

박사학위논문

인공지능을 활용한 온라인 광고 성과 향상 방안

- 네이버 키워드 검색광고와 페이스북 디스플레이
광고 중심으로 -

2022년

한 성 대 학 교 대 학 원

스마트융합컨설팅학과

스마트융합제품전공

이 정 우

박 사 학 위 논 문
지도교수 김승천

인공지능을 활용한 온라인 광고 성과 향상 방안

- 네이버 키워드 검색광고와 페이스북 디스플레이
광고 중심으로 -

An Improvement Scheme of Online Advertising Performance
using Artificial Intelligence

- Focusing on Naver Keyword Search Ads and Facebook
Display Ads -

2021년 12월 일

한 성 대 학 교 대 학 원

스마트융합컨설팅학과

스마트융합제품전공

이 정 우

박 사 학 위 논 문
지도교수 김승천

인공지능을 활용한 온라인 광고 성과 향상 방안

- 네이버 키워드 검색광고와 페이스북 디스플레이
광고 중심으로 -

An Improvement Scheme of Online Advertising Performance
using Artificial Intelligence

- Focusing on Naver Keyword Search Ads and Facebook
Display Ads -

위 논문을 공학 박사학위 논문으로 제출함

2021년 12월 일

한 성 대 학 교 대 학 원

스마트융합건설팅학과

스마트융합제품전공

이 정 우

이정우의 공학 박사학위논문을 인준함

2021년 12월 일

심사위원장 이 후진 (인)

심 사 위 원 노 광현 (인)

심 사 위 원 이 문수 (인)

심 사 위 원 임 황용 (인)

심 사 위 원 김 승천 (인)

국 문 초 록

인공지능을 활용한 온라인 광고 성과 향상 방안

- 네이버 키워드 검색광고와 페이스북 디스플레이 광고 중심으로 -

한 성 대 학 교 대 학 원
스 마 트 융 합 컨 설 톱 학 과
스 마 트 융 합 제 품 전 공
이 정 우

2012년 온라인 광고비가 지상파 TV 광고비를 추월한 이래 온라인 광고시장은 지속적으로 성장을 하고 있다. 온라인 광고 못지않게 성장하고 있는 전자상거래 시장, 즉, 온라인 쇼핑몰 산업은 온라인 광고의 의존도가 높은 영역이다. 온라인 광고의 성과를 향상시키기 위한 온라인 광고 운영작업은 기존 광고 성과 확인의 어려움과 너무 많은 광고 소재 관리 등의 이유로 어려움을 겪고 있다. 또한, 글로벌 시장에서 개인정보보호 강화 정책으로 인한 온라인 광고 성과의 저하도 큰 문제가 되고 있다. 온라인 광고의 성과를 향상시키기 위한 이상적인 온라인 광고 운영 방법은 광고 소재 단위로 광고의 성과를 실시간으로 확인하고, 성과에 따라 광고 운영작업을 실행하는 것이다. 현실적으로 인적 리소스로는 실행이 불가능하여 자동화가 필요하다.

본 연구에서는 온라인 광고 운영의 자동화를 위하여 데이터 수집과 재가공을 유연하게 할 수 있는 구조의 온라인 광고 성과분석 시스템을 제안하고

구현하였다. 또한, 온라인 광고 성과분석 시스템에서 분석한 데이터를 바탕으로 광고 성과를 향상시킬 수 있는 온라인 광고 자동운영 시스템 4가지 방법을 제시하고 구현한 후 성능 실험을 진행하였다. 첫째, 페이스북 카탈로그 광고 자동운영 시스템은 광고주 사이트의 광고 소재 상태를 반영하여 광고매체에 등록된 광고 소재를 업데이트 함으로써 광고비의 낭비를 막고 성과를 높이는 방법이다. 실험은 연 매출 100억 원 이상의 중대형 인터넷 쇼핑몰을 대상으로 1시간 단위로 광고매체의 광고 소재를 광고주 사이트의 상품의 상태에 맞게 자동으로 업데이트하는 방식의 운영 실험으로 진행하였으며, 기존 운영 방법에 비하여 본 연구에서 제안하는 방법을 통한 운영의 성과가 크게 향상됨을 확인하였다. 두 번째, 네이버 검색 광고 자동운영 시스템 중 전환을 목적으로 하는 자동운영은 새로운 광고 성과지표인 누수율을 관리하여 광고비의 낭비를 막고 성과를 높이는 방법이다. 실험은 연 매출 100억 원 이상의 중대형 인터넷 쇼핑몰들의 검색 키워드들을 대상으로 1일 단위로 기존 성과를 바탕으로 입찰가를 조정하며 누수율을 관리하고, 광고 매출 성과의 변화를 비교하는 실험을 진행하였다. 실험을 통해 누수율 관리로 광고비의 낭비가 줄었으며, 광고를 통한 매출이 증가되는 것을 확인하였다. 세 번째, 네이버 검색 광고 자동운영 시스템 중 유입을 목적으로 하는 자동운영은 방문자 수를 예측하는 방법과 방문자 추이를 예측하는 방법으로 나누어 제시하였다. 방문자 수를 예측하는 방법은 검색 키워드 별로 광고비를 입력값으로 하여 방문자 수를 예측하는 방법으로, 실험은 1년 간 검색 키워드의 운영 데이터와 성과 데이터를 바탕으로 인공지능 훈련 데이터를 만들고, 인공지능 모델을 구현하여 방문자 수 예측 정확도를 비교하는 실험을 진행하였다. 네 번째, 방문자 추이를 예측하는 방법은 검색 키워드 별로 광고비를 입력값으로 하여 방문자의 증감을 예측하는 방법이다. 방문자 수를 예측하는 방법과의 가장 큰 차이는 넓은 범위의 방문자 수를 예측하는 것이 아니라 3가지 추이만을 예측한다는 것이다. 실험은 방문자 수를 예측하는 실험과 유사하나 인공지능 모델링에 변화를 주고 이를 구현하여 방문자 추이 예측 정확도를 비교하는 실험을 진행하였다. 세 번째와 네 번째 실험 결과, 예측 정확도가 80%대로 선행 연구에 비해 높지 않으나 온라인 광고 수동 운영의 참고 자료로 실제 산업에 적

용이 가능하다.

본 연구에서 제안한 온라인 광고 자동운영 방법들이 실제 산업에 적용이 되면, 인적 리소스 감소와 기존에는 불가능했던 이상적인 광고 운영 방법을 가능하게 해주고, 이를 통해 광고 성과를 향상시키는 효과를 기대할 수 있다. 인공지능을 통한 예측 방법도 수동으로 운영하는 온라인 광고의 광고비 집행 전략에 직접적으로 도움을 줄 수 있다. 이러한 광고 운영 방법들을 통해 광고주의 광고비를 낭비하지 않으면서 광고 성과를 높일 수 있는 광고 운영이 가능해질 것이다.

【주요어】 온라인 광고, 온라인 광고 성과, 온라인 광고 자동 운영, 퍼포먼스 마케팅, 인공지능

목 차

제 1 장 서 론	1
제 1 절 연구의 배경	1
1) 온라인 광고의 역할	2
2) 온라인 광고의 분류	4
3) AD Tech 산업	6
제 2 절 연구의 필요성	9
1) 온라인 광고 성과 향상의 어려움	9
2) 온라인 광고 운영의 어려움	12
3) 이상적인 온라인 광고 운영 방법	16
제 3 절 연구의 목적 및 방법	18
1) 연구의 목적	18
2) 연구의 방법	19
제 2 장 관련기술 및 선행연구 분석	21
제 1 절 인공지능	21
1) 인공지능의 개념	21
2) 인공지능 모델링	21
3) 활성화 함수(Activation Function)	27
4) 손실함수(Loss Function)	35
5) 학습 파라미터 최적화(Optimizer)	36
6) 기타 학습 기법들	43
제 2 절 선행연구	48
1) 온라인 광고 성과지표에 대한 선행 연구	48

2) 온라인 광고에 적용된 인공지능에 대한 선행 연구	49
제 3 절 요약 및 시사점	55
제 3 장 온라인 광고 자동운영 시스템 설계	57
제 1 절 온라인 광고 운영을 위한 고려 사항	57
1) 온라인 광고의 구조	57
2) 온라인 광고 운영의 어려움	60
제 2 절 온라인 광고 자동운영 시스템 아키텍처 설계	67
1) 온라인 광고 자동운영 시스템 설계	67
2) 온라인 광고 성과분석 시스템 설계	68
3) 다양한 온라인 광고 자동운영 방법과 알고리즘 설계	71
제 4 장 온라인 광고 자동운영 시스템 구현 및 테스트	89
제 1 절 온라인 광고 자동운영 시스템 구현	89
1) 구현 범위 및 구현 내용	89
2) 시스템 성능 지표	100
제 2 절 시스템 성능 검증	103
1) 페이스북 카탈로그 광고 자동운영 시스템 성능 테스트	103
2) 전환 목적 네이버 검색 광고 자동운영 시스템 성능 테스트	107
3) 유입 목적 네이버 검색 광고 자동운영 시스템 성능 테스트	111
제 3 절 연구의 성과	124
1) 온라인 광고 자동운영 시스템 활용의 일반적 기대 효과	124
2) 온라인 광고 자동운영 시스템 활용의 시사점	125
제 5 장 결론	128

참 고 문 헌	131
---------------	-----

ABSTRACT	142
----------------	-----

표 목 차

[표 1-1] App 환경과 Web 환경의 차이	6
[표 2-1] 인공지능 관련 기술 요약	55
[표 3-1] 누수율 계산 예시	81
[표 4-1] 누수율 관리를 위한 운영 조건표	108
[표 4-2] 누수율과 ROAS의 변화	109
[표 4-3] 키워드와 데이터셋 수	112
[표 4-4] 인공지능을 활용한 유입 목적 네이버 검색 광고 자동운영 시스템 구현 환경	112
[표 4-5] 인공지능 모델 환경	113
[표 4-6] 정확도(Accuracy) 비교	113
[표 4-7] 키워드와 데이터셋 수	118
[표 4-8] 인공지능 모델 환경	119
[표 4-9] 조건별 정확도	120

그 립 목 차

[그림 1-1] 국내 온라인 광고 매출 추이(단위: 조 원)	1
[그림 1-2] 매체별 온라인 광고비 증감률	2
[그림 1-3] 글로벌 온라인 광고비 증감(2019년~2022년)	2
[그림 1-4] 대한민국 전자상거래 시장 규모(단위: 조 원)	3
[그림 1-5] App 환경에서의 사용자 추적	7
[그림 1-6] Web 환경에서의 사용자 추적	8
[그림 1-7] 페이스북 광고 운영 관리 화면	13
[그림 1-8] 페이스북 광고 성과 보고 화면	14
[그림 1-9] 페이스북 광고 성과 분석의 제한	15
[그림 1-10] 온라인 쇼핑몰의 광고 운영 Flow	17
[그림 2-1] 신경망 구조별 기하학적 해석	23
[그림 2-2] 심층 신경망(DNN) 개념도	24
[그림 2-3] RNN, LSTM, GRU 개념도	26
[그림 2-4] 시그모이드 함수와 미분함수	27
[그림 2-5] 시그모이드 함수 파이썬 코드	28
[그림 3-6] 하이퍼볼릭 탄젠트 함수와 미분함수	29
[그림 2-7] 하이퍼볼릭 탄젠트 함수 파이썬 코드	30
[그림 2-8] ReLU 함수와 미분함수	30
[그림 2-9] ReLU 함수 파이썬 코드	31
[그림 2-10] leaky ReLU 함수와 미분함수	32
[그림 2-11] leaky ReLU 파이썬 코드	33
[그림 2-12] ELU, LReLU(Leaky Relu), ReLU 비교	33
[그림 2-13] 소프트맥스 함수 그래프	34
[그림 2-14] 딥러닝의 손실함수	35
[그림 2-15] convex와 non-convex 그래프 비교	36
[그림 2-16] 다양한 최적화 알고리즘	37
[그림 2-17] 일괄 경사하강법 파이썬 코드	38


[그림 2-18] 확률적 경사하강법 파이썬 코드	39
[그림 2-19] 소규모 일괄 경사하강법 파이썬 코드	40
[그림 2-20] 부분적 최소값 문제와 모멘텀을 통한 해결	40
[그림 2-21] 모멘텀 파이썬 코드	41
[그림 2-22] RMSProp 파이썬 코드	42
[그림 2-23] Adam 파이썬 코드	43
[그림 2-24] Dropout 예시	45
[그림 2-25] 학습률에 따른 학습곡선 비교	46
[그림 3-1] 네이버와 페이스북의 광고 계층 구조	57
[그림 3-2] 네이버 광고 관리자 화면에서 본 계층 구조	58
[그림 3-3] 네이버 광고 관리자 화면(캠페인 생성)	59
[그림 3-4] 네이버의 광고비 설정(그룹 광고비 설정)	61
[그림 3-5] 개인정보보호정책으로 인한 페이스북 성과 보고 지연 안내	63
[그림 3-6] 페이스북 광고 및 광고 소재 세트	65
[그림 3-7] 온라인 광고 자동운영 시스템 다이어그램	67
[그림 3-8] 페이스북 스크립트 픽셀 베이스 코드	68
[그림 3-9] 기존 광고 성과분석 시스템 구조	69
[그림 3-10] 본 연구에서 제안하는 광고 성과분석 시스템 구조	69
[그림 3-11] 분석시스템의 계층 구조	70
[그림 3-12] 사용자 UI 컨셉	71
[그림 3-13] 페이스북 카탈로그 광고	72
[그림 3-14] 광고 자동운영 프로그램의 흐름도 - 새로운 상품 등록	75
[그림 3-15] 광고 자동운영 프로그램의 흐름도 - 순위 변경 상품 반영	76
[그림 3-16] 광고 자동운영 프로그램의 흐름도 - 품질 상품 삭제	77
[그림 3-17] 네이버 검색 광고 입찰가와 노출의 관계	79
[그림 3-18] 키워드 광고 자동운영 프로그램의 흐름도	82
[그림 3-19] 조합된 데이터 소스 레이어의 동작	83
[그림 3-20] 인공지능 훈련 데이터 세트 구성	83
[그림 3-21] 인공지능 예측 시스템 블록 다이어그램	84

[그림 3-22] 온라인 광고 자동운영 인공지능 모델 1	85
[그림 3-23] 온라인 광고 자동운영 인공지능 모델 2	86
[그림 4-1] 데이터 수집 모듈 다이어그램	90
[그림 4-2] 조합된 데이터 소스 레이어 반영 성과분석 시스템의 계층 구조 ...	91
[그림 4-3] 데이터소스 빌더와 매트릭	92
[그림 4-4] 콤포넌트 빌더	93
[그림 4-5] 위젯 빌더	94
[그림 4-6] 페이지 구성 및 워크스페이스	95
[그림 4-7] 페이지 예시	96
[그림 4-8] 페이스북 광고 소재 자동 등록 프로그램 인터페이스	97
[그림 4-9] 네이버 검색 광고 성과 데이터	98
[그림 4-10] 인공지능 예측값을 활용한 수동 운영 예시	99
[그림 4-11] 고객 유입당 비용(CPC) 비교	104
[그림 4-12] 회원 가입당 비용(CPMR) 비교	105
[그림 4-13] 광고비 대비 매출(ROAS) 비교	106
[그림 4-14] 회원 가입률(MRR) 비교	107
[그림 4-15] 누수율 관리 전후 누수율 변화	110
[그림 4-16] 누수율 관리 전후 ROAS 변화	110
[그림 4-17] 활성화 함수별 정확도 비교	114
[그림 4-18] 학습률별 정확도 비교	115
[그림 4-19] 학습률별 손실값 비교	116
[그림 4-20] 데이터셋 예제	117
[그림 4-21] 첫 번째 데이터셋 조건별 정확도 비교	121
[그림 4-22] 데이터셋별 정확도 비교	122
[그림 4-23] 두 가지 모델의 정확도 비교	123

제 1 장 서 론

제 1 절 연구의 배경

2012년 온라인 광고 매출이 2조 4,617억 원으로 지상파 TV 온라인 광고비 매출인 2조 2,304억 원을 추월한 이래 온라인 광고 시장은 [그림 1-1]에 서처럼 계속 성장하여 2016년 온라인 광고 매출 4조 1,547억 원으로 전체 방송 광고비 매출 4조 1,351억 원을 추월하며 계속 그 차이를 벌리고 있다.¹⁾ 이러한 현상은 국내뿐만 아니라 해외에서도 나타나는 현상이며, 매년 전통적인 온라인 광고매체의 온라인 광고비가 줄어들고 있는 반면에, [그림 1-2]와 [그림 1-3]과 같이 온라인 광고의 광고비는 큰 폭으로 증가하는 현상을 보이고 있다.²⁾




[그림 1-1] 국내 온라인 광고 매출 추이(단위: 조 원)

1) 한국방송온라인 광고진흥공사. (2018). 『2018년 방송통신온라인 광고비 조사』.

2) ZenithOptimedia. (2020). *Advertising Expenditure Forecasts*.



[그림 1-2] 매체별 온라인 광고비 증감률



[그림 1-3] 글로벌 온라인 광고비 증감(2019년~2022년)

1) 온라인 광고의 역할

이렇게 지속적으로 성장하고 있는 온라인 광고는 특히 온라인 쇼핑물 산업에서 중요성이 높아지고 있다. 한국의 전자상거래 시장규모는 [그림 1-4]에 서와 같이 2020년 161조 원 규모로 전년 대비 19.3% 증가하며 높은 성장률을 보이고 있다.³⁾ 온라인 쇼핑물 산업인 전자상거래 시장은 스마트폰의 대중

화에 따른 모바일 전자상거래 시장의 폭발적인 신장세, 오픈마켓에 이은 소셜 커머스의 시장 안착, 대형유통사의 인터넷 투자 확대 등에 힘입어 매년 평균 20%에 달하는 가파른 신장세를 이어가고 있다.⁴⁾



[그림 1-4] 대한민국 전자상거래 시장 규모(단위: 조 원)

온라인 쇼핑몰에서 온라인 광고의 중요성은 오프라인 쇼핑몰과 온라인 쇼핑몰을 비교함으로써 더욱 확실하게 이해할 수 있다. 오프라인 쇼핑몰이 공간의 제약으로 인해 판매 가능한 상품의 종류가 제한적인 것에 반해 온라인 쇼핑몰은 공간의 제약이 없기 때문에 판매 가능한 상품의 제한이 없다는 장점이 있다. 그러나 고객의 입장에서 오프라인 쇼핑몰은 매장에 방문하여 직접 상품을 확인할 수 있는 반면, 온라인 쇼핑몰은 직접 상품을 확인할 수가 없다는 단점이 존재한다. 중소규모의 온라인 쇼핑몰 시장 현황은 2017년 기준으로 12조 원 규모로 증가하고 있고, 개인의 쇼핑몰까지 범위를 확대하면 하루에

3) 이슬전. (2021). 소프트웨어와 융합하는 전자상거래 시장 동향. 『월간 SW 중심사회』, pp. 14-23.

4) 김정국, 이상원, 최동운. (2016). 전자상거래에서 온라인 광고와 매출의 관련성 분석(Relevance Analysis of Online Advertisement and e-Commerce Sales). 『한국엔터테인먼트산업학회논문지』, 10(2), pp. 27-35.

도 수백 개씩 생겨나고 있는 실정이다. 이와 같이 증가세에 있는 소규모, 중 규모의 쇼핑몰은 고객 접점을 확보하는데 어려움을 겪고 있다. 고객에게 인지도가 낮은 소규모 전자상거래 업체에게 있어 고객과의 접점은 검색 광고나 디스플레이 광고, 인스타그램, 블로그, 트위터와 같은 SNS를 통한 광고 등 형태의 차이는 있을 수 있으나 온라인 광고가 유일하다. 이로 인해 전자상거래 산업의 광고에 대한 의존도는 높을 수밖에 없다. 실제로 인터넷 광고는 쇼핑몰 유입량을 증가시키는 긍정적인 결과로 나타났다.⁵⁾

2) 온라인 광고의 분류

온라인 광고의 분류 방법은 다양하게 존재하지만, 본 연구에서는 크게 소재, 형태, 디바이스의 3가지 방법으로 분류하고자 한다. 소재를 통한 분류는 온라인 광고의 소재가 무엇인지로 분류하는 방법으로 텍스트 온라인 광고, 이미지 온라인 광고, 동영상 온라인 광고 등으로 나눌 수 있다. 형태를 통한 분류는 온라인 광고의 형태가 무엇인지로 분류하는 방법이다. 예를 들어 키워드 검색 광고, 배너 등 이미지 노출 위주의 온라인 디스플레이 광고, 유튜브나 앱에서 볼 수 있는 콘텐츠 삽입형 광고가 있다.

한국인터넷진흥원에서 발간한 '2017년 온라인 광고 산업 동향 조사 및 분석'에 따르면, 다양한 온라인 광고 유형 중 이용자가 선호하는 유형은 '검색 광고'가 62.8%로 가장 높은 선호도를 보이고 있다. 온라인 광고 사업자가 뽑은 매출 연계성이 가장 높은 온라인 광고의 유형으로 40.3%의 사업자가 '검색 광고'로 답하였으며, 광고주도 매출 연계성이 가장 높은 온라인 광고의 유형을 '검색 광고'로 선택(31.5%)하고 있다. 이처럼 검색 광고는 전체 광고 유형 중에서 매우 중요한 비중을 차지하고 있다.⁶⁾ 우리나라의 경우 인터넷 검색 포털 중에서 네이버를 통한 유입량이 다른 검색 포털인 다음카카오나 구글보다 월등히 많다.⁷⁾ 검색 광고에 있어서 정보의 순위가 정보의 검색과 활용에 큰 영향을 끼침에 따라 검색 광고의 키워드의 순위가 점차 중요해지고 있다.⁸⁾

5) 손미영. (2020). 소자본 온라인 패션쇼핑몰 운영 사례 연구 - 4P mix 중심으로 -. 『복식』, 70(2), pp. 117-134.

