. In the fashion area, machine learning techniques are utilized for personalized fashion recommendation systems. However, research on such applications in Korea remains insufficient. By reanalyzing a study conducted in 2017 using traditional quantitative methods with these new techniques, this study aims to confirm the utility of neural network methods. Notably, the study finds that the classification accuracy of preferred sunglasses design is highest, at 86.2%, when the L-BFGS-B neural network is activated using the hyperbolic tangent function. The most critical factors influencing purchasing decisions were consumers' occupations and their pursuit of new styles. It is interpreted that Korean sunglasses consumers prefer "safe changes." These findings are consistent for selecting both the frames and lenses of sunglasses. Traditional quantitative analysis suggests that the type of sunglasses preferred varies according to the group to which a consumer belongs. In contrast, neural network analysis predicts the preferred sunglasses for each individual, thereby facilitating the development of personalized sunglasses recommendation systems.

Key words : Fashion Eyewear, Neural Network Techniques, Multi-layer Perceptron, Consumer Preference, Sunglasses Design

*국립강릉원주대학교 패션디자인학과 부교수 (단독저자)
접수일: 2024년 6월 11일, 수정완료일: 2024년 7월 12일
게재확정일: 2024년 9월 1일

Received: June 11, 2024 / Revised: July 12, 2024

Accepted: September 1, 2024

*Corresponding Author:kimjm@gwnu.ac.kr

Dept. of Fashion Design, Gangneung-Wonju National Univ,
Korea

I. 서 론

신경망분석(Neural Network Analysis)은 인공지능 시대의 서막을 열었다. 인공지능은 머신러닝(Machine Learning)과 로봇프로세스자동화(Robotic Process Automation)으로 구성되는데, 신경망분석은 머신러닝의 핵심 기법 중 하나이다. 이것은 다층 퍼셉트론(Multilayer perceptron)을 이용하여 복잡한 문제를 예측하는 데 효과적이며, 예측 정확도가 높다.

최근 연구에서도 심층 신경망(Deep Neural Networks)을 활용한 복잡한 패턴 인식을 평가하여 이미지 인식에 대한 신경망 분석의 탁월한 성능과 예측 정확성이 입증되었다[1]. Kelly가 앞으로 모든 분야(X)에 인공지능(AI)이 접목될 것이라는 X+AI를 주장하였듯이[2], 패션 분야에서도 AI가 융합되기 시작하였다. Wang 등은 신경망의 일종인 딥러닝을 이용하여 맞춤형 패션 추천 시스템을 개발하였고[3], Najman 등은 신경망으로 소비자의 구매 패턴을 분석하고, 이를 바탕으로 맞춤형 마케팅 전략을 수립하는 연구를 하였다[4]. 한국에서도 인공지능을 이용한 연구분석 사례가 증가하고 있다. 예를 들어, 한국학술지인용색인(KCI)에 의하면 패션분야에서 인공지능을 이용한 연구가 총 56건이다. 이들 중 대부분이 2020년 이후 발표된 것이다. 한국 패션학회에서도 이제 인공지능 또는 신경망 등 머신러닝을 이용한 연구가 시작되고 있다고 할 수 있다.

그런데 새로운 기법들을 이용한 연구들이 등장하는 것도 고무적이지만, 새 기법을 이용한 연구결과물을 기존의 연구들을 비교하여 본다면, 예전에 발견하지 못하였던 것을 새롭게 찾아낼 수 있을 것으로 기대된다. 그래서 본 연구에서는 전통적 통계학의 표본을 활용한 김지민과 박수연(2017)의 “30~40대 여성의 패션아이웨어 선호도 및 구매실태 조사” 연구[5]를 다층 퍼셉트론 신경망 기법으로 다시 분석한다. 이를 통해 패션 아이웨어 시장에서 소비자의 선호도와 구매 행동을 더욱 깊이 이해하고, 소비자에게 맞춤형 구매 컨설팅까지 가능할 것으로 기대한다.

그러나 패션분야에서의 신경망 기법 적용은 아직 초기 단계이므로, 다음과 같이 기술적인 부분과 실용적 유용성 부분을 함께 고려하면서 연구를 진행하였다.

탐구문제 1: 신경망 분석기법은 전통적인 모수적 분석기법들과 어떻게 다른가?

탐구문제 2: 신경망의 종류가 다양한데, 이들 중에서 어떤 신경망이 “패션 아이웨어 구매결정 분석”에서 가장 설명력이 높은가? 그리고 신경망은 은닉층(hidden layer) 속에서 활성화 함수(activation function)를 거쳐서 출력층으로 결과물을 배출하는데, 본 연구에서는 어떤 활성화 함수가 예측 정확성을 가장 높여주는가?

