

머신러닝을 이용한 전자상거래 제품의 판매 증감률 예측에 관한 연구

이준하, 김대희

순천향대학교 사물인터넷학과

junha4304@sch.ac.kr, daeheekim@sch.ac.kr

A Study on the Forecasting System for Sales Growth and Reduction Rate in E-Commerce using Machine Learning

Junha Lee and Daehee Kim
Soonchunhyang University

요약

본 논문에서는 머신러닝을 활용한 제품별 판매 증감률 예측 시스템을 구현하고 그 활용 방법을 제안한다. 기계의 학습을 위해 오픈 데이터들을 전처리하여 데이터셋을 구축하고, 해당 데이터셋을 활용한 지도학습을 통해 제품별 판매 증감률의 예측이 가능한 회귀 모델을 생성한 후 성능평가를 수행한다.

I. 서론

4 차 산업혁명의 시대가 도래하며 제조와 유통, 물류의 경계가 허물어져 기존 산업들과는 전혀 다른 신 유통 서비스들이 생겨나고 있다. 이 과정에서 많은 유통 채널들이 생겨나고, 신생 채널들의 전자상거래 데이터가 제조사에 제공되지 않아 제조업체들은 자사 제품의 수요를 예측할 수 없게 되었다. 제조사들은 전자상거래 업체들의 요구에 맞춰 생산량을 조절하는 실정이며, 능동적 마케팅을 펼 기회가 줄어들었다. [1]

이에 본 연구에서는 제조사들의 원활한 자사 제품 수요 예측을 위해 머신러닝과 공개 데이터들을 사용하여 검색량 기반 전자상거래 제품의 판매 증감률을 예측하는 시스템을 제안하고자 한다.

II. 본론

2-1. 데이터 전처리

본 연구에서 사용한 데이터는 2016년부터 2018년까지 브라질의 전자상거래 주문 100만개에 대한 주문, 리뷰, 지불방식, 소비자, 상품, 주문아이템, 판매자, 유통주소를 저장한 데이터[2]와 브라질 검색엔진 시장 점유율 89%를 차지하고 있는 구글의 구글 트렌드 데이터이다. [3] 전자를 가공하여 상품군별 일자에 따른 판매량과 판매액을 라벨로 가진 데이터셋을 생성하였고, 이를 판매데이터로 사용하였으며, 후자를 가공하여 상품군의 일별 검색량을 판매데이터에 추가하였다. 이후 대표 카테고리들의 데이터를 통합하고, 검색량에 따른 판매량과 판매액 데이터로 구성하였으며, 그 과정에서 구글 트렌드의 검색량 데이터가 0부터 100까지의 상대 값이라는 특성을 고려하여 데이터를 정규화 하였고, 상대적으로 상관도가 낮은 판매량 데이터를 제거하여 [표 1]과 같은 최종 데이터셋을 생성하였다.

Date	Num	Price	Search
20170817	11	1268.15	98
20170818	13	1099.48	89
20170819	10	1309.42	91
20170820	20	1273.21	87
20170821	22	1782.69	91
20170822	20	918.71	93
20170823	20	1538.06	89
20170824	11	628.23	86
20170825	10	829.32	85
20170826	8	830.01	82
20170827	14	929.68	83
20170828	16	1377.4	91
20170829	20	1360.55	97
20170830	11	1118.38	89
20170831	12	1218.44	90
20170901	25	1556.67	84
20170902	9	533.27	80.18182

[표 1] 건강, 미용 관련 제품의 최종 데이터셋 (일부)

생성된 최종 데이터셋으로 검색량과 판매액, 판매량 간의 상관 분석을 진행하였다. 상관 분석은 연속 변수로 측정된 두 변수 간의 선형 관계를 분석하는 기법으로 한 변수가 증가하면 다른 한 변수도 선형적으로 증가 혹은 감소하는가를 나타내는 것이다. 상관분석에는 두 변수 사이의 선형적인 관계 정도를 나타내기 위해 상관계수를 사용한다. 일반적으로 1에 가까울수록 양의 선형관계, -1에 가까울수록 역의 선형관계가 있다고 판단하며, 0인 경우 상관관계가 없음을 의미한다. 해석의 차이가 있을

수 있지만 [그림 1]과 같이 0.5 이상의 분석 결과는 양의 상관관계가 있음을 나타내며, 0.8 이상은 강한 상관관계가 있음을 의미한다. [4]

Perfect	+1	-1
Strong	+0.9 +0.8 +0.7	-0.9 -0.8 -0.7
Moderate	+0.6 +0.5 +0.4	-0.6 -0.5 -0.4
Weak	+0.3 +0.2 +0.1	-0.3 -0.2 -0.1
Zero	0	0

[그림 1] Correlation mean [5]

상관 분석 결과 [표 2]와 같이 검색량과 판매액, 판매량 간에 양의 상관관계가 있음을 알 수 있다.