6) Korea Internet & Security Agency. (2017). Online advertising industry trend research and analysis.

7) 김정국, 이상원, 최동운. (2016). 전자상거래에서 온라인 광고와 매출의 관련성 분석(Relevance Analysis of Online Advertisement and e-Commerce Sales). 『한국엔터테인먼트산업학회논문지』, 10(2), pp. 27-35.

8) McMahan, H. B., Holt, G., Sculley, D., Young, M., Ebner, D., Grady, J., & Kubica, J. (2013). Ad click prediction: a view from the trenches. In *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 1222-1230.

다른 광고 대비 검색 광고가 가지는 가장 큰 특징은 고객이 의지를 가지고 검색을 한 경우에만 노출되는 요구형 광고(On-Demand Advertising)라는 점이다. 디스플레이 광고와 같은 대부분의 다른 광고는 고객의 의지와는 관계없이 고객이 접속한 웹페이지에 노출되어 클릭과 유입을 기대하는 방식이다. 검색 광고는 기본적으로 광고 소재가 단어로 구성된 텍스트 키워드이다. 검색 광고가 효과를 내기 위해서 광고 소재를 선택할 때에는 우선 대표되는 상품이나 서비스명을 선택하며, 다음으로는 고객이 검색해볼 것으로 추정되는 키워드를 광고 소재로 등록하여 고객이 해당 키워드를 검색했을 때 노출되게 하는 것이 중요하다. 검색 광고는 고객이 키워드를 입력하고, 노출된 키워드를 통해 광고주의 홈페이지에 유입하는 것을 가장 중요한 목표로 한다. 고객이 키워드를 검색하면 여러 경쟁 광고주들의 동일한 키워드 소재가 노출되는데, 키워드 검색 광고의 광고 성과를 높이기 위해서는 키워드의 노출 순위가 중요하다. 이 노출 순위는 광고주가 설정하는 키워드 광고 경매 입찰가에 의해 정해진다. 노출 순위를 높이기 위해 키워드 입찰가를 높이면 노출 순위도 높아지지만, 과도하게 입찰가를 높일 경우 광고비 예산 소진으로 정작 필요한 시기에 노출 자체가 안되거나 너무 많은 광고비 지출로 인해 광고의 효율이 떨어질 수 있다. 따라서 광고 예산을 고려하여 적절한 순위를 유지하기 위해 입찰가를 조절하는 것이 필수적이다.

끝으로 디바이스로 분류하는 방법은 웹 기반의 온라인 광고와 모바일 앱 기반의 온라인 광고로 나눌 수 있다.

3) AD Tech 산업

온라인 광고는 온라인 광고의 시작부터 끝까지 데이터를 기반으로 진행이 되기 때문에 데이터를 활용한 다양한 부가 서비스를 만들 수 있다. 이렇게 온라인 광고 관련 데이터를 활용하여 서비스를 제공하는 산업을 AD Tech(Advertising + Technology) 산업이라는 이름으로 새로운 산업 분야로 발전하고 있다. 이 AD Tech 산업에서 온라인 광고 데이터를 활용하는 데 있어 디바이스로 분류하는 방법이 중요하다. 그 이유는 App 환경에서의 온라인


광고와 Web 환경에서의 온라인 광고의 특징이 다르기 때문이다. [표 1-1]은 두 환경의 특성 차이를 설명한 것이다.

[표 1-1] App 환경과 Web 환경의 차이

구분	App 환경	Web 환경
사용자 특정	Device = User	Device ≠ User
관심사	Device에서 무엇을 하는가	어떤 사용자가 인터넷에서 무엇을 하는가
데이터 저장	모든 행동은 Device ID와 함께 저장	모든 행동은 사용자 ID와 함께 저장
행동 추적	쉬움(Device ID만 추적하면 됨)	어려움(특정 Device의 사용자가 다수임. 사용자 ID가 없는 상황이 더 많음)

가) App 환경에서의 온라인 광고


App 환경에서는 단일 디바이스를 통해 단일 사용자가 앱을 실행하거나 인터넷을 사용하게 된다. 그렇기 때문에 [그림 1-5]에서처럼 디바이스와 사용자를 동일시 할 수 있다. 인터넷에서의 모든 활동은 디바이스의 유니크한 ID와 함께 저장이 되며, 이것은 사용자가 늘 로그인 한 상태로 인터넷을 이용하는 것과 동일하다. 데이터를 수집할 때 디바이스의 유니크한 ID만으로 사용자의 행동을 추적하는 것이 가능하다. 사용자를 특정할 때 해당 사용자가 소유한 디바이스의 유니크한 ID로 접속한 디바이스의 사용자로 간주할 수 있다. 디바이스의 ID만으로 사용자의 모든 행동 추적이 가능하여 Web 환경에 비해 사용자 행동 추적이 쉽다. 결국, 사용자의 특성에 맞는 온라인 광고를 해당 디바이스로 보내는 것으로 특정 사용자에게 맞춤형 온라인 광고가 가능하게 된다.



[그림 1-5] App 환경에서의 사용자 추적

나) Web 환경에서의 온라인 광고

Web 환경에서는 한 명의 사용자가 여러 디바이스를 사용하여 인터넷에 접속하고, 하나의 디바이스는 여러 명의 사용자가 사용하는 환경이기 때문에 [그림 1-6]에서처럼 디바이스로 사용자를 특정할 수 없다. 인터넷에서의 모든 활동은 디바이스를 통해 사용자를 특정할 수 없기 때문에 어떤 디바이스를 사용하고 있는지에 관계없이 사용자 ID를 통해서만 특정 사용자를 인식할 수 있다. 그러나 사용자 ID는 활동하는 웹사이트마다 다르고, 로그인 없이 활동하는 경우도 많기 때문에 행동 데이터는 여러 조건으로 나뉘어 저장된다. 이는 사용자의 행동 추적을 하기 어렵게 만들고, 특정 사용자의 특성에 맞는 온라인 광고를 해당 사용자에게 전달할 수 없는 경우가 많아 맞춤형 온라인 광고를 하기에 어려운 환경이다. 이로 인하여 App 환경에서의 온라인 광고 기술에 비해 Web 환경에서의 온라인 광고 기술의 발전이 제한적인 상황이다.



[그림 1-6] Web 환경에서의 사용자 추적

다) 개인정보 보호의 시대

2021년부터는 사용자의 인터넷 행동 추적이 더욱 어려워지게 된다. 2021년 4월 애플에서는 iOS 14.5 업데이트를 통해 개인정보보호를 강화하고 사용자의 인터넷 추적을 거부할 수 있도록 하였다. 또한, 구글 역시 크롬브라우저의 써드파티 쿠키를 삭제하여 사용자의 인터넷 행동 추적을 할 수 없도록 정책을 변경하게 된다. 이로 인해 페이스북 등 글로벌 온라인 광고매체조차 온라인 광고 성과를 실시간으로 제공하지 못하게 되었으며, 대부분의 AD Tech 회사들은 사용자의 행동 추적이 어려워졌기 때문에 제공하고 있는 서비스에 제한이 생기는 등 문제가 발생하고 있다. 페이스북의 경우 110여 가지가 넘는 광고 성과 데이터를 제공하고 있었으나, 개인정보보호가 강화된 이후에는 겨우 8가지만 제공하고 있다. 또한, 실시간으로 제공하던 광고 성과 데이터를 현재는 최대 72시간 지연된 데이터로 제공하고 있는 상황이다.

제 2 절 연구의 필요성

1) 온라인 광고 성과 향상의 어려움

온라인 광고는 광고매체마다 사용하는 용어가 다르고, 온라인 광고를 등록하거나 온라인 광고 운영 설정하는 방식이 달라 해당 온라인 광고매체를 처음 접하는 광고주나 마케터는 온라인 광고를 시작하는 것부터 어려움을 느끼게 된다. 이러한 작업은 매뉴얼화 되어 있기 때문에 방법에 대해 숙지를 한 이후에는 어려움을 느끼지 못하며, 방법을 알게 되면 단순한 작업이기 때문에 이를 해결해주는 AD Tech 기업들의 서비스가 많이 제공되고 있다. 반면에 광고의 성과를 향상시키는 부분은 많은 마케터들이 다양한 방법을 시도하고 있으며, 어느 정도 성과를 거두는 경우도 있지만, 외적 요인을 포함한 다양한 원인으로 항상 효과가 있는 것은 아니다. 모든 광고주와 마케터는 자신의 광고가 더 높은 성과를 내기를 원하지만, 일정 수준의 성과를 낸 이후에는 더 이상 성과를 높이는 것에 어려움을 겪게 된다. 온라인 광고의 성과에 영향을 미치는 요소는 크게 3가지가 있으며, 광고주 형태별로 소구하는 온라인 광고 성과가 다르다.

가) 온라인 광고 성과 영향 요소

온라인 광고의 성과에 영향을 미치는 요소는 여러 가지가 존재하지만, 일반적으로 중요하게 생각되는 온라인 광고 소재, 온라인 광고 전달, 광고를 통해 접속하게 되는 웹페이지 품질의 3가지에 대해 설명한다.

(1) 온라인 광고 소재

온라인 광고를 어떤 내용으로 만들 것인가에 대한 부분으로, 광고가 잠재 고객들의 눈길을 쉽게 끌 수 있으면 광고의 성과를 높일 수 있는 확률이 높아지게 된다. 성과가 높은 광고 소재는 트렌드에 민감하지만, 시대와 지역에

관계없이 독창성, 참신함, 유머 요소를 가진 소재가 사용자들에게 인기가 높으며, 잠재고객을 유인할 수 있는 확률이 높아져 광고 성과가 향상될 확률이 높다. 품질이 낮은 광고 소재는 광고매체에서 등록을 거절하기도 한다.⁹⁾

(2) 온라인 광고 전달

고객의 눈길을 끌 수 있는 온라인 광고 소재를 제작하였다면, 어떤 광고 매체를 통해 잠재고객에게 전달할 것인지, 언제 전달할 것인지, 어떤 잠재고객에게 전달할 것인지에 따라 광고의 성과가 달라지게 된다.¹⁰⁾ 예를 들어 20대 여성용 샌들 광고를 정치뉴스 관련 페이지에 광고를 하는 것보다 여성 패션 트렌드 소개 페이지에 광고를 하는 것이 효과가 좋을 것이다. 전자의 경우 광고의 노출 대비 광고를 클릭하는 비율이 낮아 광고 효율이 높지 않기 때문에 노출형 광고 과금 방식인 CPM(Cost Per Mile)의 경우 광고비 낭비가 발생한다. 만약 광고 소재가 20대 여성의 수영복이라고 가정한다면, 광고의 클릭률은 올라갈 수 있다. 따라서 유입을 목적으로 하는 광고라면 광고 효율이 좋아 보일 수 있으나 적절한 가망고객이 아니기 때문에 실질적으로는 광고 효율이 좋은 것이 아니다. 또한, 구매로 전환되는 비율이 낮아 구매 전환을 목적으로 하는 광고일 경우에도 광고 효율이 좋지 않은 결과를 가져온다. 유입이나 구매 전환 목적 광고는 광고 클릭당 비용을 지불하는 CPC(Cost Per Click) 방식인데, 이 또한, 광고비를 낭비하는 결과를 가져오게 된다. 광고 전달 시점도 광고 성과에 큰 영향을 미치게 되는데, 예를 들어 주요 가망 고객이 학생이거나 직장인인 경우 수업시간이나 근무시간, 새벽 등 가망 고객이 광고를 보기 힘든 시간대에는 광고 효과가 떨어지게 된다. 가망 고객 집단의 인터넷 주요 사용 시간대의 데이터를 활용하거나 24시간 동일한 광고 운영의 성과 데이터를 토대로 적정 시간을 도출하고, 해당 시간대에 광고를 집중적으로 노출하는 것이 가장 높은 광고 성과를 가져올 수 있게 된다. 온라인 광고 전달의 관점에서 가장 중요한 것은 정확한 광고 타겟 집단을 설정하는 것이

9) Facebook. 광고 품질 및 성과 개선을 위해 피해야 할 광고 속성.
<https://ko-kr.facebook.com/business/help/1767120243598011>

10) 김정훈. (2016). 성공하는 모바일 광고의 특징. 『동아 비즈니스 리뷰』, 11(2).

다. 타겟 집단을 잘못 설정하는 경우 해당 타겟 집단이 모여있는 광고매체를 설정하고, 가장 인터넷 활동이 활발한 시간에 노출한다 해도 광고주가 원하는 가망 고객의 유입과 구매 전환 성과는 낮을 수밖에 없다.

(3) 웹 페이지 품질

광고를 클릭했을 때 이동하게 되는 웹페이지의 품질 또한, 광고 성과를 향상시키는 중요한 요소이다.¹¹⁾ 광고 소재는 가망 고객의 관심을 끌었으나 클릭했을 때 도달하게 되는 웹페이지의 내용이 정작 가망 고객의 관심을 끌지 못해 해당 웹페이지에서 이탈하는 경우가 많다. 심지어 관심 가는 상품의 광고를 보고 클릭했을 때 홈페이지가 오류이거나, 광고 소재와 다른 상품이 노출되는 경우도 존재한다. 이러한 경우 아무리 광고 소재가 흥미를 유발하고, 적절한 고객에게 노출되어 지불한 광고비만큼 충분한 유입이 발생하였고 광고 성과가 좋은 것처럼 보일지라도 실질적인 광고 성과는 낮은 것으로 판단될 수 있다.

본 연구에서는 광고 소재와 광고를 클릭했을 때 도달하게 되는 웹페이지의 품질은 광고주의 책임으로 간주하고 온라인 광고 운영과의 연관성은 낮기 때문에 온라인 광고 전달에 초점을 맞추어 온라인 광고 효율을 높일 수 있는 방법을 연구한다.

나) 온라인 광고주 형태에 따른 차이

광고주의 형태에 따라 광고의 목적과 광고 성과의 평가에 있어서도 큰 차이를 보이게 된다. 본 연구에서는 이러한 차이를 보이게 되는 광고주의 형태를 온라인 쇼핑몰과 그 이외의 웹사이트, 두 가지로 나누고자 한다. 이 두 가지 형태의 광고주들은 각기 다른 특징으로 인해 온라인 광고를 실행하는 목적과 광고 성과의 평가 방법이 달라지게 된다.

11) Joydeep Bhattacharya. 9 Rules for Creating Ads that Convert.
<https://www.singlegrain.com/pay-per-click-2/9-rules-for-ads-that-convert/>

(1) 온라인 쇼핑몰

온라인 쇼핑몰의 가장 큰 특징은 웹사이트 내에서 제품이나 서비스를 판매가 가능하고 결제 수단을 가지고 있어 광고를 통해 유입된 고객의 구매와 결제 여부를 파악할 수 있다는 것이다. 그렇기 때문에 온라인 쇼핑몰의 주요 온라인 광고 실행 목적은 구매 전환이고 여러 가지 광고 성과지표 중 광고비 대비 구매금액 비율인 ROAS(Return On Advertising Spend)를 가장 중요하게 여기는 광고주와 마케터가 많다. 온라인 광고 운영의 관점에서 온라인 쇼핑몰의 특징은 광고 소재가 되는 제품이나 서비스의 수가 많고, 제품이나 서비스의 변경이 잦아 광고 소재 역시 잦은 변경이 필요하다. 이에 따라 광고의 운영 복잡해진다는 특징을 가지고 있다. 온라인 쇼핑몰에 따라 제품이나 서비스의 수가 적거나, 제품이나 서비스의 변경이 빈번하게 일어나지 않는 경우도 있다. 이 경우는 온라인 광고 운영의 복잡성이 낮아지지만, 온라인 쇼핑몰의 특징은 동일하기 때문에 본 연구의 내용 적용이 가능하다.

(2) 그 밖의 웹사이트


온라인 쇼핑몰을 제외한 일반 웹사이트의 경우 광고의 목적은 브랜드의 홍보나 유입, 회원 가입과 같은 사용자 활동을 위함이 대부분이다. 일부 사용자 활동을 목적으로 하는 전환 목적의 광고가 있을 수 있으나 대부분은 유입을 목적으로 광고를 운영한다. 이 경우 광고 소재의 수가 적으며, 변경 빈도도 낮아 광고 운영이 온라인 쇼핑몰에 비해 상대적으로 단순하다는 특징을 가지고 있다. 온라인 쇼핑몰의 복잡성에 대응할 수 있는 광고 운영 방법은 상대적으로 단순한 일반 웹사이트에도 적용이 가능하다.

2) 온라인 광고 운영의 어려움

온라인 광고 성과를 향상시키는 것의 어려움과는 별도로 온라인 광고 운영작업 자체도 온라인 광고 성과 향상을 어렵게 하는 요소들을 가지고 있다.

가) 온라인 광고 성과 파악

[그림 1-7] 페이스북 광고 운영 관리 화면



[그림 1-8] 페이스북 광고 성과 보고 화면

온라인 광고의 성과를 파악하는 방법은 광고매체에서 제공하는 광고 성과를 확인하는 것이다. [그림 1-7]과 [그림 1-8]에서처럼 기본적으로 모든 광고매체는 광고 운영 관리를 위한 기능과 광고 성과를 확인할 수 있는 기능을 제공한다. 여러 광고매체에 광고를 진행하는 경우 마케터는 각 광고매체에 접속하여 광고 성과를 각각 분석해야 한다. 제공하는 광고 성과지표는 광고매체별로 기준도 다르고 광고매체를 통합하여 확인할 수도 없다. 광고의 최소 단위인 광고 소재별로 성과를 제공 받기 어려운 경우도 많다. 더 큰 문제는 개인정보 강화 정책 이후 광고매체에서 제공하는 광고 성과 데이터가 제한적이라는 것이다.

₩111,911	—	—	—	30.3	광고 크리케티터즈
₩140,166	₩124,980	3	0.89	45.5	시간
₩139,617	₩97,828	2	0.70	40.6	☐ 일
₩140,481	₩119,670				☐ 주간
₩35,367	—				☒ 2주
₩69,151	₩130,714				☐ 월간
₩85,952	₩34,200	1	0.40	20.5	계재
₩76,199	₩88,540	3	1.16	14.6	☐ 연령
₩140,443	₩80,300	2	0.57	26.4	☐ 성
					☐ 비즈니스 위치
					☐ 국가
					☐ 지역
					☐ DMA 지역
					☐ 노출 기기
9% !당	₩52,701,496 총 지출	₩112,446,146 회 전제	3,590 회 전제	2.13 회 평균	

[그림 1-9] 페이스북 광고 성과 분석의 제한

[그림 1-9]는 페이스북이 광고 성과분석 데이터를 제공하는 화면이다. 기간을 설정할 경우 정확한 데이터가 아니라 추산치를 보여준다.

나) 온라인 광고 운영 방식

온라인 광고 운영작업은 크게 광고 관리, 광고 소재 관리, 광고비 관리의 3가지로 나눌 수 있다. 광고 관리는 광고의 계층 구조에 따라 광고를 새롭게 생성하고, 계층 단계별로 대상 고객의 성별이나 연령, 지역 등 조건 값을 설정하고, 해당 광고를 켜고 끄는 작업이다. 광고 소재 관리는 광고의 소재인 키워드나 이미지와 설명, 동영상 등을 제작하고 광고매체에 등록하거나 삭제하는 작업이다. 광고비 관리는 광고 계층별로 광고비를 설정하고 조정하는 작업이다. 이 작업 역시 광고 성과 확인과 마찬가지로 광고매체 별로 각각 접속하여 작업을 해야 하며, 광고 소재 단위의 관리를 하기 위해서는 다수의 관리 페이지를 거쳐야 하는 등 광고 소재 하나의 관리에도 많은 시간이 소요된다. 쇼핑몰의 경우 광고 소재의 수가 많고 교체 주기도 짧으며, 여러 광고매체에 광고를 운영하고 있기 때문에 광고 운영작업에도 많은 인적 리소스가 필요하다. 그렇기 때문에 광고 소재 단위의 운영이 아니라 광고 소재들을 그룹으로

묶어 운영하는 것이 일반적인 운영 방법이다. 이 경우 세밀한 광고 운영이 어렵기 때문에 광고 성과의 향상에도 한계가 있다.

3) 이상적인 온라인 광고 운영 방법

이상적인 온라인 광고 운영 방법은 광고 소재 단위로 광고의 성과를 측정하여 그 결과를 바탕으로 광고 목적에 부합하는 광고 성과지표를 높일 수 있는 광고 운영 방식을 채택하여 반복적으로 실행하는 것이다. 이상적인 온라인 광고 운영을 실행하는데 크게 3가지 넘어야 하는 어려움이 있다.


가) 광고 성과 실시간 파악

소재 단위의 광고 성과를 실시간으로 파악해야 하는데, 대부분의 광고매체에서는 광고 성과의 최소 단위가 광고 소재들의 묶음인 캠페인인 경우가 많다. 또한, 광고 성과를 실시간으로 제공하지 않는 광고매체도 많아 광고 소재 단위의 성과 파악도 어렵고, 광고 성과를 실시간으로 파악하는 것도 어려운 상황이다.

나) 광고 운영 기준 수립

파악한 광고 성과를 바탕으로 광고 운영 방식을 채택할 때 어떠한 기준으로 선택할 것인지를 결정하는 기준 수립도 용이하지 않다. 예를 들어 이전 광고 성과가 향상되었을 때 더 이상 향상되기 어려우니 광고 예산을 유지하거나 감액하는 것이 좋을지, 성과가 좋은 광고이니 광고 비용을 더 집행하여 더 높은 성과를 추구하는 것이 좋을지에 대한 기준을 수립해야 한다. 온라인 광고의 경우 이러한 기준이 단순히 이전 광고 성과만으로 결정하기에는 변수가 많아 유사한 광고 성과들에 동일한 광고 운영을 실행해도 동일한 결과가 나온다는 보장을 할 수 없다는 문제가 있다.