탐구문제 3: 선글라스 소비자들의 선택에 관한 신경망 분석의 결과물은 전통적 계량분석기법이 생산해내는 것과 어떻게 다른가?

II. 기존 연구의 재검토

최근에는 관련 연구를 통해 세계적으로 상용화된 패션 애플리케이션들의 동향이 보고되고 있다. Edited, Coded Couture, Stitchfix, Lyst 등이 대상인데, 국내에서도 shoppingbot을 개발하고 있다고 한다[6]. 이 앱들은 인공지능의 한 요소인 RPA에 해당하는 것들이다. 한편, 인공지능의 다른 요소인 머신러닝 쪽에서의 연구 개발에 대해서는 메타분석(meta analysis)을 실시하였으며, 이를 통해 소비자 중심의 추천 기능, 개인화된 상품 전략, 이에 따른 생산 최적화, 그리고 가상착장을 이용한 매장의 효율성 향상에 기여할 수 있다는 결과를 얻었다[7].

소비자 추천기능과 관련한 연구도 진행되었으며, 연구를 통해 이들은 소비자들이 온라인에서 구매 대상 상품을 찾는데 많은 시간을 사용하는 문제를 줄이기 위하여 인공지능기반 협업 필터링을 이용한 패션 추천 시스템을 개발하였다. 즉, 소비자가 온라인에서 구매하였던 것과 유사한 스타일의 제품을 추천하게 하는 방식을 제시한 것이다[8]. 그런데 이미지 필터링에는 CNN(convolutionary neural network)을 사용하는데, 이것은 본 연구에서 사용하고자 하는 ANN(artificial neural network)과 매우 다르다.

다른 관련 연구에서도 패션 추천 시스템을 연구하였는데, 이 연구는 구매 여정을 세분화하였다는 차이점이 있다[9]. 그러나 이들은 머신러닝 기법이 아니라 ANOVA와 회귀분석을 사용하고 있어서, 동일한 데이터를 향후 인공지능 기법으로 다시 분석한다면 어떠한 결과가 생성될 것인지 기대하게 한다. 이것은 본 연구에서 재분석하고자 하는 김지민과 박수연(2017)의 경우와 유사하다고 할 수 있다.

패션 추천 서비스에 대한 MZ 세대들의 만족도를 분석하는 연구에서는 이들은 일대일 추천서비스와 연령대별 추천서비스를 가장 선호하는 결과를 얻었으나, AI 추천서비스의 추천 범위가 좁아서 오히려 자유로운 쇼핑을 방해한다는 한계점도 제시되고 있다[10]. 이처럼 만족도가 제한된 이유는 아직 패션분야에 인공지능이 적용되는 초기 단계이기 때문일 것이다. 따라서 앞으로 신경망을 사용하여 소비자의 구매 패턴을 분석하고, 이를 바탕으로 맞춤형 마케팅 전략을 수립하는 연구가 활성화될 필요가 있으며, 더불어 패션 분야의 인공지능화를 위해서는 데이터의 기반시설이라고 할 수 있는 레이블링(Labeling)부터 시작되어야 할 것이다[11].

III. 접근방법, 데이터, 연구설계

1. 접근방법: 모수적 분석과 머신러닝의 차이점

재분석한 기존 연구에서는 여성들의 선글라스 구매 결정에 대하여 빈도분석, t-검정, 카이검증, 교차분석 등 전통적 통계학을 적용하여 분석하였다. 그 결과 한국의 30~40대 여성들은 주로 여름철에 선글라스를 착용하며, 자신의 얼굴형과 조화롭게 어울리는 제품을 선택하며, 타인의 평가보다는 자신의 이미지 향상에 중점을 두는 것으로 조사되었다. 이런 모수적 분석기법에서는 표본을 이용하여 모집단의 모수(parameter)를 추정하는 것이 핵심 관건이다. 이때 구간추정 방식을 적용하며 모수가 존재할 확률적 범위를 찾는다. 그런데 이런 분석의 결과들은 대부분 일반화된 상식을 재확인하는데 귀결된다[12-13]. 따라서 개인화된 맞춤 구매 추천 또는 컨설팅은 하기 어렵다.