상품군	상관 계수	상품군	상관 계수
스포츠 레저	0.650293	애완동물 제품	0.822881
파티용품	0.5764	장난감	0.681671
신발	0.587769	미용&건강	0.554486
속옷, 수영복	0.612894	아동의류	0.746729
남성의류	0.549144	꽃	0.668519

[표 2] 상품군별 검색량과 판매량 간 상관계수

2-2. 모델 학습

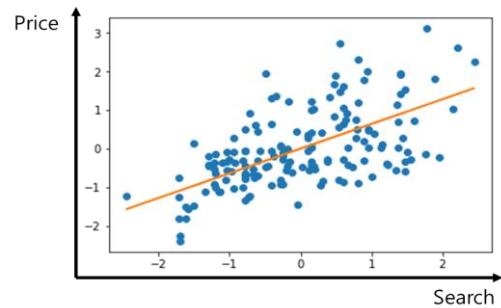
최종 데이터셋의 무작위 20%의 데이터를 검증 셋으로 분리하였고, 나머지 80%의 데이터로 모델을 학습하였다.

학습에는 Linear Regression, Random forest, Gradient Boosting Tree, Neural Network 기법을 사용하였으며, Windows 환경에서 Python 3.7 을 사용하여 분석하였다. 분석 결과 [표 3]에서 알 수 있듯이 각 기법 별 정확도는 크게 차이가 없으며, 특성이 ‘검색량’ 하나인 영향으로 Linear Regression 을 사용한 모델이 가장 정확히 판매액을 예측했다. [6]

Algorithm	Accuracy
Linear Regression	82.66%
Random forest	79.84%
Gradient Boosting Tree	82.63%
Neural Network	81.25%

[표 3] 알고리즘 별 정확도

데이터를 통해 생성된 모델의 RMSE 는 0.8059, 검증 셋의 RMSE 는 0.8266 으로 둘의 오차율은 2.5%이므로 오버피팅이나 언더피팅이 없는 학습 모델이라는 것을 알 수 있다. 모델과 데이터를 그래프로 나타내면 [그림 2]과 같은 결과를 얻을 수 있다. 그래프를 분석하면, 기울기는 0.6167, 절편은 -0.0504 로 “판매액 = 0.6167*검색량 - 0.0504”라는 모델을 생성할 수 있었다.



[그림 2] 검색량별 판매액 모델과 데이터 산점도

III. 결론

본 연구에서는 정보화 사회에서 정보격차, 그 중에서도 기준에는 공유되어 왔지만 유통 채널의 다각화와 개인정보의 중요도 상승으로 인해 공유되지 못하는 판매 데이터의 격차를 해소하여 제조사가 능동적 마케팅을 할 수 있는 기반을 만들고자 머신러닝과 오픈 데이터들을 활용하여 전자상거래 제품의 판매 증감률을 예측하는 시스템을 제안하였다. 그 결과 검색량으로 제품의 판매 증감률을 예측할 수 있었고, 검색량의 시계열 데이터 또는 검색엔진 사용자의 연령, 성별 등의 검색 데이터를 활용하여 미래 검색량을 예측한다면 검색 데이터들을 통해 미래의 판매 증감률을 예측할 수 있을 것이다. 본 연구에 최적화된 데이터를 생성하기 위해 데이터 가공이 필요했으며, 최종적으로 사용되는 데이터는 raw 데이터의 50%도 채 되지 않았다. 사용된 데이터조차 타 데이터들과 모집단이 달라 둘 간의 공통 특성인 시간을 기준으로 병합하여도 유의미한 상관 관계를 갖지 않는다는 한계가 있었다. 이러한 한계를 극복하기 위해서는 각 분야의 빅데이터를 확보한 기업들의 자발적 데이터 공유가 필요하고, 정책적 동기부여를 통한 데이터 공유 문화가 정착된다면, 데이터가 핵심 자산이 되는 4 차 산업혁명 시대를 선도할 수 있을 것이다. [7]

참 고 문 헌

- [1] 박성의, “제조 vs 유통, 그 끝에 온디맨드,” Mar.2018, (<http://clomag.co.kr/article/2815>).
- [2] “Brazilian E-Commerce Public Dataset by Olist,” 2018, (<https://www.kaggle.com/olistbr/brazilian-ecommerce>).
- [3] “google trend,” (<https://trends.google.com/trends>).
- [4] “Correlation and dependence,” (https://en.wikipedia.org/wiki/Correlation_and_dependence).
- [5] Dancey, C. and Reidy, J. “Statistics without Maths for Psychology,” 5th edition. pp. 175, Aug.2011
- [6] “Machine Learning Algorithm Cheat Sheet for Azure Machine Learning designer,” 2020, (<https://docs.microsoft.com/azure/machine-learning/algorithm-cheat-sheet>).
- [7] 최희윤, “4 차 산업혁명과 연구데이터 공유 생태계,” 한국일보(기고), Nov.2017, (<https://www.hankookilbo.com/News/Read/201711281383267387>).