다) 대량의 소재 핸들링



[그림 1-10] 온라인 쇼핑몰의 광고 운영 Flow

쇼핑몰의 경우 광고 소재가 많고, 여러 광고매체에 광고를 진행해야 하며 광고 소재의 교체가 빈번하기 때문에 수백 개에서 수만 개에 달하는 광고 소재 성과를 실시간으로 파악하고, 운영작업을 하는 것은 인력으로 불가능하다. [그림 1-10]은 상품의 수가 많은 온라인 쇼핑몰에서 이상적인 광고 운영을 하기 위한 절차를 표현한 그림이다. 온라인 쇼핑몰 내 수 많은 상품이 광고 소재가 되고, 이 광고 소재는 여러 광고매체에 등록이 된다. 각 광고매체에서 개별 광고 소재의 광고 성과를 실시간으로 확인하여 광고 성과에 따라 운영 방법을 수립하고, 해당 광고매체의 광고 운영 페이지로 접속하여 수립된 운영 방법을 적용하여 광고 운영을 실행하는 절차로 진행이 된다. 이 절차는(광고 소재의 수 x 광고매체)의 수 만큼 진행이 되어야 하기 때문에 온라인 쇼핑몰의 규모에 따라 많으면 수십만 건을 동시에 처리해야 하는 어려움이 있다. 인력으로는 불가능하여 자동화 할 수 있는 방법이 필요하다.

제 3 절 연구의 목적 및 방법

1) 연구의 목적

온라인 광고를 집행하는 모든 광고주와 마케터는 온라인 광고의 성과 향상을 원하지만, 광고 소재 단위의 성과 파악이 어렵고, 성과를 파악한다 해도 성과에 따라 광고 운영을 어떠한 기준으로 해야 하는지 기준을 수립하기 어려우며, 광고 운영작업을 수동으로 해야 하기 때문에 광고 성과를 향상시킬 수 있는 운영에 어려움을 겪고 있다. 심지어 너무 많은 광고 소재의 수와 잦은 교체로 인하여 인력으로는 제대로 운영하는 것도 어려운 상황이다. 본 연구에서는 이러한 문제들을 다음의 방법으로 해결하고 모든 과정을 자동화 하여 광고 성과 향상이 가능한 방법을 제안하고자 한다.

가) 온라인 광고 성과의 파악

광고매체에서 제공하는 광고 성과는 광고 소재 단위의 성과까지 제공하지 않는 경우가 많다. 이를 파악하기 위하여 본 연구에서는 광고주의 쇼핑몰 사이트에 광고 소재 단위의 성과까지 수집할 수 있는 스크립트를 설치하여 실시간으로 데이터를 수집한다. 광고의 성과를 파악하는 것은 광고의 성과에 일정 수준 이상의 변화가 발생하였을 때 해당 성과를 운영에 반영하는 방법으로 진행하는 것이 이상적일 수 있으나 광고 성과가 일정 기간 이상 적은 변동성만을 가지는 것도 광고 운영에 반영할 필요가 있다. 본 연구에서는 일정 시간 단위로 광고 성과를 파악하여 운영에 반영하는 방식으로 진행한다.

나) 온라인 광고 운영의 자동화

광고의 운영은 광고매체의 광고 운영 관리 페이지에 접속하여 광고 소재 별로 작업을 하는 것이 일반적이다. 본 연구에서는 동시에 여러 개의 광고 소재의 운영을 실행해야 하기 때문에 수작업으로는 불가능하여 광고매체에서

제공하는 API를 활용하여 자동으로 운영을 실행하는 프로그램을 개발하여 적용하고자 한다.

다) 온라인 광고 운영 규칙 설정

광고 성과에 따라 어떠한 운영작업을 실행할 것인지를 설정하는 규칙을 수립해야 한다. 단순히 직전 광고 성과만을 반영하여 규칙을 수립할 경우 규칙에 따라 실행한 광고 운영의 결과가 매번 기대와 동일하지 않을 확률이 높다. 또한, 광고 소재에 따른 광고 운영 성과의 차이나 시기에 따라 달라지는 운영 성과의 차이 등 외부 환경을 모두 반영하기에는 조건으로 설정할 케이스의 수가 너무 많은 문제도 있다. 아울러 다양한 상황을 모두 고려하여 수식화 하는 것도 용이하지 않은 문제도 있다. 본 연구에서는 이러한 문제를 해결하기 위하여 운영과 운영에 대한 성과를 데이터셋으로 만들어 인공지능으로 모델링하고, 운영 성과가 최선으로 나올 수 있는 운영 방법을 도출하고자 한다. 본 연구에서는 이 세 가지에 대한 방법을 제안하고, 일부 기능을 구현하고 실제로 운영된 광고 데이터를 반영하여 광고 성과 향상을 확인하는 실험을 진행하고자 한다. 이를 통해 도출된 광고 운영 성과의 향상 결과를 바탕으로 온라인 쇼핑몰 사업자들의 온라인 광고 효율을 올려주는 방법을 제시하는 것을 본 연구의 목적으로 한다.

2) 연구의 방법

온라인 광고의 성과 파악을 위해 광고매체 데이터와 광고주 사이트의 로그 데이터를 수집하고 이를 분석하는 시스템을 설계하고 구현하며, 유연한 데이터 활용을 위한 자료 구조를 제안한다. 온라인 광고 운영의 자동화와 자동화를 위한 운영 규칙을 설정하기 위해 광고매체로 페이스북과 네이버를 선정한다. 페이스북은 디스플레이 광고 중 카탈로그 광고를 대상으로 운영 규칙과 자동운영 시스템을 설계하고 구현한다. 네이버는 키워드 검색 광고를 대상으로 하여 운영 규칙과 자동운영 시스템을 설계하고 구현한다. 구현된 자동운영

시스템의 성능을 측정하기 위하여 실제로 운영되고 있는 온라인 광고에 적용하여 실험을 진행하고, 이를 통해 유의미한 제안임을 검증하고자 한다.

제 2 장 관련기술 및 선행연구 분석

제 1 절 인공지능

1) 인공지능의 개념

인공지능은 사고나 학습 등 인간이 가지고 있는 지적 능력을 컴퓨터를 통해 구현하는 기술로 컴퓨터가 스스로 학습하여 인공지능의 성능을 향상시키는 머신러닝 기법을 통해 발전해왔다. 최근에는 인간의 뉴런과 비슷한 인공신경망 방식으로 정보를 처리하는 딥러닝 기법과 여기에서 파생된 다양한 모델링 기법을 사용하여 인공지능 모델의 정확도를 높여가고 있다. 인공지능은 학습 데이터에 정답의 명시 여부에 따라 지도학습(Supervised Learning)과 비지도학습(Unsupervised Learning)으로 구분되고, 데이터를 다수의 카테고리로 나누는 분류(Classification), 연속적인 값으로 매핑하는 리그레션(Regression), 유사한 데이터를 묶는 군집화(Clustering) 등으로 구분된다. 딥러닝은 머신러닝 기법 중 하나로 인간의 뇌 구조에서 시냅스의 중첩을 모방한 인공신경망 알고리즘에 기반한 방법으로 성능을 획기적으로 향상시켰다.¹²⁾ 전 세계적으로 인공지능에 대한 연구는 활발히 진행되고 있으며, 산업과 예측하고자 하는 데이터에 따라 매우 높은 예측 정확도를 가진 인공지능 모델들이 제안되고, 실생활에도 적용되고 있다.

2) 인공지능 모델링¹³⁾

전 세계적으로 인공지능에 대한 연구는 활발히 진행되고 있으며, 산업과 예측하고자 하는 데이터에 따라 매우 높은 예측 정확도를 가진 인공지능 모

12) 최예림, 김관호. (2016). 인공지능 개요 및 적용 사례. 『ie 매거진』, 23(2), pp. 23-29.












13) Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.

델들이 제안되고, 실생활에도 적용되고 있다. 본 연구에서는 기본이 되는 인공지능 모델을 포함하여 주요 인공지능 모델들에 대한 기술을 간략하게 정리하고자 한다.

가) ANN / DNN


인공지능을 구현하기 위하여 수많은 머신러닝 방법이 개발되었다. 인공신경망(NN, Neural Network)은 그런 머신러닝 방법 중 하나이다. 최근에는 인공 신경망을 복잡하게 쌓아 올린 딥러닝이 다른 머신러닝 방법들에 비해 높은 성능을 보이고 있기 때문에 대부분의 연구가 ANN(Artificial Neural Network)이나 DNN(Deep Neural Network)의 발전된 모델에 집중되어 있다. ANN은 기본적으로 인간의 신경망을 기본으로 만들어진 모델이다. AND 게이트나 OR 게이트, NAND 게이트를 구현할 수 있는 단층 신경망을 시작으로 단층 신경망으로는 구현할 수 없는 XOR 게이트를 구현하기 위한 비선형 영역을 구현하기 위한 다층 신경망으로 발전해왔다.¹⁴⁾

14) Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), pp. 31-44.

Structure	Types of decision regions	Exclusive OR problem	Classes with meshed regions	Most general region shapes
Single-layer 	Half Plane (Bounded by hyperplane)			
Two-layer 	Convex (Open or closed regions)			
Three-layer 	Arbitrary (Complexity limited by number of neurons)			

[그림 2-1] 신경망 구조별 기하학적 해석

[그림 2-1]과 같이 신경망 구조에 따라 XOR 게이트뿐만 아니라 복잡한 구조의 분류 문제도 해결이 가능하다.



[그림 2-2] 심층 신경망(DNN) 개념도

DNN(Deep Neural Network)은 [그림 2-2]와 같이 은닉층을 2개 이상 가지고 있는 학습 방법을 의미하며 ANN은 단일 은닉층을 보유한 학습방법을 포함하기 때문에 DNN과 ANN을 구분하는 경우도 있다. 최근의 연구에서는 단일 은닉층을 보유한 학습방법은 사용하고 있지 않아 두 방법을 구별하지 않고 사용하는 경우가 일반적이며, 본 논문에서도 DNN과 ANN을 구분하지 않고 동일한 개념으로 본다.

나) CNN¹⁵⁾

합성곱 신경망(CNN: Convolutional Neural Networks)은 학습 가능한 가중치와 편향을 가진 뉴런으로 구성되어 일반 신경망과 유사하다. 각 뉴런은 일부 입력을 수신하고 벡터의 곱연산을 수행하며 선택적으로 비선형성을 따른다. 2012년에 이미지 분류 벤치마크인 ImageNet 분류에서 높은 성능을 낼 수 있는 아키텍처로 합성곱 신경망을 사용하였으며¹⁶⁾, 이후 이미지 분류뿐만

15) LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), pp. 2278-2324.

16) Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, pp.

아니라 음성이나 텍스트 분류 등 광범위하게 활용되기 시작했다. 합성곱 신경망의 구조는 기본적으로 입력 → 패딩 → 합성곱 레이어 → 풀링 → 합성곱 레이어 → 풀링 → (합성곱 레이어와 풀링의 반복) → flattening → 출력의 형태로 되어있다.¹⁷⁾

다) RNN¹⁸⁾ / LSTM¹⁹⁾ / GRU²⁰⁾²¹⁾²²⁾²³⁾²⁴⁾

CNN과는 달리 순환신경망(RNN: Recurrent Neural Network) 모델은 시간의 흐름에 따라 생성되는 데이터를 기반으로 음성이나 문서 등 연속적인 데이터를 다루기에 적합한 모델이다. 순환신경망 모델의 기본 개념은 연속적인 데이터를 다룰 때 단계별로 새로운 입력값과 이전 단계의 출력값을 함께 계산하는 방식이다. 이번 단계의 데이터 결과물(Linear Projection)과 이전 단계의 데이터 결과물에 행렬곱(w)을 한 벡터데이터를 더한다. 그 결과값을 시그모이드, 하이퍼볼릭 탄젠트, ReLU 등 비선형 활성화 함수를 통해 이번 단계의 최종 결과물로 출력값을 만든다. 순환신경망 모델은 연속적인 데이터의 단계 수가 많아지면, 경사소멸문제(Vanishing Gradient Problem)²⁵⁾가 발생하


1097-1105.

- 17) Stanford University. Convolutional Neural Networks for Visual Recognition.
<https://cs231n.github.io/convolutional-networks/>
- 18) Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), pp. 533-536.
- 19) Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), pp. 1735-1780.
- 20) Cho, K., Van Merriënboer, B., Bahdanau, D., & Bengio, Y. (2014). On the properties of neural machine translation: Encoder-decoder approaches.
- 21) Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling.
- 22) Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2015). Gated feedback recurrent neural networks. In *International conference on machine learning*, pp. 2067-2075.
- 23) Chrupała, G., Kádár, A., & Alishahi, A. (2015). Learning language through pictures.
- 24) Jozefowicz, R., Zaremba, W., & Sutskever, I. (2015). An empirical exploration of Recurrent Network architectures. in *32nd International Conference on Machine Learning, ICML 2015*, 3, pp. 2332-2340.
- 25) Srivastava, R. K., Greff, K., & Schmidhuber, J. (2015). Highway networks.

여 오래된 기록 데이터가 사라지게 되는 문제가 발생하게 된다. 연속적인 데이터의 단계가 길어지면, tanh 계산을 여러 번 하게 되고, 이 값의 미분값은 0에서 1 사이이기 때문에 계산이 반복될수록 빠르게 0으로 수렴하게 되는 문제가 있다.²⁶⁾ 이로 인해 백프로파게이션을 할 수 없는 문제가 발생하기 때문에 기본적인 순환신경망 모델은 연속적인 데이터가 긴 경우에는 적합하지 않은 방법이라 할 수 있다.

경사소멸문제를 극복하기 위한 방법으로 고안된 모델이 LSTM(Long Short Term Memory) 모델이다. LSTM 모델은 Cell State(Information Flow)를 추가하여 데이터 소멸을 방지한다. 특정 시점에서 Cell State에 기록된 정보가 지워지지 않고, 다음 단계에서 활용되며, 이는 비선형 활성화 함수를 거치지 않았기 때문에 0으로 수렴하는 경사소멸문제를 해결할 수 있게 된다. 다만, 이를 위해 각각의 단계마다 너무 복잡한 계산이 필요한 단점이 있다. 이를 해결하기 위해 게이트 수를 줄여 단순화를 한 GRU(Gated Recurrent Unit) 모델이 제안되었다.

각 모델에 대한 개념도는 [그림 2-3]과 같다.²⁷⁾



[그림 2-3] RNN, LSTM, GRU 개념도


26) Khan, Z., Khan, S. M., Dey, K., & Chowdhury, M. (2019). Development and evaluation of recurrent neural network-based models for hourly traffic volume and annual average daily traffic prediction. *Transportation Research Record*, 2673(7), pp. 489-503.

27) Khan, Z., Khan, S. M., Dey, K., & Chowdhury, M. (2019). Development and evaluation of recurrent neural network-based models for hourly traffic volume and annual average daily traffic prediction. *Transportation Research Record*, 2673(7), pp. 489-503.

3) 활성화 함수(Activation Function)

인공지능 모델의 각 층(Layer)에서는 입력값과 가중치(W), 편향값(b)을 곱과 합연산을 통해 $a = Wx + b$ 를 계산하고 마지막에 활성화 함수(Activation Function)를 거쳐 $h(x)$ 를 출력값으로 산출한다. 활성화 함수는 인공지능으로 풀고자 하는 문제가 비선형이기 때문에 필요하다. 활성화 함수는 매우 다양하며, 인공지능으로 풀고자 하는 문제에 따라 다른 활성화 함수를 사용하기도 한다.²⁸⁾ 주요 활성화 함수는 다음과 같다.²⁹⁾

가) 시그모이드(Sigmoid)³⁰⁾



[그림 2-4] 시그모이드 함수와 미분함수

28) 이강희. (2020). 활성화 함수(Activation Function) 종류 및 정리.
<https://ganghee-lee.tistory.com/32>.

29) Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *towards data science*, 6(12), pp. 310–316.

30) Sibi, P., Jones, S. A., & Siddarth, P. (2013). Analysis of different activation functions using back propagation neural networks. *Journal of theoretical and applied information technology*, 47(3), pp. 1264–1268.

시그모이드 함수는 로지스틱 함수로 불리우기도 한다. 시그모이드의 수식은 수식(2-1), 미분식은 수식(2-2)와 같다.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad \text{수식(2-1)}$$

$$\sigma'(x) = \sigma(x)(1 - \sigma(x)) \quad \text{수식(2-2)}$$

시그모이드 함수의 값의 범위는 $[0, 1]$ 이며, 그래프는 [그림 2-4]와 같다.


시그모이드 함수는 입력값이 아주 작거나 아주 큰 경우 기울기가 매우 작아져 Vanishing Gradient라는 현상이 발생한다. 이 문제는 시그모이드 함수를 활용하여 여러 개의 층(Layer)를 쌓았을 때 출력층에서 멀어질수록 기울기가 거의 0인 일부 노드들에 의하여 입력층으로 갈수록 대부분의 노드에서 기울기가 0이 되어 입력층에 가까운 노드들은 학습이 되지 않는 문제이다. 시그모이드 함수는 주로 이진 분류(Binary Classification)의 경우에 사용한다. 이진 분류는 출력층 노드가 1개이며, 이 노드에서 0~1 사이의 값을 가지기 때문이다. 시그모이드 함수를 구현하기 위한 파이썬 코드는 [그림 2-5]와 같다.

```
import numpy as np

def sigmoid(z):
    return 1 / (1 + np.exp(-z))
```

[그림 2-5] 시그모이드 함수 파이썬 코드

나) 하이퍼볼릭 탄젠트(Tanh)³¹⁾



[그림 3-6] 하이퍼볼릭 탄젠트 함수와 미분함수

하이퍼볼릭 탄젠트 함수는 [그림 2-6]에서처럼 시그모이드 함수와 유사하며, 값의 범위가 $[-1, 1]$ 이라는 점만 다르다. 대부분의 경우 시그모이드보다 성능이 좋으나 시그모이드 함수와 마찬가지로 Vanishing Gradient 문제가 발생하는 단점이 있다. 하이퍼볼릭 탄젠트 함수의 수식은 수식(2-3), 미분식은 수식(2-4)와 같다.

$$\tanh(x) = 2\sigma(2x) - 1 = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \text{수식(2-3)}$$

$$\tanh'(x) = 1 - \tanh^2(x) \quad \text{수식(2-4)}$$

31) Karlik, B., & Olgac, A. V. (2011). Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4), pp. 111-122.


하이퍼볼릭 탄젠트 함수를 구현하기 위한 파이썬 코드는 [그림 2-7]과 같다.

```
import numpy as np

def tanh(z):
    return np.tanh(z)
```

[그림 2-7] 하이퍼볼릭 탄젠트 함수 파이썬 코드

다) ReLU(Rectified Linear Unit)³²⁾



[그림 2-8] ReLU 함수와 미분함수

ReLU(Rectified Linear Unit)는 가장 많이 사용되는 활성화 함수이다. 수식은 수식(2-5)와 같으며, $x > 0$ 이면 기울기가 1인 직선, 그 외에는 0이 된다. 그래프는 [그림 2-8]과 같다.

$$a = \max(0, z)$$

수식(2-5)

32) Agarap, A. F. (2018). Deep learning using rectified linear units (relu).

ReLU는 계산의 복잡성이 낮아 Sigmoid나 하이퍼볼릭 탄젠트에 비해 속도가 매우 빠르다. 이는 지수함수(Exponential Function)에 의해 미분을 계산하는 경우에도 미분값이 0이나 1이기 때문이다. 특히 최적화 함수를 확률적 경사하강법(SGD: Stochastic Gradient Descent)을 사용할 때 선형 함수이기 때문에 빠르게 계산이 가능하다. 그러나 $x < 0$ 일 경우 기울기가 0이 되기 때문에 입력값이 0보다 작을 경우 더 이상 업데이트가 되지 않는 문제가 있다.³³⁾ ReLU 함수를 구현하기 위한 파이썬 코드는 [그림 2-9]와 같다.


```
import numpy as np

def relu(z):
    return z * (z > 0)
```

[그림 2-9] ReLU 함수 파이썬 코드

33) Lu, L., Shin, Y., Su, Y., & Karniadakis, G. E. (2019). Dying relu and initialization: Theory and numerical examples.

라) leaky ReLU³⁴⁾



[그림 2-10] leaky ReLU 함수와 미분함수

leaky ReLU는 입력값이 $x < 0$ 일 경우 문제가 발생하는 ReLU 활성화 함수의 단점을 극복하기 위해 고안된 활성화 함수이다. 수식은 수식(2-6)과 같으며, 그래프는 [그림 2-10]과 같다. 그래프에서는 알기 어려우나 수식에서는 알 수 있듯이 $x < 0$ 일 경우 기울기가 0이 아니라 0.01이 된다.

$$f(x) = \max(0.01x, x) \quad \text{수식(2-6)}$$

leaky ReLU 함수를 구현하기 위한 파이썬 코드는 [그림 2-11]과 같다.


34) Dubey, A. K., & Jain, V. (2019). Comparative study of convolution neural network's relu and leaky-relu activation functions. In *Applications of Computing, Automation and Wireless Systems in Electrical Engineering*, pp. 873-880

```
import numpy as np

def leaky_relu(z):
    return np.maximum(0.01 * z, z)
```

[그림 2-11] leaky ReLU 파이썬 코드

마) ELU(Exponential Linear Units)³⁵⁾




[그림 2-12] ELU, LReLU(Leaky Relu),
ReLU 비교

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ \alpha(e^x - 1) & \text{if } x \leq 0 \end{cases} \quad \text{수식(2-8)}$$

ELU(Exponential Linear Units)는 [그림 2-12]와 수식(2-8)에서처럼 ReLU의 임계점을 -1로 낮춘 함수를 e^x 를 이용하여 0 근처에서 항상 미분이 가능하도록 만들었다. 이를 통해 ReLU의 장점을 모두 포함하고, 단점은 해결하였다. 그러나 ReLU와 Leaky ReLU에 비하여 지수함수(exponential function)에 대한 미분값을 계산해야 하기 때문에 복잡도는 올라간다.