이에 비하여 신경망, support vector machine, Xg boost 등 머신러닝 기법들에서는 모집단을 전제로 하지 않는다. 그 대신 수집된 데이터를 학습용 데이터와 예측용 데이터로 분할한다. 그런 다음 다양한 기법을 학습용 데이터에 적용하여 추정 공식을 산출하는데, 이것을 학습(learning)이라고 한다. 학습된 추정 공식에 개별 데이터를 투입하여, 예측치를 찾아내는 것이 머신러닝의 일반적인 과정이다[14]. 머신러닝에서는 개인별 맞춤형 예측이 주된 목적이어서, 패션 추천 시스템의 개발에 훨씬 더 적합한 기법이라고 할 수 있다.

일반적으로 머신러닝 기법들의 예측정확도는 모수적 기법의 정확도 보다 훨씬 높는데, 그것은 과적합

(overfitting)의 결과일 수도 있다. 이런 과적합에 대응하는 방법으로는 ①정규화(regularization), ②교차검증(cross-validation), ③bagging과 boosting을 이용한 앙상블 기법(Ensemble methods) 등이 있다. 그런데 이런 과적합 대응기법들은 본 연구에서 사용하는 삼성SDS의 BrighticsAI나 Microsoft의 Azure Studio 등 머신러닝 분석 툴에 이미 탑재되어 있다.

2. 데이터셋

“패션 아이웨어”에 대한 설문조사의 결과 총 547개의 사례데이터(instance)가 수록되어 있다. 이 중 159개의 사례데이터는 안경 구매와 관련된 것이므로, 본 연구에서는 선글라스 구매와 관련된 388개의 사례데이터를 분석한다[15].

이 데이터셋에는 여러 변수 값들이 있는데, ①선글라스 구매 동기, ②본인 성향, ③정보획득경로, ④응답자의 개인신상, 그리고 ⑤선호하는 제품에 관한 의견들이 수록되어 있다.

선글라스 구매 동기로는 자외선 보호, 할인 기간, 스트레스 해소, 충동구매, 새로운 유행, 지적 이미지, 수집용 구매, 새로운 스타일 등 8가지가 있다.

본인 성향은 다음 여러 요인들 중 어떤 것을 중요시하느냐에 따라 달라진다: 디자인/스타일, 색상/무늬, 얼굴형과 조화, 유행성/매력성, 브랜드 명성, 품질, 가격, 개성표현, 타인평가, 그리고 AS.

선글라스를 구매하는데 필요한 정보획득 방법에 관하여서는 과거 경험, 유명인 관찰, 매장 진열, 대중 매체, 카탈로그, 서적 잡지, 판매원 권유, 친구 또는 친척 권유 등 8가지를 설문하였다. 구매 의향 금액은 10만원 이하, 10만원 이상~20만원 이하, 20만원 이상~30만원 이하, 30만원 이상~40만원 이하, 40만원 이상~50만원 이하, 그리고 50만원 초과 중에서 선택하는 형식으로 질문하였다.

마지막으로 구입하려는 선글라스는 그 형태와 프레임, 그리고 렌즈 색상으로 구분할 수 있다. 선글라스 형태에는 보잉형, 보스틴형, 오벌형, 원형, 폭스형, 사각형, 고글형, 오버사이즈형이 있고 프레임은 블랙, 브라운, 그레이, 화이트, 호피, 메탈, 비비드 컬러, 무테, 기타 중에서 선택할 수 있다. 그리고 렌즈 색상은 블랙, 브라운, 그레이, 블루, 핑크, 미러가 있다. 이 밖에 응답자 개인 신상(직업, 연령, 학력) 및 선글라스 착용습관을 설문하

였다.

3. Label과 Feature

통계학 분석에서는 독립변수와 종속변수라는 용어를 사용한다. 이에 반하여, 머신러닝에서는 독립변수를 Label이라고 하는데, 경우에 따라서는 Target 변수라고 부르기도 한다. 그리고 종속변수에 해당하는 것은 속성(Feature)이라고 한다[16].

본 연구는 구매하고자 하는 선글라스 제품과 관련된 특성, 즉, 선글라스 형태, 프레임, 렌즈 색상이라는 3개 변수를 각각의 Label로 채택하며, Feature 변수로는 구매 동기, 본인 성향, 정보획득경로 및 개인신상 정보를 채택한다.

4. 신경망분석기법 또는 MLP

머신러닝의 가장 대표적인 분석기법인 신경망분석기법은 ①입력층, ②은닉층, 그리고 ③출력층으로 구성된다. 입력층에서 데이터를 받아들이면, 은닉층에서는 신경망의 뉴런(neuron)이 데이터를 활성화 함수(activation function)를 이용하여 다른 수치로 변환시킨다. 이렇게 변환된 수치가 출력층으로 보내진다.

신경망은 ①수치를 처리하는 ANN(Artificial Neural Network), ②이미지를 처리하는 CNN(Convolutionary Neural Network), 그리고 ③ChatGPT와 같이 문자를 처리하는 RNN(Recurrent Neural Network)이 있다. 본 연구는 수치 처리에 적합한 ANN을 채택하였다.

그런데 ANN에도 수많은 종류가 있는데, 일반적으로 많이 사용되는 신경망은 다음과 같이 3개이다. 즉, ADAM (Adaptive Moment Estimation), SGD (Stochastic Gradient Descent), L-BFGS-B (Limited-memory Broyden-Fletcher-Goldfarb-Shanno with Box constraints)가 그들이다.

이 신경망들은 단일한 1개 층으로도 사용할 수 있고, 2개~3개 또는 더 많은 층으로도 사용할 수 있다. 그래서 신경망분석을 다층퍼셉트론분석(multi-layer perceptron method: MLP)이라고도 한다. 복잡한 문제를 풀 때는 은닉층을 많이 사용하게 되는데, 이것을 특별히 딥러닝(deep learning)이라고 한다. 본 연구는 상대적으로 소규모의 데이터처리에 해당하므로 2~3개 층의 MLP만으로도 충분하다.

활성화 함수는 입력 신호를 출력 신호로 변환하는

비선형 함수이다. 본 연구에서는 활성화 함수로 항등함수(Identify), 시그모이드(Logistic), 하이퍼볼릭 탄젠트(Tanh), Rectified Linear Unit(ReLU)들 중에서 어느 것이 효과적인지 테스트한다.

5. 연구설계

본 연구는 앞에 설명한 Label과 Feature 변수들에 대한 신경망분석(또는 MLP)을 실행한다. 그런데 어떤 종류의 신경망이 해당 데이터셋을 분석하는데 가장 적합한지 미리 알 수 없으며, 또 신경망별로 어떤 종류의 활성화 함수가 가장 높은 예측정확도를 산출해낼 것인지 미리 알 수 없다.

이런 문제는 머신러닝에서 흔히 접하는 문제이다. 이에 대한 대응은 시행착오(trial and error) 방식으로 여러 가지 신경망에 대하여 여러 가지 활성화 함수를 적용하는 것이다. 즉, 가장 예측정확도가 높은 것을 찾아내면 된다. 따라서 본 연구는 3개의 Label에 대하여 3개의 신경망을 각각 적용하되, 신경망마다 4개의 활성화 함수를 적용하는 방식으로 설계한다. 그 결과 총 36개(=3x3x4)의 MLP를 시행하여, 그들의 결과물을 비교하는 방식으로 진행된다.

모수적 분석기법에서는 결과물의 비교에 chi-square, F, 또는 R-square 등의 지표를 사용한다. 이에 비해 머신러닝 기법에서는 혼동행렬(Confusion Metrics)로부터 각종 손실함수 또는 모델성능지표(CA, AIC, F1, Recall)를 사용하여 비교한다.

그런데 또 하나의 문제가 있다. 신경망에서 전이 과정을 은닉층(hidden layer)이라 부르는 이유는, 은닉층에서 무슨 일이 일어나는지 분석가가 알 수 없다는 점 때문이다. 즉, 신경망분석을 하면 정확도가 높은 예측을 실행하여 주는데, 그 원리와 학습방정식은 알려주지 않는다는 것이다. 따라서 기계가 학습한 내용을 알고 싶으면, 별도로 Python으로 코딩을 하여야만 한다.

6. 분석모형 실행

이상의 연구설계에 따라 BrighticsAI 분석 툴로 MLP 분석을 시행하였다. 시행 모형은 그림 1과 같이 워크플로우(workflow) 방식으로 진행된다. 총 388개의 사례데이터 중 70%를 랜덤 샘플링하여 272개가 학습데이터로 사용되었고, 나머지 30%인 116개가 예측데이터로 사용되었다.



그림 1. BrighticsAI에서 MLP를 시행하는 모형
 Figure 1. MLP model executed by BrighticsAI

IV. 분석 결과와 해석

1. 신경망 분석 결과

선호하는 선글라스 형태에 대하여 다양한 신경망과 활성화 함수를 적용한 MLP 분석 결과는 표 1과 같다. L-BFGS-B 신경망에 하이퍼볼릭 탄젠트(tanh) 활성화 함수를 적용할 때 분류정확도(Classification Accuracy: CA)가 0.862로 가장 컸다. 배덕중은 최근의 연구에서 82.1%의 CA를 양호한 편으로 판정하였는데, 본 연구의 CA는 그것을 상회한다[17].