35) Clevert, D. A., Unterthiner, T., & Hochreiter, S. (2015). Fast and accurate deep network learning by exponential linear units (elus).

바) 소프트맥스(Softmax)³⁶⁾



[그림 2-13] 소프트맥스 함수 그래프

소프트맥스 함수는 주로 출력층에서 사용된다. 시그모이드 함수가 2가지 선택지 중 하나를 고르는 이진 분류(Binary Classification) 문제에 활용되는데 비해 소프트맥스 함수는 세 가지 이상의 선택지 중 하나를 고르는 다중 클래스 분류(Multi Class Classification) 문제에 사용된다.³⁷⁾ 그래프는 [그림 2-13]과 같으며³⁸⁾, 수식은 수식(2-9)와 같다.


$$\sigma(z)_i = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad \text{수식(2-9)}$$

36) Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *towards data science*, 6(12), pp. 310-316.

37) Asadi, B., & Jiang, H. (2020). On approximation capabilities of ReLU activation and softmax output layer in neural networks.

38) 유원준. 딥러닝을 이용한 자연어 처리 입문. <https://wikidocs.net/24987>.

4) 손실함수(Loss Function)



[그림 2-14] 딥러닝의 손실함수

손실함수는 [그림 2-14]와 같이 실제값과 예측값의 차이를 수치화해주는 함수이다. 이 두 값의 차이, 즉, 오차가 클수록 손실함수의 값은 크고 오차가 작을수록 손실함수의 값은 작아진다. 회귀분석 문제에서는 평균 제곱 오차, 분류 문제에서는 크로스 엔트로피를 손실함수로 사용한다. 손실함수의 값을 최소화하는 두 개의 매개 변수인 가중치 W 와 편향 b 를 찾아가는 것이 딥러닝의 학습 과정이므로 손실함수의 선정은 매우 중요하다.³⁹⁾ 주요 손실함수는 다음과 같다.

가) 평균제곱오차(MSE: Mean Squared Error)

평균제곱오차의 수식은 수식(2-10)과 같으며, 일반적으로 회귀분석에서 모델의 정확도를 판단할 때 사용하는 값을 계산할 때 사용된다. 인공지능 모델링에서도 유사한 용도로 사용되며, 연속형 변수를 예측할 때 사용한다.⁴⁰⁾

$$-\frac{1}{N} \sum (y - \hat{y})^2 \quad \text{수식(2-10)}$$

39) 유원준. 딥러닝을 이용한 자연어 처리 입문. <https://wikidocs.net/24987>.

40) 딥러닝, 손실함수, 평균제곱오차(MSE). <https://gooopy.tistory.com/61>.


나) 크로스 엔트로피(Cross-Entropy)⁴¹⁾

$$-\sum y \log \hat{y} \quad \text{수식(2-11)}$$

크로스 엔트로피는 수식(2-11)에서처럼 실제값(y , 0 또는 1)과 예측값($\hat{y}$, 확률)이 맞는 경우에는 0으로 수렴하고, 값이 틀릴 경우에는 값이 커지기 때문에, 실제값과 예측값의 차이를 줄이기 위한 엔트로피라고 할 수 있다.

5) 학습 파라미터 최적화(Optimizer)


딥러닝의 학습은 손실함수(Loss Function)의 최소값을 찾는 것을 목표로 한다. 손실 값은 예측값과 실제값의 차이를 의미한다. 즉, 딥러닝의 학습은 손실함수의 함수값이 최소화 되도록 하는 가중치(weight)와 편향(bias)를 찾는 것이다. 최소값을 찾아가는 방법을 최적화(Optimization)이라 하고, 최적화를 수행하는 여러 가지 알고리즘을 최적화 알고리즘(Optimizer)라고 한다. 또한, 딥러닝 학습모델의 각 층의 가중치와와 편향 등 학습 파라미터의 초기값 설정도 중요하다.



[그림 2-15] convex와 non-convex 그래프 비교

41) Zhang, Z., & Sabuncu, M. R. (2018). Generalized cross entropy loss for training deep neural networks with noisy labels. In *32nd Conference on Neural Information Processing Systems (NeurIPS)*.

딥러닝을 통해 해결하고자 하는 문제가 [그림 2-15]와 같은 논컨벡스 최적화(non-convex optimization)이기 때문에⁴²⁾ 여러 곳의 부분적 최소값(local minimum)이 존재한다. 따라서 시작점에 따라 최적지점을 찾지 못하게 될 수도 있다.⁴³⁾



[그림 2-16] 다양한 최적화 알고리즘

최적화 알고리즘은 연구를 통해 다양하게 제시되고 있다. 최적화 알고리즘은 [그림 2-16]과 같이 다양한 종류가 있으며, 주요 알고리즘은 다음과 같다.

가) 경사하강법(Gradient Descent)

경사하강법은 학습 파라미터 최적화 기법으로 널리 사용되고 있으며, 수식 (2-12)로 나타낼 수 있다.

42) 백지오. (2020). Convexity와 딥러닝(Convex Function과 Convex Set).
<https://skyl.tistory.com/33>.

43) Ruder, S. (2016). An overview of gradient descent optimization algorithms.

$$\theta \leftarrow \theta - \eta \frac{\partial L}{\partial \theta} \quad \text{수식(2-12)}$$

θ 는 갱신하고자 하는 학습 파라미터를 의미하며, $\frac{\partial L}{\partial \theta}$ 은 손실값에 대한 θ 의 경사 방향, η 는 학습률(Learning Rate)을 의미한다. 즉, 손실값에 대하여 θ 의 경사 방향으로 η 만큼 θ 를 갱신하는 것이다. 경사하강법에도 여러 가지 변형이 존재하는데, 그 중 주요한 3가지는 다음과 같다.

(1) 일괄 경사하강법(Batch Gradient Descent)⁴⁴⁾

일괄 경사하강법은 전체 학습데이터의 손실값에 대한 각 파라미터의 경사값을 모두 구한 후 한 번의 epoch이 실행되는 동안 모든 파라미터 갱신을 한 번만 수행하는 방식이다. 파라미터 업데이트를 위해 데이터 전체를 계산에 이용하기 때문에 속도가 느리고 메모리 요구량이 많다는 단점이 있으나 최적해를 찾을 수 있다는 장점이 있다. 일괄 경사하강법을 구현하기 위한 파이썬 코드는 [그림 2-17]과 같다.

```
for i in range(nb_epochs):
    params_grad = evaluate_gradient(loss_function, data, params)
    params = params - learning_rate * params_grad
```

[그림 2-17] 일괄 경사하강법 파이썬 코드

(2) 확률적 경사하강법(SGD: Stochastic Gradient Descent)⁴⁵⁾

확률적 경사하강법은 학습데이터의 순서를 무작위로 섞은 후 개별 데이터 단위로 손실값과 경사도를 구하여 학습 파라미터를 업데이트 하는 방식이다.

44) Ruder, S. (2016). An overview of gradient descent optimization algorithms.

45) Robbins, H., & Monro, S. (1951). A stochastic approximation method. *The annals of mathematical statistics*, pp. 400–407.

한 번의 epoch이 실행되는 동안 학습데이터 수 만큼 업데이트가 실행되어 일괄 경사하강법보다 속도가 빠르며, 학습률을 줄였을 때 일괄 경사하강법만큼의 최적해를 찾을 수 있는 장점이 있다. 하지만, 일정하지 않은 경사값으로 파라미터를 업데이트하는 경우 최적해를 찾기 위한 복잡도가 늘어난다.⁴⁶⁾ 확률적 경사하강법을 구현하기 위한 파이썬 코드는 [그림 2-18]과 같다.

```
for i in range(nb_epochs):
    np.random.shuffle(data)
    for example in data:
        params_grad = evaluate_gradient(loss_function, example, params)
        params = params - learning_rate * params_grad
```

[그림 2-18] 확률적 경사하강법 파이썬 코드

(3) 소규모 일괄 경사하강법(Mini-batch Gradient Descent)⁴⁷⁾

소규모 일괄 경사하강법은 개별 데이터가 아니라 지정된 단위(batch_size)로 학습한다는 점을 제외하고는 확률적 경사하강법과 동일하다. 확률적 경사하강법에 비하여 안정적으로 학습하는 경향이 있다. 또한, 데이터를 지정된 단위로 나누기 때문에 행렬 연산으로 계산할 수 있어 검증된 다양한 라이브러리를 활용하여 코드를 구현할 수 있다는 장점도 있다.⁴⁸⁾ 소규모 일괄 경사하강법을 구현하기 위한 파이썬 코드는 [그림 2-19]와 같다.

46) Duchi, J., Hazan, E., & Singer, Y. (2011). Adaptive subgradient methods for online learning and stochastic optimization. *Journal of machine learning research*, 12(7), pp. 2121–2159.

47) Duchi, J., Hazan, E., & Singer, Y. (2011). Adaptive subgradient methods for online learning and stochastic optimization. *Journal of machine learning research*, 12(7), pp. 2121–2159.

48) Hinton, G., Srivastava, N., & Swersky, K. (2012). Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. *Cited on*, 14(8), 2.


```

for i in range(nb_epochs):
    np.random.shuffle(data)
    for batch in get_batches(data, batch_size=50):
        params_grad = evaluate_gradient(loss_function, batch, params)
        params = params - learning_rate * params_grad

```

[그림 2-19] 소규모 일괄 경사하강법 파이썬 코드

나) 모멘텀(Momentum)⁴⁹⁾



[그림 2-20] 부분적 최소값 문제와 모멘텀을 통한 해결

일반적으로 경사하강법은 [그림 2-20]과 같이 전체 그래프의 최저점이 아닌 중간 부분을 최저점으로 인식하는 부분적 최소값(local minimum) 문제를 겪게 된다. 이를 해결하기 위한 방법으로 사용되는 것이 모멘텀 방식이다. [그림 2-20]에서(a)는 A점에서 부분적 최소값에 빠지게 되나(b)는 경사가 지속되는 것에 의한 모멘텀이 더해지면서 부분적 최소값인 A 구간을 빠져나갈 수 있다. 운동량을 뜻하는 물리 현상과 관계가 있는 모멘텀은 경사를 따라 움직이는 물체가 기울기 방향으로 가속하게 된다는 점에서 기인된 방법으로 수식(2-13)과 같이 나타낼 수 있다.

$$\begin{aligned}
 v &\leftarrow \mu v - \eta \frac{\partial L}{\partial \theta} \\
 \theta &\leftarrow \theta + v
 \end{aligned}
 \tag{수식(2-13)}$$

49) Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural networks*, 12(1), pp. 145-151.

μ 는 물리에서 지면 마찰이나 공기 저항에 해당되는 수치로 아무런 힘을 받지 않는 상태에서 서서히 하강하는 역할을 하며, 이 부분을 제외하고는 경사하강법과 동일하다. 경사도가 모멘텀과 동일한 방향이라면 더 큰 값으로 업데이트가 되는 방식이다. 모멘텀을 구현하기 위한 파이썬 코드는 [그림 2-21]과 같으며, μ 는 사용자가 지정하는 하이퍼파라미터이다.

```
param_grad = evaluate_gradient(loss_function, data, params)
v = mu * v - learning_rate * param_grad
param = v + param
```

[그림 2-21] 모멘텀 파이썬 코드

다) 적응형 경사하강법(AdaGrad)⁵⁰⁾과 ADADELTA⁵¹⁾

확률적 경사하강법과 모멘텀은 모두 학습 파라미터에 같은 학습률을 적용한다. 최적해를 빠르게 찾기 위해서 학습 파라미터의 업데이트 빈도에 따라 학습률을 다르게 해줄 필요가 있다. 적응형 경사하강법은 학습률을 조정하면서 학습을 하는 방식이다. 업데이트의 정도를 알기 위해 적응형 경사하강법은 이전의 경사도를 저장한다. 이를 통해 업데이트 값이 큰 경우 학습률을 낮추는 조정을 거치게 된다. 이 경우 값의 증가에 따라 학습률이 소실되는 문제점이 있다.

ADADELTA는 적응형 경사하강법의 학습률 소실 문제를 해결하기 위한 알고리즘이다. 이 방식은 이전의 모든 경사값 정보를 저장하지 않고, 이전 x 개의 경사값 정보만을 저장한다. 이전 경사값 정보의 영향력을 감소시켜 문제를 해결한다.

50) Ward, R., Wu, X., & Bottou, L. (2019). AdaGrad stepsizes: Sharp convergence over nonconvex landscapes. In *International Conference on Machine Learning*, pp. 6677–6686.

51) Zeiler, M. D. (2012). Adadelta: an adaptive learning rate method.

라) RMSProp⁵²⁾

RMSProp은 ADADELTA와 동일하게 적응형 경사하강법의 학습률 소실 문제를 해결하기 위해 개발된 알고리즘이다. 이전의 경사값 정보들을 모두 동일한 가중치로 계산하지 않고 오래된 경사값 정보는 적은 가중치를 부여하고, 최근의 경사값 정보는 큰 가중치를 부여하기 위해 지수이동평균을 적용한다.⁵³⁾ RMSProp을 구현하기 위한 파이썬 코드는 [그림 2-22]와 같으며, decay_rate는 사용자 지정 하이퍼파라미터이고 보통 [0.9, 0.99, 0.999] 중 하나를 사용한다.

```
params_grad = evaluate_gradient(loss_function, data, params)
h = decay_rate * h + (1 - decay_rate) * params_grad**2
params = params - learning_rate / (np.sqrt(h) + eps) * params_grad
```

[그림 2-22] RMSProp 파이썬 코드

마) Adam⁵⁴⁾

Adam은 모멘텀과 RMSProp을 모두 적용하여 경사도가 모멘텀과 동일한 방향이라면 더 큰 값으로 업데이트하고, 각 데이터마다 학습률을 다르게 적용한다. 성능이 다른 알고리즘에 비해 좋은 편이어서 일반적으로 가장 많이 사용되는 최적화 알고리즘이다. Adam을 구현하기 위한 파이썬 코드는 [그림 2-23]과 같으며, beta1, beta2, eps는 사용자가 지정하는 하이퍼파라미터이다. 각각 0.9, 0.999, 10^{-8} 을 지정하는 경우 좋은 성과를 보인다.⁵⁵⁾

52) Xu, D., Zhang, S., Zhang, H., & Mandic, D. P. (2021). Convergence of the rmsprop deep learning method with penalty for nonconvex optimization. *Neural Networks*, 139, pp. 17-23.

53) Zou, F., Shen, L., Jie, Z., Zhang, W., & Liu, W. (2019). A sufficient condition for convergences of adam and rmsprop. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 11127-11135.

54) Dozat, T. (2016). Incorporating nesterov momentum into adam.

55) Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization.

```

params_grad = evaluate_gradient(loss_function, data, params)
m = beta1 * m + (1 - beta1) * params_grad
v = beta2 * v + (1 - beta2) * params_grad**2
params = params - learning_rate * m / (np.sqrt(v) + eps)

```

[그림 2-23] Adam 파이썬 코드

6) 기타 학습 기법들

가) 과적합 방지

과적합(Overfitting)이란 인공지능 모델이 학습데이터에 과도하게 적응되어 일반화 성능이 떨어지는 경우이다. 인공지능 모델이 실제로 사용되기 위하여 학습데이터 이외의 데이터에서도 성능이 유지되어야 한다. 과적합 상태인 경우 학습데이터에는 높은 성능을 보이지만 학습데이터 외 데이터에는 낮은 성능을 보이는 경우이다. 과적합을 방지하기 위한 기법은 다음과 같다.

(1) 모델 복잡도 줄이기

가장 간단한 방법으로 은닉층의 수나 매개변수 등 하이퍼파라미터의 수를 줄이는 방법이다.

(2) 데이터 양 늘리기

인공지능 모델은 데이터의 양이 적을 경우, 해당 데이터의 특정 패턴이나 노이즈의 영향으로 과적합 현상이 발생할 확률이 증가한다. 따라서 데이터의 양을 늘릴수록 인공지능 모델은 데이터의 일반적인 패턴을 학습하여 과적합을 방지할 수 있다. 만약, 준비된 데이터의 양이 적을 경우 의도적으로 기존의 데이터를 조금씩 변형하고 추가하여 데이터의 양을 늘려 사용하는 데이터 증식 또는 증강(Data Augmentation) 기법을 활용하기도 한다.⁵⁶⁾

56) 유원준 et al. (2021). 딥러닝을 이용한 자연어 처리 입문.

(3) 빠른 중지(Early Stopping)

학습과 함께 검증오차를 지속적으로 확인하여 검증오차가 현 단계까지의 최소값보다 높아질 경우 학습을 중단하고 최소값의 검증오차를 산출한 모델을 최종 모델로 사용하는 기법이다.⁵⁷⁾

(4) 가중치 감소(Weight Decay)


복잡한 모델이 간단한 모델보다 과적합 가능성이 높다. 가중치 감소(Weight Decay)는 이를 방지하기 위해 학습 파라미터의 값이 큰 경우 그에 상응하는 패널티를 비례하여 부여하는 기법이다.

가중치 감소 중 L1 규제(Regularization) 방식은 기존 손실함수에 학습 파라미터의 절대값을 더하는 방식으로 학습 파라미터를 거의 0에 가깝게 만드는 특성을 가진다. 가중치 감소 중 L2 규제(Regularization) 방식은 가장 일반적인 기법으로 기존 손실함수에 모든 학습 파라미터의 제곱을 더한 식을 새로운 손실함수로 사용한다. 이 기법은 큰 값이 많이 존재하는 가중치에 제약을 주고, 가중치 값을 가능한 널리 퍼지도록 하는 효과를 준다. L1과 L2를 혼합하여 사용하거나 동시에 사용하기도 한다.⁵⁸⁾

57) Kim, M. S., Lee, J. K., Choi, Y. H., Kim, S. H., Jeong, K. W., Kim, K. L., & Lee, S. S. (2020). A Study on the Optimal Setting of Large Uncharged Hole Boring Machine for Reducing Blast-induced Vibration using Deep Learning. *Explosives and Blasting*, 38(4), pp. 16-25.

58) Ying, X. (2019). An overview of overfitting and its solutions. In *Journal of Physics: Conference Series*, 1168(2), p. 022022.

(5) Dropout




[그림 2-24] Dropout 예시

Dropout은 [그림 2-24]에서처럼 학습과정에서 신경망의 일부를 사용하지 않는 방법이다. 학습시에는 신경망 일부를 무작위로 삭제하고, 테스트할 때에는 모든 신경망을 사용한다. 이를 통해 학습시 특정 뉴런이나 특정 조합에 의존성이 강해지는 것을 방지해주고, 매번 무작위로 신경망을 삭제하기 때문에 서로 다른 신경망들을 앙상블(ensemble) 하는 효과를 통해 과적합을 방지한다.⁵⁹⁾

59) Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), pp. 1929-1958.

나) 학습률 감소



[그림 2-25] 학습률에 따른 학습곡선 비교

학습률은 [그림 2-25]과 같이 과도하게 크면 학습을 할 수 없고, 과도하게 작으면 학습시간이 너무 길어지는 문제가 있다. 학습의 시작부터 종료 시점까지 동일한 학습률로 학습을 진행할 수 있으나 학습이 진행되면서 해당 인공지능 모델이 최적화 지점에 수렴하게 되므로 점진적으로 학습률을 작게 하는 것이 더 좋은 결과를 낼 수 있다.⁶⁰⁾ 스텝 감소(Step Decay)는 간단한 방법으로 스텝마다 일정하게 학습률을 줄이는 방식이다. 예를 들어 epoch을 5회 실행시마다 50%를 감소하거나, epoch을 20회 실행시마다 10%씩 감소하는 방법이다. 데이터나 신경망 구조에 따라 일률적으로 적용하는 것은 바람직하지 않다. 개선된 모델로 지수 감쇠 방식⁶¹⁾도 있으며, 학습률 감소보다 배치 사이즈를 증가하는 것이 좋다는 연구도 있다.⁶²⁾

60) You, K., Long, M., Wang, J., & Jordan, M. I. (2019). How does learning rate decay help modern neural networks?

61) An, W., Wang, H., Zhang, Y., & Dai, Q. (2017). Exponential decay sine wave learning rate for fast deep neural network training. In *2017 IEEE Visual Communications and Image Processing (VCIP)*, pp. 1-4.

다) 하이퍼파라미터 최적화

사용자가 변경할 수 없는 학습 파라미터(모델 파라미터라고도 한다)와 달리 하이퍼파라미터는 사용자가 지정하는 값이다. 최적의 학습 모델을 구현하기 위하여 설정하는 값으로 학습률(Learning Rate), epoch 수(훈련 반복 횟수), 활성화 함수, 최적화 함수, 손실함수, 가중치 초기화, 배치 크기, 은닉층의 수 등이 있다. 하이퍼파라미터의 최적값은 데이터셋이나 인공지능 모델 구조마다 다르며 사전에 알기 어렵다. 최적값을 구하는 일반적인 절차는 다음과 같다.

- 1단계 : 하이퍼파라미터 값 범위 설정
- 2단계 : 설정된 범위에서 하이퍼파라미터의 값을 무작위 추출
- 3단계 : 샘플링한 하이퍼파라미터 값을 사용하여 학습 후 검증 데이터로 정확도 평가
- 2단계와 3단계 반복. 결과에 따라 하이퍼파라미터 범위를 축소하며 최적값 도출

하이퍼파라미터의 최적화 기법으로 그리드 서치(Grid Search)⁶³⁾, 랜덤 서치(Random Search)⁶⁴⁾, 베이지안 옵티마이제이션(Baysian Optimization)⁶⁵⁾ 등 다양한 방법이 존재하며, 지속적인 연구가 이루어지고 있다. 본 연구에서는 최적의 성과를 도출하기 위해 상기 서술된 관련 기술을 조합하여 활용하였다.