표 1. 신경망별/활성화 함수별 분류정확도

Table 1. Classification accuracy by neural network and by activation function

신경망	활성화 함수	CA
ADAM	Identify	0.543
	Logistic	0.552
	tanh	0.759
	ReLU	0.709
SGD	Identify	0.560
	Logistic	0.371
	tanh	0.422
	ReLU	0.509
L-BFGS-B	Identify	0.586
	Logistic	0.836
	tanh	0.862
	ReLU	0.759

각 속성변수의 상대적 영향력은 그림 2와 같다. 직업이 선글라스 형태 선택에 가장 큰 영향을 미쳤고, 다음으로 영향이 큰 속성은 새로운 스타일의 추구하고 학력이었다. “직업”과 “학력”은 대표적인 보수적 속성이지만, 선글라스는 안경과 달리 “새로운 스타일을 추구”하는 속성도 있다. 즉, 대부분의 소비자들은 선글라스 선택에

있어서 큰 변화보다는 약간의 변화를 가미하고자 한다.

카탈로그나 과거의 구매 경험 등 정보습득 원천도 선글라스 선택에 중요한 영향 요인이다. 그러나 소비자들은 “할인 기간” 중에 구매하기를 원하는 정도가 크다. 반면, 매장진열품이나 충동구매 요인은 상대적으로 구매 결정에 영향력이 작았다.





그림 2. Feature별 구매결정에 영향을 미친 영향력
 Figure 2. Feature importance on factors of purchase decision

2. 선글라스 형태의 선택



주. 1.0=보잉형; 2.0=보스턴형; 3.0=오벌형; 4.0=원형; 5.0=폭스형; 6.0=사각형; 7.0=고글형; 8.0=오버사이즈형


그림 3. 선글라스 형태에 대한 선호도의 혼동모형
 Figure 3. Confusion matrix of preferred sunglass shapes

여러 구매 동기와 정보습득 과정을 통해, 최종적으로 많이 선호한 선글라스 형태는 “보스턴형”(34.8%)과 “오

버사이즈형”(34.3%)이다. 다음으로 “보잉형”(9.5%)과 “오벌형”(9.0%)이 꾸준한 선호를 받았다. 그림 3은 실제 응답 대 예측치를 비교한 혼동행렬이다. 117명 중 38명이 보스턴형이라 응답하였는데, 실제 응답과 예측모형 모두에서 보스턴형으로 나타난 것은 34명이다. 약간의 예측오차가 발생한 것이다. 가장 큰 예측오차는 “폭스형”과 “사각형” 선글라스 형태인데, 각각 9명 중 5명만 실제 응답과 예측치가 일치하였다. 이 두 항목에서만 각각 44.4%의 오류가 발생하였다. 그러나 전술하였듯이, 전체적으로는 86.2%의 양호한 예측정확도를 보이고 있다.

3. 선글라스 프레임에 대한 선호도

가장 선호도가 높은 프레임은 블랙 컬러였으며(45.8%), 두 번째가 브라운 컬러(21.%)이다. 그러나 호피무늬 프레임(13.4%)과 메탈 프레임(12.6%)도 어느 정도 수요가 있었다.



주. 1.0=블랙; 2.0=브라운; 3.0=그레이; 4.0=화이트; 5.0=호피무늬; 6.0=메탈; 7.0=비비드 컬러; 8.0=무테; 9.0=기타

그림 4. 선글라스 프레임에 대한 선호도의 혼동모형
Figure 4. Confusion matrix of preferred sunglass frames

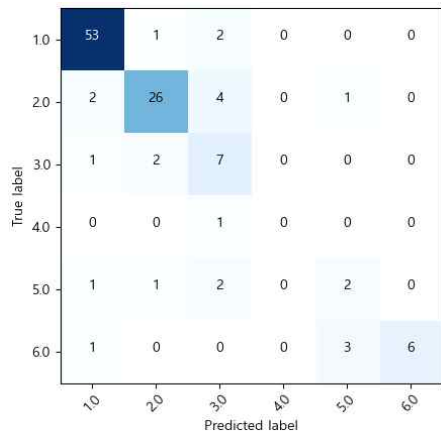
프레임 선호도에 가장 큰 영향을 미친 속성 3가지로는 ①새로운 스타일의 추구, ②친구나 가족의 권유, 그리고 ③수집용 구매 목적이었다. 그런데 선글라스 형태와 프레임 선택에서 공통되게 영향을 미친 요인은 새로운 스타일의 추구이다. 시력 교정용 안경과 달리 선글라스는 일상으로부터의 일탈 효과도 있기 때문에 판단된다.