62) Smith, S. L., Kindermans, P. J., Ying, C., & Le, Q. V. (2017). Don't decay the learning rate, increase the batch size.

63) Bergstra, J., Bardenet, R., Bengio, Y., & Kégl, B. (2011). Algorithms for hyper-parameter optimization. *Advances in neural information processing systems*, 24.

64) Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of machine learning research*, 13(2).

65) Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. In *Automated machine learning*, pp. 3-33.

제 2 절 선행연구

1) 온라인 광고 성과지표에 대한 선행 연구

지속적으로 성장하고 있는 온라인 광고 시장은 광고비 집행이 늘어남에 따라 광고 성과를 확인하고자 하는 요구가 강한 시장이다. 전통적 매체와는 달리 온라인 광고는 모든 광고가 컴퓨터와 모바일 기기 위에서 데이터를 기반으로 운영되기 때문에, 광고의 성과를 확인하기 용이하다는 특징을 가지고 있다. 온라인 광고의 성과는 온라인 광고의 실행 목적에 따라 다른 지표를 요구한다. 예를 들어 대표적인 온라인 광고 성과지표인 CPC(Cost per Click)는 중요한 지표이지만, CPC가 좋은 수치를 보인다고 구매가 함께 느는 것은 아니기 때문에⁶⁶⁾, 구매 전환이 중요한 광고주에게 CPC는 가장 중요한 성과지표는 아니다.

온라인 광고의 광고비 책정방식은 노출 수에 비례하여 광고비를 지불하지만, 일종의 정액제 형태인 CPM(Cost Per Mille) 광고방식과 클릭당 비용을 지불하는 종량제 형태의 CPC(Cost Per Click) 광고방식, 그리고 행위당 비용을 지불하는 또 다른 종량제 형태의 CPA(Cost Per Action) 광고방식으로 구분된다.⁶⁷⁾ CPM 광고방식과 CPC광고방식, CPA 광고방식에 대한 연구는 여러 방면으로 진행되어 왔다. CPM 광고방식과 CPC 광고방식의 우수성을 비교하는 연구를 통해 CPC 광고방식이 CPM 광고방식에 비해 우수함을 증명하였다.⁶⁸⁾ 그러나 온라인 광고의 실제 운영에 있어서 두 광고방식은 목적에 따라 다르게 활용되기 때문에 어느 한 쪽의 우수성은 목적이 달라지면 다른 결과가 도출될 수 있다는 문제가 있다. CPA 과금 체계에서 광고 클릭 후 사용자의 행위 즉, Conversion Action Data를 확보하는 메커니즘에 대한 진행

66) 이철, 이경전. (2008). Cost-Per-Action 광고 방법을 이용한 Conversion Action Data 메커니즘의 평가. *Information Systems Review*, 10(2), pp. 123-135.

67) 오창우. (2008). 인터넷 검색광고 요금체계의 특징 및 부정클릭 유형에 관한 연구. 『광고학연구』, 19(4), pp. 7-27.

68) 김도연, 임규진, 이대철. (2011). 키워드 검색 광고 운영 DB 데이터 분석을 통한 CPM 와 CPC 방식의 광고효과 연구. 『한국전자거래학회지』, 16(4), pp. 139-154.

한 연구도 있다.⁶⁹⁾ 그러나 이 연구는 탐색적 연구로서의 한계를 지닌다.

2) 온라인 광고에 적용된 인공지능에 대한 선행 연구

온라인 광고에 인공지능 기법을 도입하는 연구도 다양하게 진행되어왔다. 네이버 검색광고에 검색 키워드의 가격을 예측하기 위하여 인공지능 기법을 활용한 연구도 있으며,⁷⁰⁾ 해당 연구에서는 키워드 검색 결과를 크롤링하여 데이터를 수집하고, 수집된 데이터를 다양한 최적화 알고리즘을 적용하여 정확도를 높일 수 있는 방법을 제안하였다. 최적화 알고리즘의 비교 분석을 통해 예측 정확도가 높은 알고리즘을 제안하는 연구를 진행하고, 이를 통해 검색 키워드의 순위를 예측하고자 하였다. 이러한 연구는 검색 키워드의 노출 순위를 예측하는 데 도움을 주지만, 현재 광고비를 집행하고 있는 검색 키워드의 입찰 가격 변화에 따라 방문자 수가 얼마나 발생할 것인지를 예측해주는 것은 못한다. 검색 키워드의 노출 순위가 높을수록 클릭을 통한 방문자 수가 늘어날 확률도 높아지지만, 노출 순위를 최상위로 등록하기 위한 입찰 금액도 높아진다. 광고비 지출의 최적화를 고려하면 무조건 노출 순위만을 올리는 것은 바람직하지 않다.

클릭률 예측의 핵심 과제는 예측에 영향을 주는 특징 간 상호작용을 효과적으로 모델링하는 것이다. 이러한 목적을 위해 초기의 CTR 예측 모델들은 로지스틱 회귀⁷¹⁾, naive Bayes⁷²⁾, Follow the Regularized Leader(FTRL)⁷³⁾

69) 이침, 이경전. (2008). Cost-Per-Action 광고 방법을 이용한 Conversion Action Data 메커니즘의 평가. *Information Systems Review*, 10(2), pp. 123-135.

70) 지민준, 박현희. (2018). TensorFlow를 활용한 검색 키워드의 최적 순위 예측 알고리즘. 『한국통신학회논문지』, 43(8), pp. 1347-1356.

71) Richardson, M., Dominowska, E., & Ragno, R. (2007). Predicting clicks: estimating the click-through rate for new ads. In *Proceedings of the 16th international conference on World Wide Web*, pp. 521-530.

72) Hand, D. J., & Yu, K. (2001). Idiot's Bayes—not so stupid after all?. *International statistical review*, 69(3), pp. 385-398.

73) McMahan, H. B., Holt, G., Sculley, D., Young, M., Ebner, D., Grady, J., & Kubica, J. (2013). Ad click prediction: a view from the trenches. In *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 1222-1230.

같은 선형 모델에 기반하였다. 이 모델들은 간단하며, 확장하기 쉬운 장점이 있지만, 특징 간 상호 작용을 효과적으로 포착하는데 한계를 지녀 성능이 낮다는 단점이 있다.

최근 제안된 많은 CTR 예측 모델 구조에 중요한 영감을 준 연구는 Neural Network Language Model(NNLM)⁷⁴⁾로 대규모 희소 입력을 처리해야 하는 언어 모델링에서 저차원의 밀집 벡터로 매핑하는 임베딩 기법을 제안하여 차원의 저주를 극복할 수 있게 되었고 희소한 특성을 가지는 CTR 데이터 모델링에서 필수적으로 도입하는 계층으로 자리 잡게 되었다. Factorization Machine(FM)⁷⁵⁾은 가장 성공한 초기 CTR 모델 중 하나인데 이 방법 역시 임베딩 기법을 활용한다. 희소 데이터에 대한 임베딩 처리를 통해 생성된 특징 벡터들에 대해 벡터 간 내적을 수행하여 특징 간 상호작용을 모델링하는 방식이다. 이 연구는 구체적인 CTR 예측을 연구하는 것은 아니며, 단순히 모델링 방법만을 연구했다는 점에서 한계를 가진다. Field-Aware Factorization Machine(FFM)⁷⁶⁾은 각 특징을 연관된 필드의 여러 벡터와의 내적을 통해 특징 상호 작용의 범위를 더 정교화하여 예측 성능을 향상시킬 수 있었고 Criteo社와 Avazu社가 주최한 두 번의 CTR 예측 대회에서 우승을 차지하였다. 하지만, 이 방식은 특징들의 2차(second order) 상호작용만 모델링함에 따라 고차원 특징 상호작용에 대한 파악이 힘들어 성능상의 열화가 존재하는 한계를 지닌다.

심층신경망(deep neural network, DNN)은 컴퓨터 비전, 음성 인식, 자연어 처리 분야에서 큰 성공을 거두었다⁷⁷⁾⁷⁸⁾⁷⁹⁾⁸⁰⁾. 이 분야의 데이터들은 공간

74) Bengio, Y., Ducharme, R., Vincent, P., & Janvin, C. (2003). A neural probabilistic language model. *The journal of machine learning research*, 3, pp. 1137-1155.

75) Rendle, S. (2010). Factorization machines. In *2010 IEEE International conference on data mining*, pp. 995-1000.

76) Juan, Y., Lefortier, D., & Chapelle, O. (2017). Field-aware factorization machines in a real-world online advertising system. In *Proceedings of the 26th International Conference on World Wide Web Companion*, pp. 680-688.

77) 김준기, 조완현, 나명환, 전명희. (2019). 영상처리와 딥러닝 기법을 사용한 채소의 등급별 자동 분류시스템 개발. *Journal of The Korean Data Analysis Society*, 21(1), pp. 63-73.

78) 백광일, 강창완, 최승배, 김규곤. (2016). 신경망모형을 이용한 민간아파트 분양가격 보조지표에 관한 연구. *Journal of The Korean Data Analysis Society*, 18(3), pp. 1367-1376.

적 혹은 시간적으로 상관관계가 존재하는 특성을 지니는데, DNN은 데이터의 지역적 의존성과 밀도 있는 특징 공간의 표현을 파악하는데 탁월한 성능을 발휘하였다. 이러한 장점은 DNN을 CTR 예측에 활용하여 특징 간 고차원 상호작용을 파악하고자 하는 시도를 촉발시켰다. 대표적인 연구들로는 FM 방식에 기반한 연구들⁸¹⁾⁸²⁾⁸³⁾, 저차 및 고차 특징 상호작용을 동시에 학습하는 구조를 제안한 연구들⁸⁴⁾⁸⁵⁾⁸⁶⁾⁸⁷⁾⁸⁸⁾이 있다. 하지만, 이미지나 음성 데이터와는 달리 CTR 데이터의 유용한 특징 상호작용은 일부분에 지나지 않기 때문에 학습에 많은 매개 변수를 필요로 하는 일반 DNN은 효율적이지 않을 수 있다. 최근, 고급 신경망 구조인 Convolutional Neural Network(CNN)을 활용하여 희소하지만 중요한 특징 상호작용을 파악하려는 연구들이 제안되고 있다. CNN은 컨볼루션과 풀링 계층을 반복적으로 적층하고 각 컨볼루션 계

-
- 79) 정문성, 손방용. (2018). 컨볼루션 신경망을 기반으로 한 한글 음악 리뷰 감정 분류 모델 설계 및 분석. *Journal of The Korean Data Analysis Society*, 20(4), pp. 1863-1871.
- 80) 강창완, 최승배, 박현정. (2020). 시계열 예측을 위한 인공신경망의 입력노드 수 결정. *Journal of The Korean Data Analysis Society*, 22(3), pp. 1055-1065.
- 81) Zhang, W., Du, T., & Wang, J. (2016). Deep learning over multi-field categorical data. In *European conference on information retrieval*, pp. 45-57.
- 82) Qu, Y., Cai, H., Ren, K., Zhang, W., Yu, Y., Wen, Y., & Wang, J. (2016). Product-based neural networks for user response prediction. In *2016 IEEE 16th International Conference on Data Mining (ICDM)*, pp. 1149-1154.
- 83) Qu, Y., Fang, B., Zhang, W., Tang, R., Niu, M., Guo, H., & He, X. (2018). Product-based neural networks for user response prediction over multi-field categorical data. *ACM Transactions on Information Systems (TOIS)*, 37(1), pp. 1-35.
- 84) Cheng, H. T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., & Shah, H. (2016). Wide & deep learning for recommender systems. In *Proceedings of the 1st workshop on deep learning for recommender systems*, pp. 7-10.
- 85) Guo, H., Tang, R., Ye, Y., Li, Z., & He, X. (2017). DeepFM: a factorization-machine based neural network for CTR prediction.
- 86) Zhou, X., & Shi, Y. (2020). DeepFaFM: A Field-array Factorization Machine based Neural Network for CTR Prediction. In *2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, 1, pp. 2559-2563.
- 87) Wang, R., Fu, B., Fu, G., & Wang, M. (2017). Deep & cross network for ad click predictions. In *Proceedings of the ADKDD'17*, pp. 1-7.
- 88) Lian, J., Zhou, X., Zhang, F., Chen, Z., Xie, X., & Sun, G. (2018). xdeepfm: Combining explicit and implicit feature interactions for recommender systems. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp. 1754-1763.

층에서 필터를 통해 중요한 로컬 패턴을 찾는 방식으로, 학습에 사용되는 매개 변수의 가중치를 공유하여 필요한 매개 변수 수를 크게 줄일 수 있는 장점이 있어 이미지 인식 및 자연어 처리 분야에 많이 활용되는 방식이다. CNN을 활용하여 CTR 예측을 처음으로 수행한 모델은 Convolutional Click Prediction Model(CCPM)이다⁸⁹⁾. 하지만, CTR 데이터의 특징 정렬 순서는 이미지와 자연어에서처럼 연관 관계가 크게 없으므로 CCPM처럼 로컬 패턴을 찾아내는데 일반적인 CNN 구조를 사용하는 방식은 CTR 데이터의 글로벌 특징 정보를 파악하는데 제약이 있다. 이를 극복하기 위해 CNN을 통해 수집된 로컬 정보를 기반으로 DNN을 통해 전역 정보를 수집하여 학습하는 Feature Generation by Convolutional Neural Network(FGCNN)⁹⁰⁾도 제안되었다. FGCNN은 CTR 예측 작업을 feature generation과 deep classifier의 두 단계로 나누는 모델을 제안하였다. 특징 생성 기능은 CNN을 통해 새로운 특징을 생성하여 원래의 특징 공간을 확장하는 한편, deep classifier에서는 기존 제안된 CTR 모델을 채택하여 확장된 특징 공간을 기반으로 학습하고 예측을 수행한다. 본 논문에서는 CNN 예측 성능에 영향을 줄 수 있는 주요 하이퍼 파라미터인 임베딩과 풀링의 영향을 시각적으로 분석하여 CNN 기반의 예측 모델 설계 시 참고할 수 있는 정보를 제공하는 연구를 수행하였다. 하지만 최적의 특징 배열을 찾는 것은 특징의 수가 늘어남에 따라 배열의 조합이 기하급수적으로 증가하여 계산적으로 비효율적일 뿐만 아니라 데이터가 시간에 따라 지속적으로 변화하기 때문에 어느 시점에서 찾아낸 최적의 배열이 시간에 대해 최적임을 보장해 줄 수 없는 문제가 존재한다.⁹¹⁾

이러한 연구 외에도 국내 광고매체를 대상으로 연구가 이루어지기도 하였다. 비공개 입찰로 운영되는 ‘네이버’에서 특정 순위에 광고를 위치시키기 위한 입찰 금액을 예측하기 위한 모델 선정과 그 모델의 Feature Engineering과

89) Liu, Q., Yu, F., Wu, S., & Wang, L. (2015). A convolutional click prediction model. In *Proceedings of the 24th ACM international on conference on information and knowledge management*, pp. 1743–1746.

90) Liu, B., Tang, R., Chen, Y., Yu, J., Guo, H., & Zhang, Y. (2019). Feature generation by convolutional neural network for click-through rate prediction. In *The World Wide Web Conference*, pp. 1119–1129.

91) 김태석. (2020). CNN을 활용한 CTR 예측 시각화 분석. *Journal of The Korean Data Analysis Society (JKDAS)*, 22, pp. 2603–2614.

관련하여 연구도 있다. 해당 논문에서는 키워드 검색광고 입찰 가격 예측을 위해 다양한 feature들을 분석하여 키워드 별 광고 데이터에서 가격에 영향을 미치는 주요 feature들을 확인하기 위한 연구를 진행했다. 또한, 분석한 내용을 바탕으로 모델을 제작한 뒤, 실제 데이터를 통해 목표 순위로 이동하기 위해 필요한 비용을 예측하였다. 이를 통해 블라인드로 진행되는 입찰 방식에서, 원하는 입찰 순위에 도달하는데 걸리는 시간을 줄일 수 있는 방안을 제시하였으나, 목표 순위에 도달하기 위한 비용 예측에 실제 광고주의 매출 데이터를 결합하여, 추후 각 키워드의 광고 효과 분석에 관한 연구가 필요하다.⁹²⁾

이 외에도 키워드 광고에서 특정 순위에 광고를 위치시키기 위한 낙찰 금액을 예측하기 위한 모델링과 전처리 기법을 제안하고 다중 회귀 분석 모델로 학습할 것을 제안한 논문도 있다.⁹³⁾ 해당 논문은 예측을 위한 다양한 변수들을 제안하였으나 실제 데이터를 반영하여 예측을 진행하지는 않았다. 또한, LSTM과 GRU를 활용하여 키워드 목표 순위를 위한 최소 낙찰가를 예측한 연구도 있다.⁹⁴⁾ 해당 연구는 LSTM 모델과 GRU 모델의 성능을 비교하여 GRU 모델이 LSTM 모델에 비해 정밀도가 높다는 결과를 도출하였으나, 전체적인 성능이 높지 않고, 예측 값의 편중이 심한 문제가 있다.

이러한 선행 연구들은 성능 저하보다 더 중요한 문제를 가지고 있는데, 실험을 위한 데이터로 사용자 정보(성별, 직업 등), 컨텍스트 정보(상품 정보, 구매 이력 등)를 활용한다는 것이다. 검색광고의 경우 검색하는 사용자를 특정하여 사용자에게 따라 검색 결과를 다르게 보여주는 오디언스 타게팅이 가능하지만, 최근 개인정보보호를 강화하는 것이 세계적인 추세로 사용자의 개인정보 보호 정책이 강화되면서 개인정보 데이터는 온라인 광고에서 활용할 수 있는 데이터로 한정적인 데이터가 되었다. 이로 인해 정확한 오디언스 타게팅이 잘 되지 않으며, 앞으로는 더욱 어려워질 전망이다. 따라서 앞으로 검색광고는 불특정 다수가 검색을 통해 노출되는 검색 키워드를 클릭하는 과정으로

92) 김도형, 김태성, 박준규. (2017). 머신러닝을 이용한 키워드 광고 입찰가격 예측 모델에 관한 연구. 『한국정보과학회 학술발표논문집』, pp. 1910-1913.

93) 김도형, 김태성, 박준규. (2017). 머신러닝을 이용한 키워드 광고 입찰가격 예측 모델에 관한 연구. 『한국정보과학회 학술발표논문집』, pp. 1910-1913.

94) 장규리. (2020). 딥러닝을 이용한 키워드 목표 순위를 위한 최소 낙찰가 예측 / Prediction for Suggesting Minimum Bidding Price of Keyword Using Deep Learning. 『경상대학교 대학원』.

인지하여야 한다. 검색광고의 성과 예측에 관한 연구도 기존과 같이 사용자 정보나 컨텍스트 정보를 활용하지 않는 새로운 연구가 필요하다.

제 3 절 요약 및 시사점

본 논문에서 검토한 인공지능 관련 기술은 [표 2-1]과 같다.

[표 2-1] 인공지능 관련 기술 요약

분류		기술
인공지능 모델링		• ANN/DNN • CNN • RNN/LSTM/GRU
활성화 함수		• 시그모이드 • 하이퍼볼릭 탄젠트 • ReLU • leaky ReLU • ELU • 소프트맥스
손실함수		• 평균제곱오차 • 크로스 엔트로피
학습 파라미터 최적화	• 경사하강법	• 일괄 경사하강법 • 확률적 경사하강법 • 소규모 일괄 경사하강법
	• 모멘텀 • AdaGrad/ADADELTA • RMSProp • Adam	
기타 학습기법	• 과적합 방지	• 모델 복잡도 줄이기 • 데이터 양 늘리기 • 빠른 중지 • 가중치 감소 • Dropout
	• 학습률 감소 • 하이퍼 파라미터 최적화	

본 논문에서는 광고매체의 특징과 실험을 위해 확보한 데이터의 특성을 고려하여 인공지능 관련 기술을 조합하여 실험을 진행하였으며, 인공지능 모델링은 DNN을 활용하였고, 활성화 함수는 시그모이드 함수와 ReLU 함수를 활용하였다. 손실함수는 평균제곱오차 함수와 크로스엔트로피 함수를 활용하

였다. 학습 파라미터 최적화를 위하여 Adam을 활용하였고, 과적합 방지를 위하여 모델 복잡도 줄이기, 빠른 중지, Dropout 기법을 활용하였다. 학습률을 다르게 설정하여 최적의 학습률을 찾기 위한 방법도 실행하였다. 일부 활용하지 않은 인공지능 관련 기술은 추가 연구에 활용하려는 계획을 가지고 있다.

다양한 온라인 광고 성과지표에 대한 선행 연구가 있으며, 대부분 탐색적 연구이거나 실제로 온라인 광고 운영을 통한 실험을 진행한 연구는 아니다. 연구를 위한 온라인 광고 운영의 실 데이터는 확보가 어려우며, 연구를 위해 별도로 온라인 광고를 운영하는 것은 비용의 문제나 광고주에게는 기회 손실의 문제가 발생하기 때문에 실험이 어려운 것이 현실이다. 본 연구에서는 광고주들의 동의를 얻어 실제로 온라인 광고를 운영하며 연구를 진행한 점에서 의미가 있다고 할 수 있다.


온라인 광고에 적용된 인공지능에 대한 선행 연구들 역시 많이 진행되어 왔다. 연구에 따라 제안한 인공지능 모델의 예측 정확도는 매우 높아 실제 산업에 적용하는 것도 가능한 수준이기도 하다. 그러나 대부분의 연구가 개인정보를 활용하기 때문에 최근 강화된 개인정보 정책에 의해 실제 산업에 반영되기는 어려운 것이 현실이다. 본 연구에서는 이러한 문제를 극복하기 위하여 개인정보를 활용하지 않고 인공지능을 포함하여 여러 가지 방법으로 광고 성과를 예측하는 실험을 한다는 점에서 의미가 있다고 할 수 있다.

제 3 장 온라인 광고 자동운영 시스템 설계

제 1 절 온라인 광고 운영을 위한 고려 사항

1) 온라인 광고의 구조

온라인 광고는 온라인 광고 운영의 목적에 따라 운영의 다양성을 확보하기 위해 계층적인 구조를 갖는다. 이 구조의 형태와 단계별 용어는 광고매체별로 차이는 있으나 기본적인 컨셉은 동일하다.



[그림 3-1] 네이버와 페이스북의 광고 계층 구조

예를 들어 국내 검색 광고 포털인 네이버의 경우, 검색 광고는 [그림 3-1]과 같이 광고 계정 - 캠페인 - 광고 그룹 - 키워드의 단계로 계층화 되어있고, 페이스북의 경우, 광고 계정 - 캠페인 - 광고 그룹 - 광고의 단계로 계층화 되어있다.



[그림 3-2] 네이버 광고 관리자 화면에서 본 계층 구조

[그림 3-2]는 네이버의 광고 관리자 화면을 통해 확인할 수 있는 광고 계층 구조이다.⁹⁵⁾ 네이버의 경우 계정은 광고주의 ID를 의미한다. 광고주 ID 하나당 키워드는 최대 10만 개를 등록할 수 있어, 키워드가 늘어나면 계정을 추가해야 한다. 이러한 계층 구조는 광고 소재인 키워드가 많을 경우 관리의 용이성을 제공한다. 두 번째 계층 구조인 캠페인은 목적에 따라 나뉘게 되는데, 네이버의 경우 목적에 따라 사전에 분류된 광고 상품 유형을 선택하도록 되어있다. 목적이 다른 광고를 진행하기 위해서 복수의 캠페인을 만들 수 있도록 되어있다. 예를 들어 쇼핑몰 유입을 위한 캠페인, 블로그 유입을 위한 캠페인, 상품 카테고리별 캠페인, 광고 예산을 크게 사용하는 캠페인, 광고 예산을 작게 사용하는 캠페인, 상시 운영하는 광고를 위한 캠페인, 명절 등 특정 기간만 운영하는 캠페인 등 다양한 목적으로 캠페인을 생성하여 운영할

95) 네이버 검색 광고 센터. <https://searchad.naver.com/>.

1 캠페인 만들기

2 광고그룹 만들기

3 광고만들기 (키워드/소재)

1 새 캠페인 만들기

[등록 캠페인 불러오기](#)

캠페인은 일련의 마케팅 활동을 목적(광고의 유형, 기간, 예산) 기준으로 묶어서 관리하는 단위입니다.
광고 목적에 따라 광고가 노출되는 위치를 확인한 다음 캠페인 유형을 선택해 캠페인을 생성하세요.

[자세히 보기](#)

캠페인 유형 ①

광고 목적에 따라 캠페인 유형을 선택하세요.

[캠페인 유형 상세 설명 보기](#)

☒
파워링크 유형
 네이버 통합검색 및 네이버 외부의 다양한 영역에 텍스트와 사이트 링크를 노출하는 기본형 검색광고

☐
쇼핑검색 유형
 네이버 쇼핑의 검색 결과 화면 등에 상품 이미지와 쇼핑 콘텐츠를 노출하는 판매 유도형 검색광고

☐
파워컨텐츠 유형
 블로그, 포스트, 카페 콘텐츠를 네이버 통합검색 결과 및 콘텐츠 지면에 노출하는 정보 제공형 검색광고

☐
브랜드검색 유형
 상호 등 브랜드 키워드의 네이버 통합검색 결과에 다양한 광고 콘텐츠를 함께 노출하는 검색광고

☐
플레이스 유형
 네이버 스마트플레이스의 업체 정보를 네이버 통합검색 결과 및 콘텐츠 지면에 노출하는 지역 정보 광고

누구나 쉽게 시작하는 디스플레이 광고상용

* 실시간 입찰로 네이버 프리미엄 지면에 노출하는 [성격형 디스플레이광고 알아보기](#)

구 광고관리시스템에서 등록 가능한 상품

* 업체 이미지 홍보에 적합한 [클릭초이스플러스 알아보기](#)

* 파편 상품이미지와 가격을 바로 보여줄 수 있는 [클릭초이스상품광고 알아보기](#)

캠페인 이름 ①

파워링크#7

6/30

하루예산 ①

하루 동안 이 캠페인에서 지출할 의사가 있는 최대 비용을 설정합니다.

☒
 원
 70원에서 1,000,000,000원까지 입력 가능(10원 단위 입력)

하루예산을 입력하세요.

☐ 예산을 균등배분 합니다.

예산을 균등배분한 경우, 하루예산에 맞춰 시스템이 광고 노출을 조절합니다. [도움말](#)

☐ 제한없음

① 경우에 따라 예산을 초과하는 금액이 과금될 수 있습니다. [도움말](#)

캠페인 단위의 광고비 설정

✓ 고급옵션 고급옵션에서는 캠페인의 기간을 설정/수정할 수 있습니다.

기간 ①

해당 캠페인의 광고노출 기간을 설정합니다.

☒ 오늘부터 종료일 없이 계속노출

☐ 시작 및 종료 날짜 설정

저장하고 계속하기

취소

– 59 –

다음 계층인 광고 그룹은 유사한 광고 소재를 묶어 하나의 그룹으로 지정하는 것인데, 네이버의 경우 광고 노출 전략 단위의 개념으로 예를 들어 커피를 파는 쇼핑몰의 광고를 진행한다고 가정할 때 “커피”와 관련된 키워드들을 모아 관리하는 그룹 하나, “원두”와 관련된 키워드들을 모아 관리하는 그룹 하나, 이렇게 그룹들을 생성하고 관리하는 방식이다. 광고가 노출될 때 함께 노출되는 웹페이지의 주소(URL)를 함께 등록하게 되어있다. 이 두 그룹의 키워드가 노출될 때 각각 다른 웹페이지를 노출할 수 있고, 동일한 웹페이지를 노출할 수도 있다. 따라서 그룹의 분류는 노출되는 웹페이지 구분으로 나누어도 되고, 광고 소재의 유사성으로 나누어도 된다. 실제로 광고 소재를 클릭했을 때 이동하게 되는 최종 도착지 주소는 광고 그룹의 주소와 달라도 된다.

2) 온라인 광고 운영의 어려움

높은 성과를 추구하며 온라인 광고를 운영하기 위해서는 진행하고 있는 광고의 성과를 파악하여, 그 성과에 맞는 전략을 수립하고 운영에 반영하는 것이 필요하다. 그러나 현실적으로는 다음의 문제들로 인하여 광고 성과를 향상시키는 데 한계가 존재한다.

가) 광고 성과 단위

광고를 운영할 때 광고 목적에 맞게 광고 캠페인을 설정하게 되는데, 하나의 캠페인에는 복수의 광고 그룹을 설정하고, 하나의 광고 그룹 안에는 복수의 광고 소재가 들어간다. 일반적으로 광고비는 광고 캠페인별로도 설정할 수 있고, 그룹별로도 설정할 수 있으며, 가장 세부 요소인 광고 소재별로 설정할 수 있다. 광고매체와 광고 종류에 따라 다르지만, 실제로 광고를 운영할 때에는 광고 소재별로 광고비를 설정하기에는 너무 많은 작업이 필요하여 [그림 3-3]처럼 광고 캠페인별로 설정하거나 [그림 3-4]처럼 광고 그룹별로 광고비를 설정할 수 있도록 되어 있다. 이때 하위 계층의 광고비, 즉, 광고 그

룹의 광고비를 설정할 경우 해당 광고 그룹에 들어있는 광고 소재들의 개별 광고비는 광고매체에서 알아서 배정하여 소진한다.

2 캠페인 만들기

2 광고그룹 만들기

3 광고만들기 (키워드/소재)

2 새 광고그룹 만들기

광고 그룹은 광고의 운영과 효과 분석, 입찰을 진행하는 단위입니다.
광고 그룹을 기준으로 누구에게(타겟팅) 무엇을 보여 줄 것인가(소재)를 확인한 다음 광고 그룹을 생성하세요.

자세히 보기

광고그룹 이름: 캠페인 #1_광고그룹#1

URL ①: URL을 선택하세요. ▾

기본 입찰가 ①: ☒ 직접 설정 원

☐ 자동입찰 설정(beta)

하루예산 ②: 하루 동안 이 광고그룹에서 지불할 의사가 있는 최대 비용을 설정합니다.
☒ 0 원 70원에서 1,000,000,000원까지 입력 가능(10원 단위 입력)
하루예산을 입력하세요.

☐ 제한없음

① 경우에 따라 예산을 초과하는 금액이 과금될 수 있습니다. 도움말

그룹 단위의 광고비 설정

> 고급옵션: 광고를 노출할 매체, 지역, 일정을 설정할 수 있고, 콘텐츠 매체 전용 입찰가, PC/모바일 입찰가 가중치를 설정할 수 있습니다.

이전 단계 | **지정하고 계속하기** | 취소

[그림 3-8] 네이버의 광고비 설정(그룹 광고비 설정)

광고매체에 따라 차이는 있으나 일반적으로 광고매체에서는 광고 전체의 성과와 광고비를 설정한 단계까지의 성과를 제공한다. 예를 들어 캠페인 단위로 광고비를 설정한 경우 캠페인 단위의 성과는 확인이 가능하지만 그룹이나 광고 소재의 성과는 확인이 어렵다. 따라서 광고주나 마케터가 광고 성과를 바탕으로 광고 운영 전략 수립을 할 때 광고 성과가 제공되는 단계의 하위 단계까지 고려하기 어렵다. 광고 캠페인 또는 광고 그룹 내에는 여러 가지 광고 소재가 활용되고 있기 때문에 각 개별 광고 소재의 광고 성과를 판단하여 광고 소재의 교체나 광고 소재별 광고비 설정이 가능하다면 더욱 높은 효율의 광고 운영이 가능해진다. 이를 위해서는 수많은 광고 소재별로 광고비를 각각 설정을 해야 하는 어려움이 있다.

나) 광고 운영 전략 수립의 근거

광고 운영 전략 수립에 있어서 더 큰 문제는 광고 성과를 파악한 후 광고 운영을 어떻게 하는 것이 향후 광고 성과를 높이는 방법인가를 결정하는 것이 광고주나 마케터의 경험이나 감을 통해서 진행된다는 점이다.

마케터는 광고 운영 전략을 수립하는 근거로 광고 성과를 활용한다. 광고 성과는 대부분 광고매체에서 제공하는 데이터를 기반으로 한다. 광고매체에서 제공하는 광고 성과 데이터로 광고 성과를 높이는 전략을 수립하는 데에는 크게 3가지 문제가 있다.

(1) 광고 성과 제공 단위

앞에서 서술한 것처럼 광고매체에서 제공하는 광고 성과 데이터는 광고비를 집행하는 단계까지의 성과 데이터이다. 광고의 기본 단위 요소인 광고 소재별 성과 데이터는 제공하지 않을 확률이 높다. 광고 캠페인이나 광고 그룹 단위로 광고 운영 전략을 세울 수 있으나, 광고 소재 단위의 광고 운영 전략을 세우는 것이 세부적인 전략으로 더 높은 성과를 기대할 수 있다.

(2) 제한적인 광고 성과 데이터

전세계적으로 개인정보 보호 정책이 강화되어 특정 고객군을 타겟으로 하여 광고를 운영하는 것이 어려워졌다. 뿐만 아니라, 광고매체에서 제공하는 광고 성과 데이터도 축소되었으며 제한적이 되었다. 페이스북의 경우 애플의 iOS 14.5 버전 이후 강화된 개인정보보호 정책 이후 큰 변화가 있었는데, 이전 제공하던 광고 성과 데이터의 종류가 110 가지 이상이었으나, 이후부터는 8가지로 축소되었으며, 실시간으로 제공하던 광고 성과 데이터를 [그림 3-5]와 같이 길게는 72시간 지연된 데이터를 제공하고 있어 실시간으로 광고 성과를 확인하며 운영 전략을 세워 운영하는 것이 어려워졌다.⁹⁶⁾

96) 페이스북 비즈니스 고객센터. Apple iOS 14 릴리스용 보고서 업데이트.
<https://www.facebook.com/business/help/584603712214119?id=428636648170202>.

Apple iOS 14 릴리스용 보고서 업데이트

조회 2,781회

Apple에서 새 iOS 14 정책 요구 사항을 적용함에 따라 Facebook의 iOS 14 앱 설치 캠페인 성과 측정이 제한될 수 있습니다. 유사한 제한 사항이 일부 웹 전환 이벤트 측정에도 적용됩니다. Facebook은 Facebook상의 마케팅 성과를 평가할 때 비즈니스에 최적의 측정 경험을 제공하기 위한 업데이트 작업을 진행하고 있습니다. Apple에서 기술 사양에 대한 가이드나 업데이트를 제공하면 이러한 제품 업데이트를 다시 논의할 수 있습니다. 앱 및 웹 전환 보고서에 미치는 영향에 관한 자세한 내용은 아래를 참조하세요.

• 앱의 보고서 업데이트

iOS 14 앱 설치 캠페인에서는 모바일 앱 설치 및 기타 앱 이벤트에 대한 보고 시 Apple SKAdNetwork API에서 제공하는 데이터를 사용해야 합니다. 다음 사항은 Apple의 SKAdNetwork API에서 제공하는 데이터의 주요 영향 및 예상되는 제한 사항을 이해하는 데 도움이 됩니다. 이러한 지표와 Facebook에서 직접 보고하는 다른 지표를 비교할 때 주의하시기 바랍니다.

- **보고 지연:** SKAdNetwork API에서는 실시간 보고가 지원되지 않기 때문에 데이터 수집이 최대 3일까지 지연될 수 있습니다. 결과는 실제로 발생한 시점이 아니라 SKAdNetwork API에서 Facebook으로 데이터가 보고된 시점을 기준으로 하여 보고됩니다.
- **추산 결과:** SKAdNetwork API는 캠페인 수준에서 집계된 결과를 Facebook에 보고합니다. 단일 광고 또는 단일 광고 세트로 구성된 캠페인이 아니라면 광고 세트 및 광고 수준의 결과를 집계하는 데 통계 모델링이 사용될 수 있습니다. 하나의 광고에 여러 개의 크리에이티브가 포함된 경우 크리에이티브 수준의 보고서는 지원되지 않습니다.
- **분석 데이터 및 고유 지표가 지원되지 않음:** SKAdNetwork API 데이터는 집계되는 형태이므로 전환 관련 게재, 행동 및 다이내믹 크리에이티브 요소 분석 데이터(예: 연령, 성별, 지역, 노출 위치)는 지원되지 않습니다. 노출, 링크 클릭, 동영상 조회와 같은 온라인 행동의 분석 데이터는 큰 영향을 받지 않을 것으로 예상됩니다. 이는 또한 오프사이트 전환의 고유 지표에도 영향을 미치게 됩니다. 분석 데이터와 마찬가지로 시그널이 제한되고 반환되는 데이터가 집계되는 형태이기 때문에 지표를 고유 하위 세트로 분할하는 것은 현재 지원되지 않습니다. 분석 데이터 및 고유 지표 모두 2021년 4월 27일 이전의 과거 데이터는 계속 사용할 수 있습니다.
- **현재 기여 기간이 지원되지 않음:** SKAdNetwork API에서는 1일, 7일, 28일 클릭 기여 기간 또는 조회 기여 기간을 지원하지 않습니다. 결과는 SKAdNetwork API의 기여 기간에 따라 보고됩니다. 기여에 관한 최근 변경 사항에 대한 정보는 이 도움말을 참조하세요.

[그림 3-9] 개인정보보호정책으로 인한 페이스북 성과 보고 지연 안내


(3) 광고주 사이트 상태 미반영

광고주의 사이트 상태가 미반영 되어 발생하는 문제는 주로 광고주가 쇼핑몰이며 상품 판매를 목적으로 광고를 진행하는 경우 발생하는 문제이다. 광고 소재로 사용되어 광고가 진행되고 있는 상품이 품질이나 링크 오류 등으로 광고비는 소진되었으나 고객의 이탈로 인해 성과 데이터가 오염되는 경우가 발생한다. 예를 들어 평균적으로 100이라는 광고비를 소진하고, 500이라는 매출을 올리는 광고 소재가 있다고 가정할 때, 해당 광고 소재의 상품이 품질되어 100이라는 광고비를 소진하고, 200이라는 매출을 올리는 결과가 나왔을 때, 이는 광고 성과가 낮아진 것이 아니라 광고주 사이트 내 상품 관리의 문제가 발생한 것이다. 그러나 광고주 사이트의 상태를 알 수 없는 마케터는 이 성과 데이터만을 참고하여 광고 운영 전략을 수립하기 때문에 오류가 발생하게 된다. 이처럼 광고주의 사이트 상태를 실시간으로 체크하고, 이를 광고에 반영하지 못하는 것은 광고 전략 수립뿐만 아니라 운영에 있어서도 광고 성과에 악영향을 미치고, 광고주의 광고비를 낭비하는 결과를 가져온다. 이러한 문제를 보완하기 위하여 광고 성과를 소재 단위까지 파악하고, 개인정보 보호 정책에 영향을 받지 않는 성과 데이터를 수집해야 하며, 광고주 사이트의 상태를 실시간으로 파악하고 반영할 수 있어야 높은 성과를 추구할 수 있는 광고 전략을 수립하고 운영할 수 있다. 그러나 현실적으로는 광고 소재 단위의 광고 성과를 파악하기 어렵고, 광고매체에서는 너무 적은 종류의 데이터를 비실시간으로 제공받고 있으며, 광고주 사이트의 상태를 알지 못하는 상태에서 광고 전략을 수립하고 있다.

다) 너무 많은 광고 소재

브랜드 광고나 단일상품/서비스를 제공하는 광고주의 경우 광고 소재가 제한적이다. 그러나 쇼핑몰과 같은 다품종의 상품을 취급하고, 제품의 수명주기가 짧은 경우 광고 소재의 수가 많으며, 소재의 변경에 대한 요구도 많아지게 된다. 광고 상품 하나로 다수의 광고 소재를 생성하는 경우도 많아 하나의 광고주가 운영하는 광고 소재가 수십만 개에 이르는 경우도 있다. 하나의 상품이 다수의

캠페인에 각각 광고 소재로 등록될 수도 있고, 키워드 검색 광고의 경우 다양한 키워드의 조합으로 복수의 광고 소재가 등록되기도 한다. [그림 3-6]에서 보여지는 것처럼 하나의 광고 그룹 내 약 1,400개의 광고가 등록되어 있고, 하나의 광고는 40여 개의 광고 소재들이 모인 카탈로그 형태로 제공되기도 한다.⁹⁷⁾



[그림 3-10] 페이스북 광고 및 광고 소재 세트

광고 소재가 많은 경우 소재별 광고 성과를 분석하는 것도 어려우며, 광고 소재 단위로 광고 운영을 하는 것은 인력으로는 불가능하다. 그렇기 때문에 광고 계층을 활용하여 캠페인 단위의 운영, 광고 그룹 단위의 운영, 또는 일부 고성과 광고 소재만 집중적으로 운영하고, 나머지는 일괄 조정과 같은 방식의 운영이 일반적인 온라인 운영 방법이다. 이러한 문제를 해결하기 위해 광고 성과 데이터의 수집, 분석, 운영의 자동화가 필요하다. 운영의 자동화 중 일부는 인공지능을 활용하여 과거 광고 운영작업과 그에 따른 광고 성과를 기초 데이터로 하여 훈련하고 테스트하여 신뢰성이 일정 수준 보장된 인공지능 모델을 만들고, 광고 소재 단위로 광고 성과에 차이가 발생하거나 광고 성과가 너무 낮게 유지되는 경우 광고 운영 방법을 실시간으로 변경하고자 한다. 이때, 광고 운영 방법은 광고비 증액, 광고비 감액, 광고 끄기, 광고 켜기, 현재 상태 유지의 5가지로 이루어진다. 인공


97) 페이스북 비즈니스 관리자. <https://business.facebook.com/>.

지능을 활용하는 경우 현재 광고 성과를 확인하고, 광고 운영 방법에 따라 광고 성과가 상승할 확률을 도출하고, 그중 가장 높은 확률을 기대할 수 있는 운영 방법에 따라 광고 운영을 실행한다. 이후 해당 운영 방법과 그에 따른 운영 결과도 다시 인공지능 모델의 훈련 값으로 활용하여 정확도를 높인다.

본 연구에서는 이러한 시스템을 설계하고 실제로 온라인 광고가 운영된 데이터를 활용하여 성능을 테스트하였다.

제 2 절 온라인 광고 자동운영 시스템 아키텍처 설계

1) 온라인 광고 자동운영 시스템 설계



[그림 3-11] 온라인 광고 자동운영 시스템 다이어그램

[그림 3-11]은 온라인 광고 자동운영 시스템의 전체 모듈 다이어그램이다. 온라인 광고 자동운영 시스템은 크게 데이터 수집 모듈, 분석 모듈, 사용자 접속 모듈, 예측 모듈, 운영 모듈로 구성된다. 데이터 수집 모듈은 다시 광고주 사이트로부터 로그 데이터를 수집하는 모듈과 광고매체로부터 광고 성과 데이터를 수집하는 모듈로 분류된다.

사용자가 광고주의 사이트에 직접 접속하는 경우 사이트 데이터 수집 모듈을 통해 해당 사용자의 여정 로그가 수집되고, 분석 모듈을 통해 변환되어 데이터베이스에 저장된다. 사용자가 광고매체에 접속한 후 광고주의 광고를 클릭하여 광고주 사이트에 접속하는 경우 광고매체에서 제공하는 광고 성과 데이터를 광고 성과 데이터 수집 모듈에서 수집하여 데이터베이스에 저장하고, 사이트 데이터 수집 모듈에서도 해당 사용자의 여정 로그를 수집하여 분

석 모듈을 통해 변환된 데이터가 데이터베이스에 저장된다. 광고주는 사용자 접속 모듈에 접속하여 광고 성과를 확인할 수 있다. 광고주는 운영 모듈을 통해 광고를 수동으로 운영할 수 있으며, 예측 모듈이 광고주가 수동으로 운영할 때 전략 수립에 도움이 되는 성과 예측 데이터를 제공한다. 광고 자동운영은 사전 설정된 조건이나 예측 모듈의 데이터를 바탕으로 광고 운영을 자동으로 수행한다. 온라인 광고 자동운영 시스템은 크게 성과분석 시스템, 자동운영 시스템, 성과 예측 시스템으로 나뉘며 기능 모듈은 각 시스템에 중복되어 활용된다.