그림 4는 프레임 선호도에 대한 혼동 행렬이다. 예측 정확도 CA는 0.828로서 양호한 정도이다. 그러나 분석 결과를 좀 더 구체적으로 보면, 오류를 가장 많이 발생시킨 선글라스 프레임은 브라운 프레임이다. 총 24명이 이 프레임을 선호한다고 응답하였는데, 이들 중 1/4에 해당하는 6명에 대해서 신경망은 블랙 프레임을 선호하는 것으로 예측하였다. 그리고 무테를 선호한다고 응답한 숫자는 총 4명에 불과하지만, 이들 중 예측오류가 발생한 것은 3건이나 된다.

인공지능 또는 머신러닝 기법을 사용하는 목적은 예측오류의 최소화이다. 따라서 현재의 80%대에 해당하는 예측정확도를 90%대로 제고하는 것은 향후의 연구 과제이다.

4. 선글라스 렌즈에 대한 선호도

선글라스에서 렌즈의 컬러 역시 매우 중요한 요소이다. 김지민과 박수연(2017)의 연구결과, 블랙 컬러 렌즈가 전체의 43.3%를 점유하며, 그 다음으로 브라운 컬러가 33.2%를 점유하였다. 가장 선호도가 높은 프레임은 블랙 컬러였으며, 두 번째가 브라운 컬러였다.



주. 1.0=블랙; 2.0=브라운; 3.0=그레이; 4.0=블루; 5.0=핑크; 6.0=미러

그림 5. 선글라스 렌즈 컬러에 대한 선호도의 혼동모형
Figure 5. Confusion matrix of preferred lens colors

선호도에 가장 큰 영향을 미친 속성 4가지로는 ①착용습관, ②배장진열품, 그리고 ③학력과 ④스트레스 해소 목적이다. 이 속성들은 선글라스 형태나 프레임의 선택에 영향을 미친 속성들과 차이가 난다. 학력과 착용습관이라는 보수적인 속성이 렌즈 색상의 선택에 영

향을 미치는 동시에, 매장진열품을 보고 구매하는 행태와 스트레스 해소 목적 또한 렌즈 색상의 선택에 영향을 미치고 있다. 그러나 그림 5에 나타난 바와 같이 특이한 색상을 선택하는 비율은 낮으며, 소비자의 53%가 블랙을 선택하고, 26%가 브라운을 선택하여 무난한 색상이 주류를 이루고 있다.

5. 분석요약

이상의 신경망 분석을 통해 선글라스라는 개성 넘치는 민감한 패션 상품에 대한 선호도를 ①형태에 대한 선호도와 ②프레임에 대한 선호도, 그리고 ③렌즈 컬러에 대한 선호도로 나누어서 살펴보았다. 그리고 이 선호도에 영향을 미치는 속성들이 매우 다양함을 발견하였다. 표 2는 형태, 프레임, 렌즈별 선호도 영향 요인들을 요약한 것이다.

표 2. 선글라스 형태, 프레임, 렌즈에 대한 선호에 영향을 미치는 속성들

Table 2. Features affecting preference over shape, frame, and lens color of sunglasses

구분	영향력이 큰 속성들
선글라스 형태	1. 직업 2. 새로운 스타일 추구 3. 학력 4. 과거의 구매 경험
선글라스 프레임	1. 새로운 스타일 추구 2. 친구나 가족의 권유 3. 수집용 구매 4. 대중매체
선글라스 렌즈	1. 착용빈도 2. 매장진열품 3. 학력 4. 스트레스 해소

여기서 알 수 있는 것은 선글라스 형태, 프레임, 렌즈별로 영향을 미치는 요인들이 제각각이라는 점이다. 그리고 이 요인들이 생성해내는 예측의 정확도가 약 82%~86%로 양호하다.

V. 전통적 분석결과와 머신러닝 분석결과의 비교

본 연구에서 가장 중요한 탐구주제는 같은 데이터를 가지고 전통적인 통계분석을 하는 경우와 새로운 기법인 머신러닝 기법을 적용했을 때의 차이점이다.