2) 온라인 광고 성과분석 시스템 설계

가) 데이터 수집 모듈

```
<!-- Facebook Pixel Code -->
<script>
  !function(f,b,e,v,n,t,s)
  {if(f.fbq)return;n=f.fbq=function(){n.callMethod?
  n.callMethod.apply(n,arguments):n.queue.push(arguments)};
  if(!f._fbq)f._fbq=n;n.push=n;n.loaded=!0;n.version='2.0';
  n.queue=[];t=b.createElement(e);t.async=!0;
  t.src=v;s=b.getElementsByTagName(e)[0];
  s.parentNode.insertBefore(t,s)}(window, document,'script',
  'https://connect.facebook.net/en_US/fbevents.js');
  fbq('init', '{your-pixel-id-goes-here}');
  fbq('track', 'PageView');
</script>
<noscript>
  
</noscript>
<!-- End Facebook Pixel Code -->
```


[그림 3-12] 페이스북 스크립트 픽셀 베이스 코드

온라인 광고 성과분석 시스템은 사이트 데이터 수집 모듈과 광고 성과 데이터 수집 모듈, 분석 모듈의 일부 기능과 사용자 접속 모듈을 활용한다. 광고 성과 데이터 수집 모듈은 광고매체에서 공식적인 API가 제공되는 경우 API 통신을 통해 데이터를 수집하며, API가 없는 광고매체의 경우 웹 크롤링(crawling)을 통해 데이터를 수집한다. 사이트 데이터 수집 모듈은 경우 광고

주의 웹페이지에 스크립트를 설치하여 필요한 데이터를 수집한다. 이렇게 데이터를 수집하기 위해 광고주의 웹페이지에 스크립트를 설치하는 것은 광고 매체에서도 진행되는 방식으로 보편적으로 사용되는 방식이다. 예를 들어 페이스북의 경우 [그림 3-12]과 같이 광고 성과를 파악하기 위하여 픽셀(pixel)이라는 명칭의 스크립트를 설치⁹⁸⁾하며, 해당 스크립트는 광고를 통해 유입된 고객이 광고주 사이트에서 이탈할 때까지 여정에 있어서 유의미한 행동에 대한 데이터를 수집한다. 본 연구를 위해 설치한 스크립트는 광고를 통해 유입되지 않은 고객의 행동 데이터도 수집하며, 판매하는 상품/서비스의 정보와 변경 내역까지 수집한다는 점이 다르다. 이때 개인정보 보호를 위하여 고객을 특정할 수 있는 정보는 수집하지 않는다.



[그림 3-13] 기존 광고 성과분석 시스템 구조



[그림 3-14] 본 연구에서 제안하는 광고 성과분석 시스템 구조

이러한 방식은 기존 광고 성과분석 시스템과 큰 차이가 있다. [그림 3-9]와 같이 기존 광고 성과분석시스템이 광고매체의 데이터만을 수집하여 광고 매체에 의존적이며, 제공할 수 있는 데이터가 한정적인 것에 비해 [그림 3-14]과 같이 광고주 사이트의 로그까지 수집하여 분석하고, 광고매체에서 제공하는 광고 성과 데이터와 조합하기 때문에 광고매체 데이터에 의존적이지 않


98) facebook, facebook Pixel.

<https://developers.facebook.com/docs/facebook-pixel/get-started/>.

으며, 다양한 조건을 부여하여 커스터마이징 된 성과 데이터를 제공할 수 있게 된다.

나) 데이터 가공 모듈


수집된 데이터는 분석시스템을 통해 재가공 되고, 광고주 사이트의 데이터와 광고매체의 데이터를 조합하며, 마케터가 활용할 수 있는 기본 성과지표 단위로 모듈화된다. 모듈화된 데이터는 데이터 메트릭이라 부르며 메트릭을 조합하고 조건을 부여하여 복잡한 광고 성과를 분석할 수 있게 된다. 이를 좀 더 상세하게 설명하기 위한 [그림 3-11]은 본 연구에서 제안하고자 하는 분석시스템의 계층 구조이다.



[그림 3-15] 분석시스템의 계층 구조

Raw 데이터 레이어에서는 광고매체와 고객사 사이트에서 데이터를 수집하는 단계이다. 메트릭 레이어에서는 수집된 데이터를 재가공하여 마케터들이

주로 활용하는 기본 성과지표 형태로 가공한다. 데이터 소스 레이어에서는 기본 성과지표를 광고의 계층에 맞게 조합이나 분해를 하고, 마케터에게 유용한 성과지표를 만들기 위해 조건을 부여하거나 성과지표들을 조합해 새로운 성과지표를 만들기도 한다. 컴포넌트 레이어에서는 조합된 데이터를 텍스트 형태나 그래프 형태, 표 형태 등으로 시각화하는 작업을 한다. 위젯 레이어에서는 생성된 컴포넌트들을 규격에 맞게 크기를 재조정하며, 페이지 레이어에서는 이러한 위젯들을 배치하여 마케터의 화면을 구성한다. 워크스페이스 레이어는 복수의 페이지 레이어를 담고 있는 공간을 만든다.



[그림 3-16] 사용자 UI 컨셉


[그림 3-16]는 각 레이어에서 생성된 데이터 및 형태를 배치한 사용자 화면의 컨셉 예시이다.

3) 다양한 온라인 광고 자동운영 방법과 알고리즘 설계

자동운영의 실행, 즉, 광고 소재의 등록이나 광고비 설정 등 운영에 필요한 작업은 광고매체에서 제공하는 API를 활용하여 구현한다. 시스템 설계에

서 중요한 것은 어떠한 판단 기준으로 광고 소재를 선정하고, 광고비를 설정하는가 하는 알고리즘에 대한 부분이다. 온라인 광고 자동운영 시스템은 광고주나 마케터의 수기 운영을 거치지 않고 광고 예산과 목적만 설정하면 높은 광고 성과를 추구하며 전 과정을 자동으로 운영하는 것을 궁극적인 목표로 한다. 각 광고매체 별로 광고 성과를 높일 수 있는 방법들을 적용하여 자동으로 운영하는 기능에서부터 한정된 예산으로 여러 광고매체에 광고비를 분배하는 기능까지 완성하는 것을 목표로 한다. 그러나 그 단계까지 진행하기 위해서는 많은 연구가 필요하며, 본 연구에서는 그중 페이스북 디스플레이 광고 중 카탈로그 광고와 네이버 검색 광고에 대한 자동운영의 일부를 설계하고 구현하는 것을 목표로 한다.

가) 페이스북 카탈로그 광고 자동운영 시스템



[그림 3-17] 페이스북 카탈로그 광고

페이스북의 다양한 광고 중 카탈로그 광고⁹⁹⁾는 [그림 3-13]과 같이 세로로 스크롤하는 사용자의 피드 화면에 노출되어 가로로 스크롤 하면서 광고 소재를 확인할 수 있는 형태의 광고이다.¹⁰⁰⁾ 좌우로 슬라이드 할 때 노출되는

99) Facebook. (2015). Drive Conversions on Every Device with Dynamic Product Ads. *Facebook for Business*.

모든 광고 소재(creative)들의 묶음을 광고 소재 세트라고 한다. 광고 소재 세트 내 하나의 광고 소재는 상품의 이미지, 광고 문구, 클릭했을 때 접속되는 상품 상세 페이지 주소(URL)로 이루어져 있다. 광고 소재 세트는 사전에 광고주나 마케터가 광고로 노출하고자 하는 상품들을 등록하는 것으로 구성된다. 사용자가 뉴스피드를 보는 동안 동일한 광고주의 카탈로그 광고가 여러 번 노출될 수 있다. 이때 광고 소재 세트에 등록된 광고 소재의 수가 많은 경우 페이스북의 광고 소재 노출 알고리즘에 의거하여 소재들을 선별하여 보여주게 되지만, 등록된 광고 소재의 수가 적으면 매번 중복되는 광고 소재가 노출된다. 이를 방지하기 위하여 광고 소재 세트에 쇼핑몰 내 모든 상품을 등록하는 경우도 있으나, 쇼핑몰에서 판매하는 상품의 수가 많거나 매일 새로운 상품이 등록되는 경우 마케터가 직접 광고 소재를 업데이트 하는 것이 용이하지 않은 문제가 있다. 페이스북은 여러 개의 광고 소재 세트를 등록할 수 있기 때문에 마케터는 다양한 상품들로 구성된 광고 소재 세트를 여러 개 등록하는 방법을 활용한다. 이때 각 광고 소재 세트를 어떤 상품들로 구성할 것인가를 결정해야 한다. 일반적으로는 쇼핑몰 내에서 판매가 많이 이루어지는 인기 상품, 즉, 베스트 상품으로 광고 소재 세트를 구성한다. 신상품 역시 광고 소재 세트에 많이 사용된다. 상품이 많고, 고객층도 다양한 경우, 고객 연령별, 지역별, 성별로 인기 있는 베스트 상품을 구분하여 각각 광고 소재 세트를 만들기도 하고, 신상품을 소개하고자 하는 고객군별로 구분하여 광고 소재 세트를 만드는 경우도 있다.

온라인 쇼핑몰은 24시간 운영이 되며, 베스트 상품의 순위 변동, 신상품의 등록, 상품의 품질은 비정기적으로 발생하는 일이다. 광고 소재 세트의 광고 성과가 극대화되기 위해서는 비정기적으로 발생하는 일들이 광고 소재 세트에 늦지 않게 반영되어야 한다. 예를 들어 특정 광고 소재가 쇼핑몰에서는 품질일 경우 페이스북은 품질 상황을 파악할 수 없기 때문에 품질된 광고가 계속 노출이 된다. 해당 광고 소재를 이용자가 클릭하는 경우 광고비는 소진되지만, 이용자의 구매는 발생하지 않는다. 광고의 목적이 쇼핑몰에 이용자의 유입수를 늘리는 것이라면 문제없으나, 구매 전환이 목적이라면 해당 광고 소

100) 이정우, 김승천. (2021). 국내 패션 이커머스 사업자의 디스플레이 광고 실적 개선을 위한 자동 광고 운영 기법. 『전자공학회논문지』, 58(10), pp. 35-41.


재는 삭제되거나 교체되어야 한다. 광고 성과를 보면 전체 광고 성과가 낮은 것으로만 보일 뿐 일부 광고 소재의 품질로 인하여 광고비가 낭비되고, 이로 인해 광고 성과가 낮아졌다는 것을 마케터가 알 수 있는 방법이 없다. 베스트 상품의 순위 변동이나 신상품의 등록 역시 마케터가 상품의 변동 상황을 실시간으로 파악하여 광고 소재 세트를 업데이트 해주는 것이 필요하지만, 현실적으로는 불가능하다.

이를 해결하기 위해 마케터가 쇼핑몰 상품들의 상황을 파악하여 직접 광고 소재 세트를 업데이트하는 대신 매시간 쇼핑몰 상품들의 상황을 파악하고, 변화가 있는 경우 광고 소재 세트를 업데이트하는 자동화 프로그램 알고리즘을 제안한다. 제안한 알고리즘이 유효한지를 판단하기 위하여 실제로 프로그램을 구현하여 마케터가 직접 운영하는 경우와 프로그램 알고리즘에 의해 운영되는 경우의 광고 성과를 비교를 통해 프로그램 알고리즘의 유효성을 판단하고자 한다. 제안하는 페이스북의 카탈로그 광고 자동운영은 광고매체 데이터뿐만 아니라 광고주 웹사이트의 상품 정보를 수집하는 데이터 수집 모듈이 주기적으로 상품 정보를 수집하기 때문에 가능한 자동운영 방법이다. 광고 운영 자동화 프로그램은 데이터베이스와 데이터 수집 스크립트로 구성된 성과 분석 시스템, 변화감지 프로그램, 광고 소재 추출 프로그램, 광고 소재 업데이트 프로그램으로 구성된다. 쇼핑몰에 상품 데이터 및 판매 데이터를 실시간으로 수집하여 별도의 서버에 설치된 데이터베이스에 저장하는 스크립트를 설치한다. 해당 스크립트는 모든 상품의 정보, 대표 이미지, 상품의 세부 내용, 등록 시간, 판매 정보를 수집하며, 추가로 사용자의 유입 경로, 구매 정보를 수집한다. 이때 사용자의 개인정보에 해당하는 데이터는 수집하지 않는다. 광고 운영 자동화 프로그램은 상황별로 다음과 같은 알고리즘으로 동작하게 된다.

(1) 새로운 상품 등록

새로운 상품이 등록된 경우, 변화감지 프로그램을 통해 해당 상품에 대한 정보를 전달받은 광고 소재 추출 프로그램은 해당 상품의 대표 이미지와 텍

스트를 추출하여 광고 소재로 만들고, 업데이트 프로그램이 페이스북 광고 소재 세트 중 신상품 광고 소재 세트에 해당 광고 소재를 추가한다. 이때, 광고 소재 세트 내의 광고 소재의 수가 사전에 지정한 개수를 초과하는 경우 오래된 광고 소재는 해당 광고 소재 세트에서 삭제한다.




[그림 3-18] 광고 자동운영 프로그램의 흐름도 - 새로운 상품 등록

[그림 3-18]는 광고 운영 자동화 프로그램이 쇼핑몰의 신상품 등록을 인식하고, 신상품에 대한 광고 소재를 생성하여 페이스북 광고에 자동으로 업데이트하는 실행 과정을 도식화 한 흐름도이다.

(2) 상품 순위 변경

신상품 등록 외에 쇼핑몰 내 베스트 상품의 변동으로 인하여 베스트 상품 순위 내에 새로운 상품이 등록되는 경우, 변화감지 프로그램을 통해 해당 상품에 대한 정보를 전달받은 광고 소재 추출 프로그램은 해당 상품의 대표 이미지와 텍스트를 추출하여 광고 소재로 만든다. 만들어진 광고 소재를 업데이트 프로그램이 페이스북 광고 소재 세트 중 베스트 상품 광고 소재 세트에

추가한다. 이때, 광고 소재 세트 내의 광고 소재의 수가 사전에 지정한 개수를 초과하는 경우 베스트 상품 순위 밖으로 밀려난 광고 소재는 해당 광고 소재 세트에서 삭제한다. 본 연구에서는 쇼핑몰 내 베스트 상품으로 지정하였으나 광고 성과를 기반으로 하는 베스트 상품 세트를 구성하는 방법도 온라인 광고 자동운영으로 높은 성과를 기대할 수 있는 방법이다.




[그림 3-19] 광고 자동운영 프로그램의 흐름도 - 순위 변경 상품 반영

[그림 3-19]는 쇼핑몰에서 베스트 상품의 순위가 변경되었을 때 광고 운영 자동화 프로그램이 베스트 상품 랭킹 변경을 인식하고 새로 등록된 베스트 상품에 대한 광고 소재를 생성하여 페이스북 광고를 업데이트하는 실행 과정을 도식화 한 흐름도이다.

(3) 상품의 품질

품질된 상품이 변화감지 프로그램을 통해 발견되었을 경우, 광고 소재 업데이트 프로그램은 페이스북 광고 소재 세트에서 해당 상품의 광고 소재를 삭제한다.



[그림 3-20] 광고 자동운영 프로그램의 흐름도 - 품질 상품 삭제

[그림 3-20]은 쇼핑몰에서 광고 소재로 등록된 상품이 품질된 경우 광고 운영 자동화 프로그램이 품질된 상품을 인식하여 페이스북 광고에서 해당 상품의 광고 소재를 제거하는 실행 과정을 도시한 흐름도이다.

본 연구에서는 제안한 온라인 광고 자동운영 시스템의 알고리즘을 구현하고, 실제 온라인 광고 운영을 통한 실험으로 광고 성과 향상 여부를 확인하여 알고리즘의 유효성을 입증하고자 한다.

나) 네이버 검색 광고 자동운영 시스템

본 연구에서 네이버 검색 광고의 자동운영 방식은 목적에 따라 크게 2가지로 분류된다. 하나는 전환, 즉, 사용자가 광고를 클릭하여 광고주의 웹페이지에 접속한 후 구매나 회원가입 등 특정한 행동을 완료하는 것을 목적으로 하는 경우로 주로 쇼핑몰을 대상으로 한다. 다른 하나는 유입, 즉, 사용자가 광고를 클릭하여 광고주의 웹페이지에 접속하는 것만을 목표로 하는 경우로 주로 브랜드 광고나 전환을 설정하기 어려운 광고주를 대상으로 한다. 전환을 목적으로 하는 광고의 경우 성과지표를 광고비 대비 매출을 나타내는 ROAS를 사용한다. 반면 유입을 목적으로 하는 광고의 경우 성과지표를 클릭률

(CTR: Click Through Ratio)이나 클릭당 광고비(CPC: Cost per Click)를 사용한다.

본 연구에서는 전환을 목적으로 하는 광고의 자동운영 방법은 누수율이라는 새로운 지표를 만들고 이 지표를 반영하여 사전에 정의된 조건에 의해 광고비 입찰가를 조정하는 방식으로 설계하였고, 유입을 목적으로 하는 광고의 자동운영 방법은 인공지능을 도입하여 광고 성과를 예측하여 예측값에 따라 자동으로 운영하는 방식으로 설계하였다. 전환을 목적으로 하는 광고의 자동운영에 인공지능을 도입하지 않은 이유는 광고 운영의 결과값으로 사용되는 지표인 ROAS는 광고를 통한 매출을 통해 계산하며, 매출값의 범위가 넓어 인공지능에 활용하기에는 여러 단계의 추가 연구가 필요하기 때문이다. 반면 유입을 목적으로 하는 광고의 경우 광고 운영의 결과값이 클릭 수 또는 클릭 추이이며, 시간 간격을 충분히 짧게 하면 일정한 범위 내의 결과값으로 수렴되기 때문에 인공지능을 활용한 예측이 가능하다.

(1) 전환을 목적으로 하는 자동운영 : 사전 정의된 규칙 사용

네이버 검색 광고의 목적이 전환인 경우 본 연구에서 제안하는 자동운영 방법은 새로운 성과지표인 누수율을 통해 관리하는 방법이다.



[그림 3-21] 네이버 검색 광고 입찰가와 노출의 관계

네이버의 키워드 검색 광고의 광고비는 CPC 방식이다. CPC(Cost per Click)는 사용자가 검색한 결과 노출되는 키워드를 클릭했을 때 광고주가 지불하게 되는 비용으로 키워드 입찰가에 의해 결정되는 금액이다.¹⁰¹⁾ [그림 3-21]과 같이 입찰가를 높이면 검색 결과 노출 순위가 올라가게 되어 검색 상단에 키워드가 표시된다. 광고의 클릭률은 높아 지지만 고객이 광고를 클릭 할 때마다 높은 비용이 광고비로 지출된다. 광고주가 입찰가를 낮추면 고객이 클릭할 때 비용이 낮아지지만 검색 결과는 순위가 낮아져 고객의 클릭률이 떨어지거나 심지어 검색 첫 페이지에 공개되지 않아 고객이 다음 페이지로 이동해야만 보여지게 되어 광고 효과가 떨어지게 된다. 사용한 광고비와 판매 액의 관계를 보여주는 광고 실적 지표인 ROAS(Return on Advertising)는 광고 업계에서는 대표적으로 사용하는 성과지표이다. 이것은 투자한 광고비의 회수율이며 광고 비용 1원당 매출을 보여준다. ROAS가 높을수록 광고 효율 성이 높다.¹⁰²⁾ ROAS는 수식(3-1)과 같이 계산할 수 있다.

101) NAVER Corp. NAVER AD SERVICES. <https://saedu.naver.com/adguide/eng.nhn>.

$$ROAS(\%) = \frac{Sales}{Clicks \times Average\ CPC} \times 100 \quad \text{수식(3-1)}$$

예를 들어 한 달간 10,000건의 클릭이 발생했고, 평균 클릭당 광고비는 100원이라 가정하면 광고비는 100만 원이 소진된 것이다. 해당 광고를 통한 매출이 500만 원인 경우 ROAS는 500%가 된다. 이때 단순히 ROAS가 높다고 전체 광고 성과가 좋다고 할 수는 없다. 만일, 전체 키워드 중 상위 5%의 키워드에서 발생하는 매출이 450만 원인 경우, 나머지 키워드의 95%는 50만 원의 매출에 대한 기여도밖에 없어 광고 운영이 잘 된다고 보기 어렵다. 이처럼 전체 키워드 중 ROAS가 일정 기준 미만인 키워드는 광고비를 낭비하고 있는 것으로 판단하여, 이 키워드들을 관리함으로써 전체 성과를 높이는 방법으로 제안하는 새로운 성과지표가 누수율이다.¹⁰³⁾ 이 누수율은 수식(3-2)와 같이 계산할 수 있으며, 광고비 지출 대비 ROAS가 일정 비율 이하인 키워드의 광고비 소진 금액 비율을 의미한다. 즉, 전체 광고비 지출 중 성과가 떨어지는 광고에 사용된 광고비의 비율을 의미한다.

$$Leakage\ Ratio(\%) = \frac{Low\ Performance\ AD\ Cost}{Total\ AD\ Cost} \times 100 \quad \text{수식(3-2)}$$

예를 들어 아래 [표 3-1]과 같은 총 1,000개의 키워드를 운영하는 온라인 키워드 검색 광고 성과를 가정해보자. 키워드 그룹 A에서 C까지 55개의 키워드에서 전체 매출의 66.2%가 발생하고 나머지 945개의 키워드에서는 33.8%의 매출이 발생하고 있다. 오히려 키워드 그룹 E와 F는 매출이 지출한 광고비보다 낮아 광고 운영으로 손해를 본다고 말할 수 있다. 이 예시 표에서 그룹 D부터 F를 저성과 키워드 그룹으로 규정하고, 전체 광고비에서 저성과 키워드 그룹으로 소진된 광고비를 통해 누수율을 계산해보면 66.7%로 매우

102) Vaver, J., & Koehler, J. (2011). Measuring ad effectiveness using geo experiments. *Work. Paper*, pp. 1-8.