표 3. 전통적 계량기법으로 생성한 분석결과

Table 3. Analysis results from classic quantitative analysis

선글라스 형태디자인	30대 (명, %)	40대 (명, %)	합계 (명, %)
보잉형	24(11.3)	13(7.4)	37(9.5)
보스틴형	82(38.5)	53(30.0)	135(34.8)
오벌형	17(8.0)	18(10.3)	35(9.0)
원형	6(2.8)	0(0.0)	6(1.5)
폭스형	15(7.0)	4(1.3)	19(4.9)
사각형	6(2.8)	10(5.7)	16(4.1)
고글형	0(0.0)	7(4.0)	7(1.8)
오버 사이즈형	63(29.6)	70(40.0)	133(34.3)
chi-square	26.801***(df=7)		

표 4. 신경망으로 분석하여 예측한 결과

Table 4. Prediction from neural network analysis

소비자연 번	실제 선택	예측 결과	정오 판정	고려한 속성들
1	보스틴	보스틴	정	
2	오버 사이즈	오버 사이즈	정	<개인속성> -직업 -학력
3	보스틴	보스틴	정	-연령대
4	오버 사이즈	오버 사이즈	정	-결혼여부
5	오버 사이즈	오버 사이즈	정	<구매동기> -새로운 스타일 추구
6	오버 사이즈	오버 사이즈	정	-수집용구매 -스트레스해소
7	보스틴	보스틴	정	-자외선보호
8	오벌	오벌	정	-할인기간
9	보스틴	보스틴	정	
10	보잉	보잉	정	<정보획득>
11	오버 사이즈	오버 사이즈	정	-과거 경험 -카탈로그
12	보스틴	보스틴	정	-유명인관찰
13	보스틴	보스틴	정	-친구, 친지
14	오버 사이즈	오버 사이즈	정	-서적 -매장진열 -직원설명
15	오버 사이즈	오버 사이즈	정	-충동구매
16	오벌	사각	오	
17	폭스	보잉	오	

이 차이점에 따라 신경망 등 머신러닝의 유용성이 판단되기 때문이다.

표 3은 김지민과 박수연(2017)이 전통적인 통계학에 입각하여 생성한 교차표분석 결과이다. 이 분석 결과를 해석하자면, “선글라스 디자인 선택에 있어서 30대 여성과 40대 여성은 유의미할 정도로 차이가 난다”는 것이다. 물론 자세히 보면, 30대 여성은 보스틴형 선글라스를 더 선호하고, 40대 여성은 오버사이즈형을 더 선호한다는 것을 별도로 검증할 수 있다. 그러나 힘들

게 수행한 계량분석으로 얻을 수 있는 정보량은 매우 한정적이다.

이에 비해 표 4는 신경망분석을 통해 각 개인이 어떤 형태의 선글라스를 선택할 것인지 예측해준다. 여기서는 17명의 사례만 제시하여 그중 15명의 예측이 정확하고, 2명의 예측에 있어서만 오류가 발생하였다.

그러나 분석자가 원하면 388명 각자에 대해서도 소비자가 어떤 형태의 선글라스를 구매할 것인지 예측 가능하다. 그리고 모든 속성을 다 이용하지 않고, 직업, 연령 등 소수의 속성값만 가지고도 소비자의 구매 선호도를 예측할 수 있다.

이와같이 인공지능 혹은 신경망 같은 머신러닝은 소비자를 분류하고, 예측하는 데 매우 유용하다. 그 결과 소비자 맞춤형 선글라스 추천 시스템 같은 것으로 발전할 잠재력이 크다.

VI. 결 론

본 연구는 2017년에 전통적 계량분석기법으로 분석한 30대~40대 여성들의 선글라스 구매결정을 신경망분석이라는 신기술로 다시 분석하였다. 그 결과 전통적 기법으로 분석하였을 때는 집단간 비교를 통해 선글라스에 대한 선호를 파악할 수 있었다. 즉, 소비자 A는 30대 여성이므로 보스턴형 선글라스를 좋아할 것이다. 소비자 B는 40대이므로 오버사이즈형 선글라스를 좋아할 것으로 추정한다.

그러나 인공지능의 하나인 신경망 분석을 통해서, 소비자 C는 30대이더라도, 여러 속성을 고려하건데, 오벌형을 좋아할 것이다. 소비자 D는 40대이지만, 사각형을 선호할 것이다. 이런 식의 맞춤형 구매 선호 파악이 가능해진다. 따라서 본 연구의 결과를 기초로 하여, 유명 패션 앱 Edited, Coded Couture, Stitchfix, Lyst와 다른 새로운 유형의 패션 앱도 만들 수 있다.

다만 신경망 분석을 비롯한 머신러닝 기법들이 계속 발전하고 있다. 국내 패션 분야에의 적용은 이제 시작하는 단계이다.

References

[1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning", *Nature*, Vol. 521, pp. 436-444, May 2015. <https://doi.org/10.1038/nature14539>
 [2] K. Kelly, *The Inevitable: Understanding the 12*

Technological Forces That Will Shape Our Future. Penguin Books, New York. 2017.

- [3] J. Wang, Y. Ma, L. Zhang, R. X. Gao, and D. Wu, "Deep learning for smart manufacturing: methods and applications", *Journal of Manufacturing Systems*, 48(C), pp.144-156, Jan. 2018. <https://doi.org/10.1016/j.jmsy.2018.01.003>
 [4] K. M. Najman, K. Najman, and S. Badowska, "The GNG neural network in analyzing consumer behaviour patterns: empirical research on a purchasing behaviour processes realized by the elderly consumers", *Advances in Data Analysis and Classification*, Vol. 14, pp. 947-982, Aug. 2020.
 [5] J. M. Kim and S. Y. Park, "A Study on Fashion Eyewear Preferences and Purchasing Behaviors of Women in Their 30s and 40s", *Journal of Basic Design & Art*, Vol. 18, No. 6, pp. 117-131, Dec. 2017.
 [6] C. E. Kim and J. H. Lee, "Trends of Big Data and Artificial Intelligence in the Fashion Industry", *Journal of the Korean Society of Clothing and Textiles*, Vol. 42, No. 1, pp. 148-158, 2018. <https://doi.org/10.5850/JKSCT.2018.42.1.148>
 [7] O. M. Pak and W. Y. Lee, "A Case Study of Artificial Intelligence (AI) Reflected in the Fashion Industry: Focused on Fashion Consumers", *Journal of the Korean society of design culture*, Vol. 26, No. 4, pp. 189-205, 2020. <https://doi.org/10.18208/ksdc.2020.26.4.189>
 [8] H. An, S. Kwon, and M. Park, "A Case Study on the Recommendation Services for Customized Fashion Styles based on Artificial Intelligence", *Journal of the Korean Society of Clothing and Textiles*, Vol. 43, No. 3, pp. 349-360, 2019. <https://doi.org/10.5850/JKSCT.2019.43.3.349>
 [9] S. Kang and Y. Pan, "Effect on user evaluation, purchase intention, and satisfaction of personalized recommendation services by purchase journey in mobile fashion commerce", *Journal of The Korea Convergence Society*, Vol. 13, No. 1, pp. 63-70, 2022.
 [10] M. S. Kim and J. Kim, "A Study on Satisfaction with AI-based Recommendation Service of Online Fashion Shopping Malls -With a Focus on Generation MZ", *Journal of the Korean Society of Design Culture*, Vol. 27, No. 3, pp. 15-26, 2021. <https://doi.org/10.18208/ksdc.2021.27.3.15>
 [11] W. Y. Lee, "Analysis of Fashion Labeled Data for Artificial Intelligence Learning", *Journal of the Korean Society of Design Culture*, Vol. 28,

- No. 3, pp. 355–369, 2022. <https://doi.org/10.18208/ksdc.2022.28.3.355>
- [12]S. E. Maxwell, H. D. Delaney, and K. Kelley, “Designing Experiments and Analyzing Data: A Model Comparison Perspective”, New York (3rd), *NY: Routledge*, ISBN: 9781138892286, Sept. 2017. <https://doi.org/10.4324/9781315642956>
- [13]T. Chen, and C. Guestrin, “XGBoost: A Scalable Tree Boosting System”, *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785–794, Aug. 2016. <https://doi.org/10.1145/2939672.2939785>
- [14]D. J. Bae, “Use of BrighticsAI for Analyzing Public Finance in Korea: a Case of Citizen Participation Budget System”, *Study of Financial Administration*, Vol. 3, No. 3, pp. 1–28, 2023.
- [15]R. J. Wang, L. Krishnamurthi, and E.C. Malthouse, “How Mobile Shopping Affects Customer Purchase Behavior: A Retailer’s Perspective”, *Developments in Marketing Science: Proceedings of the Academy of Marketing Science*, Springer, pp. 703–704, ISBN:9783319118154, 3319118153, 2016. https://doi.org/10.1007/978-3-319-11815-4_215
- [16]D. J. Bae. “Use of BrighticsAI for Analyzing Public Finance in Korea—a Case of Citizen Participation Budget System”, *Public Financial Administration*, Vol. 3, No. 3, pp. 1–28, 2024.
- [17]D. J. Bae. “Development of AHP-MAUT Hybrid Model to Enhance Effectiveness of Decision Support System”, *The Journal of the Convergence on Culture Technology*, Vol. 10, No. 3, pp. 421–426, 2024. <https://doi.org/10.17703/jcct.2024.10.3.42>