103) Lee, Jung-Woo, et al. (2019). A study of Leakage Ratio for increasing performance of online keyword search advertising. *Restaurant Business*, 118(8), pp. 308-314.

높게 나타남을 알 수 있다.

[표 3-1] 누수율 계산 예시


키워드 그룹	키워드 개수	평균 ROAS	변경 전 광고비	누수율 관리 작업	변경 후 광고비
A	10	300%	55,000		95,000
B	15	200%	45,000		75,000
C	30	180%	50,000		80,000
D	50	100%	79,500		45,000
E	250	75%	95,000		65,000
F	645	20%	125,500		90,000
합계			450,000		450,000
소계(저성과)			300,000		200,000
누수율			66.7%		44.4%
총 매출			520,850		690,750

누수율 관리를 통하여 저성과 키워드에서 소진되는 광고비의 일부를 고성
과 키워드로 전환하여 누수율을 44.4%까지 낮추는 것으로 전체 광고 성과를
향상시키는 결과를 가져오게 되는 것이다.

[표 3-1]에서 ROAS와 광고비를 이용하여 다음 수식을 통해 매출을 계산
할 수 있으며, Leakage Ratio를 22.2% 낮춤으로 인하여 매출을 32.6% 상승
시키는 결과를 가져왔다.

$$Total\ Sales = \sum_i (Average\ ROAS(i) \times Total\ AD\ Cost(i)) \quad \text{수식(3-3)}$$

상기 내용은 이해를 돕기 위해 예시를 든 것이고, 다음 장에서 실제로 운
영되는 쇼핑몰들의 광고 운영에 누수율 관리를 적용하여 전체 광고 성과의
변화를 확인하고자 한다.




[그림 3-22] 키워드 광고 자동운영 프로그램의 흐름도

[그림 3-22]은 전환을 목적으로 하는 키워드 광고 자동운영 프로그램의 흐름도이다. 누수율을 관리하기 위하여 개별 검색 키워드의 광고 성과에 따라 광고비를 조절하거나 해당 키워드의 광고를 켜거나 끄는 광고 운영작업을 하게 된다. 광고 운영작업의 기준은 성과가 낮은 키워드는 광고비를 축소하거나 끄고, 광고 성과가 높은 키워드는 광고비를 증액하는 것을 기본으로 한다. 광고 성과의 높고 낮음에 대한 기준과 각 기준 별 운영작업을 세분화하여 설정하며, 광고 운영과 광고 성과 데이터가 누적되면 통계프로그램을 활용하여 조건의 개선을 위한 변경을 진행한다.

(2) 유입을 목적으로 하는 자동운영 : 인공지능 활용

네이버 검색 광고의 목적이 유입인 경우 본 연구에서 제안하는 자동운영 방법은 인공지능을 활용한 성과 예측을 기반으로 운영하는 방법이다. 기본적인 운영 방법은 기존 성과를 바탕으로 광고비를 증액했을 때, 감액했을 때, 변동이 없을 때 각각 어떤 성과가 나올 것인지 인공지능을 활용해 예측하고,

가장 높은 성과가 나오는 운영작업을 선택하여 실행하는 것이다. 이를 위해서 인공지능을 활용하기 위한 데이터가 필요하다. 데이터 수집 및 분석 모듈을 통해 분석된 성과 데이터는 예측 시스템의 인공지능 훈련 데이터로의 재가공이 필요하다. 수집된 성과 데이터는 주식이나 날씨와 같은 연속성을 보유한 데이터가 아니기 때문에 예측값의 정확성이 보장되지 않는다. 예측을 위해서는 최소한 어떤 운영작업을 통해 어떤 성과가 나왔는지에 대한 입력값과 출력값의 조합 데이터가 필요하며, 운영 당시의 환경 데이터로 과거 성과 데이터와 일부 컨디션 데이터가 필요하다. 이를 위해 데이터 수집 및 분석 모듈의 고도화가 필요하다. 기존 온라인 광고 성과분석 시스템에서 데이터 소스 레이어를 성과 데이터인 데이터 소스 레이어와 운영작업 데이터인 엔티티 소스 레이어로 세분화하고, 이 두 레이어를 합쳐 조합된 데이터 소스 레이어(CDS: Combined Data Source Layer)로 만든다.




[그림 3-23] 조합된 데이터 소스 레이어의 동작

[그림 3-23]과 같이 조합된 데이터 소스 레이어를 통해 운영작업을 수행하면 데이터 소스에서 생성된 데이터와 운영 로그가 함께 데이터베이스에 저장된다. 조합된 데이터 소스와 운영 로그 데이터가 입력값이 되고, 해당 운영작업의 성과 데이터가 출력값이 되는 훈련 데이터 세트가 [그림 3-20]처럼 만들어져 인공지능 예측 시스템을 위한 훈련 데이터로 활용할 수 있다.




[그림 3-24] 인공지능 훈련 데이터 세트 구성



[그림 3-25] 인공지능 예측 시스템 블록 다이어그램

조합된 데이터 소스 레이어를 통해 개인정보는 배제하고 운영작업 데이터와 성과 데이터, 운영시 환경에 대한 데이터를 수집하고, 딥러닝 훈련을 통해 예측할 수 있는 시스템을 구현한다. [그림 3-25]은 인공지능 예측 시스템의 시스템 블록 다이어그램이다.

본 연구에서 제안하는 방식은 사용자 정보와 컨텍스트 정보를 제외하고 현재 집행 중인 광고의 과거 입찰가 변동 이력과 그에 따른 성과를 통해 입찰 금액 변동 시 방문자 수를 인공지능 모델링 기법 중 DNN(Deep Neural Network)을 활용하여 예측하는 것으로 광고비의 과다 집행을 막고 최적화된 광고비 집행 방법이다. 인공지능에 활용할 데이터의 형태가 CNN에 적합하지 않으며, 연속적인 데이터로 보이지만 전후 연관성이 없고 시계열 데이터가 아니기 때문에 진보된 인공지능 모델링인 LSTM, GRU을 사용하는 것 또한, 적절하지 못하여 DNN을 활용하여 2가지 온라인 광고 자동운영 모델을 만들고자 한다. 하나는 입찰가에 따른 방문자 수를 예측하는 모델이고, 다른 하나는 입찰가에 따른 방문자 수 추이를 예측하는 모델이다.




[그림 3-26] 온라인 광고 자동운영 인공지능 모델 1

[그림 3-26]는 본 연구에서 제안하는 유입을 목적으로 하는 자동운영의 2가지 인공지능 모델 중 첫 번째 모델의 블록 다이어그램이다. 첫 번째 모델은 입찰가를 입력하면, 유입자 수, 즉, 방문자 수를 예측해주고 예측의 정확도를 제시하는 방법이다. 마케터나 자동화 프로그램은 예측 정확도가 일정 수준 이상이고 예측값이 적절하다고 판단되면 입력한 입찰가를 실제로 광고 운영에 적용하고, 예측 정확도가 낮거나 예측값이 기대 이하이면 다른 입찰가를 입력하여 다시 인공지능 모델을 통한 예측을 실행하게 된다.

인공지능 모델링 설계는 2개의 히든 레이어를 가지는 DNN(Deep Neural Network)으로 한다. 각 레이어의 노드 카운트는 256개로 설정하고, 과적합(overfitting)을 줄이기 위해 dropout은 20%로 설정한다. 데이터를 학습할 때 실제 결과와 예측 결과값의 차이를 최소화하기 위한 최적화 알고리즘으로 Adam 알고리즘을 최적화 알고리즘으로 사용한다. 활성화 함수(Activation function)는 sigmoid 함수와 ReLU 함수를 사용하여 차이를 비교한다. 학습률

(Learning Rate)은 손실 함수가 최소화가 되는 최적의 해를 찾아가는 과정을 반복하는 방식이다. 학습률이 너무 크게 되면, 최적의 값으로 수렴하지 않고 발산하는 오버슈팅(Overshooting)이 발생하게 되고, 학습률이 너무 작게 되면 수렴하는 속도가 너무 느리고 부분적 최소값(Local minimum) 문제에 빠질 확률이 증가하게 된다. 본 연구에서는 적합한 학습률을 찾기 위하여 0.0001에서 0.1까지 적용한 후 가장 최상의 결과를 내는 값을 찾고자 한다. 손실함수는 평균 제곱 오차(MSE: Mean Squared Error)를 사용한다. 각 100회의 에폭(epoch)을 진행하도록 하며, 검증데이터(validation set)의 손실값을 모니터링하여 최소화시키는 방향으로 트레이닝을 진행하다가 성능이 증가되지 않으면 중지하도록 설계한다.



[그림 3-27] 온라인 광고 자동운영 인공지능 모델 2

[그림 3-27]는 본 연구에서 제안하는 유입을 목적으로 하는 자동운영의 2가지 인공지능 모델 중 두 번째 모델의 블록 다이어그램이다. 두 번째 모델은 입찰가를 입력하면 유입자 추이, 즉, 지금보다 방문자 수가 늘어날 것인지, 줄

어 들 것 인 지, 유 지 할 것 인 지에 대 한 예 측 값 을 각 각 보 여 주 고 결 과에 대 한 정 확 도를 제 시 하 는 방 법 이 다. 마 케 터 나 자 동 화 프 로 그 램 은 그 예 측 값 중 확 률 이 가 장 높 은 값 을 최 종 예 측 값 으 로 판 단 하 고 그 대 로 진 행 할 것 인 지 입 찰 가 를 변 경 할 것 인 지 결 정 하 게 된 다. 두 가 지 방 법 은 입 력 값 은 동 일 하 나 결 과 값 의 형 태 가 다 르 기 때 문 에 훈 련 을 위 한 모 델 링 방 법 도 상 이 하 다.

인공 지능 모 델 링 설 계 는 3 개 의 히든 레 이 어를 가 지 는 DNN 으 로 한 다. 각 레 이 어의 노 드 카운트 는 256 개 와 512 개 로 설 정 하 여 각 각 테 슣 트 하 고, 전 체 트 레 이 닝 데 이 터 를 나 누 어 테 슣 트 하 기 위 한 배 치 사 이 즈(batch size) 는 32 와 64 로 설 정 하 여 각 각 테 슣 트 한 다. 과 적 합(overfitting) 을 줄 이 기 위 한 dropout 은 20% 로 방 문 자 수 를 예 측 하 는 모 델 과 동 일 하 게 설 정 한 다. 데 이 터 를 학 습 할 때 실 제 결 과 와 예 측 결 과 값 의 차 이 를 최 소 화 하 기 위 한 최 적 화 알 고 리 즈 모 으 Adam 알 고 리 즈 를 최 적 화 알 고 리 즈 모 으 사 용 한 다. 활 성 화 함 수 의 경 우 최 종 노 드 외 의 노 드 에 는 ReLU 함 수 를 사 용 한 다. 마 지 막 노 드 의 활 성 화 함 수 는 분 류(Classification) 의 결 과 값 을 출 력 하 는 것 이 기 때 문 에 소 프 트 맥 스(Softmax) 함 수 를 사 용 한 다. 학 습 률(Learning Rate) 은 0.001 과 0.0001 두 가 지 를 적 용 한 후 가 장 최 상 의 결 과 를 내 는 값 을 찾 는 다. 손 실 함 수 역 시 분 류 문 제 를 해 결 하 는 데 적 합 한 다 중 분 류 손 실 함 수(Categorical Crossentropy) 를 사 용 한 다. 각 100 회 의 에 포 크(epoch) 을 진 행 하 도 록 하 며, 검 증 데 이 터(validation set) 의 손 실 값 을 모 니 터 링 하 여 최 소 화 시 키 는 방 향 으 로 트 레 이 닝 을 진 행 하 다 가 성 능 이 증 가 되 지 않 으 면 중 지 하 도 록 설 계 한 다.

본 연 구 는 인 공 지능 을 활 용 한 온 라 인 광 고 자 동 운 영 에 관 한 기 초 연 구 단 계 이 기 때 문 에 기 존 운 영 방 식 과 의 비 교 보 다 도 입 하 려 는 인 공 지능 모 델 링 의 정 확 도 와 손 실 값 확 인 을 통 해 실 제 시 스템 에 적 용 가 능 한 지 를 판 단 하 고, 정 확 도 향 상 을 위 한 추 가 연 구 의 초 석 이 되 는 연 구 를 진 행 하 고 자 한 다. 누 수 율 관 리 를 통 한 자 동 운 영 도 높 은 성 과 를 내 고 있 지 만, 성 과 데 이 터 의 수 가 적 거 나 갑 자 기 성 과 변 화 가 큰 경 우, 세 밀 한 조 정 이 필 요 한 경 우 등 사 전 설 정 된 조 건 을 적 용 하 기 어 려 운 사 례 가 발 생 하 고, 이 로 인 해 전 체 성 과 가 낮 아 지 는 경 우 가 발 생 할 수 있 다. 인 공 지능 을 활 용 할 경 우 성 과 가 향 상 될 수 있 는 방 법 과 각 각 의 확 률 까 지 확 인 할 수 있 기 때 문 에 더 세 밀 한 운 영 작 업 이 가 능 하 며, 정

확도가 임계값을 넘지 못하는 경우나 오차값이 큰 상황일 때에는 안내 메시지를 통해 운영자의 개입으로 성과의 저하나 광고비의 낭비를 사전에 막을 수 있다.

제 4 장 온라인 광고 자동운영 시스템 구현 및 테스트

제 1 절 온라인 광고 자동운영 시스템 구현

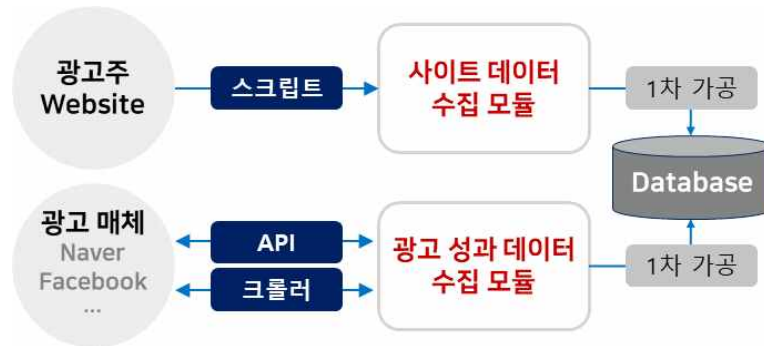
1) 구현 범위 및 구현 내용

본 연구에서 제안하는 온라인 광고 자동운영 시스템은 성과분석 시스템과 자동운영 시스템으로 구분된다. 자동운영 시스템은 페이스북 카탈로그 광고 자동운영 시스템과 네이버 검색 광고 자동운영 시스템으로 나뉘고, 네이버 검색 광고 자동운영 시스템은 전환을 목적으로 하는 경우 사전 정의된 규칙을 사용한 자동운영, 유입을 목적으로 하는 경우 인공지능을 활용한 자동운영 시스템으로 다시 나뉜다. 이중 성과분석 시스템은 본 연구에서 제안한 시스템 아키텍처 설계에 따라 구현하였으며, 자동운영 시스템 중 페이스북 카탈로그 광고 자동운영 시스템과 네이버 검색 광고 중 전환을 목적으로 하는 경우 사전 정의된 규칙을 사용한 자동운영은 본 연구에서 제안한 알고리즘을 반영하여 구현하였다. 네이버 검색 광고 중 전환을 목적으로 하는 경우 사전 정의된 규칙을 사용한 자동운영 시스템은 일종의 엔진으로 사용자를 위한 UI가 구현되지 않았다. 끝으로 네이버 검색 광고 중 유입을 목적으로 하는 경우의 자동운영 시스템은 인공지능을 활용하기 위하여 인공지능 엔진을 개발하였다. 구현된 인공지능 엔진에 사전 준비된 데이터셋을 활용하여 훈련과 테스트를 통해 정확도를 평가하였다.

가) 성과분석 시스템의 구현


성과분석 시스템의 구현은 크게 데이터 수집 모듈 구현과 데이터 가공 모듈 구현, 가공된 데이터를 시각화해주기 위한 빌더 구현과 UI 모듈 구현이

필요하다. 데이터 수집 모듈과 데이터 가공 모듈은 엔진의 성격을 지니고 백그라운드로 실행되는 모듈로 사용자 UI는 구현하지 않는다.



[그림 4-1] 데이터 수집 모듈 다이어그램


[그림 4-1]은 데이터 수집 모듈을 도식화 한 그림이다. 데이터 수집 모듈은 광고매체의 성과 데이터와 광고주의 웹사이트 데이터를 가져와 1차 가공을 거친 후 데이터베이스에 저장한다. 광고 성과 데이터 수집 모듈은 여러 광고매체에서 제공하는 API를 활용하여 주기적으로 성과 데이터를 수집하며, 공식적으로 API를 제공하지 않는 일부 국내 광고매체의 경우 크롤링 방식을 통해 데이터를 수집한다. 광고주 웹사이트의 데이터는 광고주 웹사이트에 설치된 스크립트를 통해 데이터를 수집하는데, 이벤트가 발생할 때 통신을 통해 수집하며, 이벤트가 없더라도 데이터의 종류에 따라 5분 주기, 1시간 주기, 1일 주기로 데이터를 수집한다. 광고매체로부터 수집하는 데이터는 1일 1회 수집하여 광고주 웹사이트에서 수집한 데이터와 연동하는 작업을 수행한다. 데이터 수집 모듈을 통해 수집된 데이터를 그대로 데이터베이스에 저장하는 경우 데이터의 양이 기하급수적으로 증가하기 때문에, 저장하기 전에 데이터 가공 모듈을 통해 데이터로서 의미를 갖는 최소한의 데이터로 가공되어 저장된다. 광고주 웹사이트에 설치하는 스크립트는 자바스크립트로 개발되었으며, 광고매체에서 데이터를 수집하는 프로그램과 1차 가공을 하는 프로그램 및 모든 서버 프로그램은 PHP로 개발되었다.



[그림 4-2] 조합된 데이터 소스 레이어 반영 성과분석 시스템의 계층 구조

[그림 4-2]는 기존 데이터 소스 레이어를 조합된 데이터 소스 레이어 (CDS)로 변경한 시스템의 계층 구조이다. 데이터 수집 모듈에서 수집된 데이터들이 각 계층 구조에 따라 변화되며 사용자에게 유의미한 데이터로 변경되어 전달되고, 이 데이터를 반영하여 자동운영 시스템이 작동하게 된다. 데이터베이스에 저장된 데이터들을 광고 성과지표 데이터로 만들어 광고주별로 커스터마이징하여 시각화하는 기능은 각 계층 별로 빌더를 개발하여 구현하였다. 조합된 데이터 소스 레이어 중 엔티티 소스 레이어는 운영과 환경 데이터를 저장하는 레이어로 별도의 UI가 개발되지 않고, 데이터 소스 레이어에 포함되어 개발된다.

(1) 데이터 소스 필터




[그림 4-3] 데이터소스 필터와 메트릭

[그림 4-3]은 데이터 소스 필터와 메트릭의 사용자 화면이다. Raw 데이터 레이어에서 수집된 데이터를 활용하여 메트릭 레이어에서 생성된 다양한 메트릭과 그 메트릭을 광고주나 마케터가 유용하게 활용할 수 있도록 데이터 소스 필터를 통해 커스터마이징된 성과지표를 생성할 수 있다. 또한, 광고 매체에서 제공되는 광고성과 데이터뿐만 아니라 광고주 사이트의 로그 데이터도 조합하기 때문에 성과지표의 확장 또한 가능하다. 예를 들어 광고매체에서는 광고를 클릭하여 접속하는 경우 광고성과 데이터로 유입수라는 광고 지표를 제공한다. 또한, 광고를 클릭하여 접속한 후 상품을 구매할 경우 광고매체는 구매에 관련된 광고 지표도 제공한다. 데이터 소스 필터에서는 이 두 가지 지표를 조합하여 구매율과 같은 새로운 지표도 생성할 수 있다. 또한, 광

고매체에서는 제공하지 않는 데이터를 함께 활용하여 장바구니에 담았다가 포기하는 수치 등 더욱 복잡한 지표를 제공하는 것도 가능하다.


(2) 콤포넌트 빌더



[그림 4-4] 콤포넌트 빌더


[그림 4-4]는 각종 지표를 시각화하기 위한 콤포넌트 빌더이다. 콤포넌트 빌더에서는 지표를 텍스트나 그래프, 표 등으로 시각화할 수 있도록 콤포넌트를 제작한다. 일반적으로 광고 성과를 보고자 하는 기간 내 합산값이나 평균값, 비율 등 특정 수치를 알고자 하는 경우 텍스트 콤포넌트로 제작을 하고, 특정 기간의 변화값이나 추이를 알고자 하는 경우 그래프 형태, 다양한 값들을 모아보고 싶을 때에는 표 형태로 콤포넌트를 제작한다. 지표가 보여주는 값과 그 범위에 따라 콤포넌트의 크기도 각기 다르게 제작할 수 있다.

(3) 위젯 빌더




[그림 4-5] 위젯 빌더

[그림 4-5]는 위젯 빌더로 앞서 제작한 컴포넌트를 배열하여 하나의 페이지로 만드는 툴이다. 컴포넌트의 크기에 맞춰 그리드 형태의 틀 안에 배치하는 형태이며, 그림의 예시는 1 x 2 크기의 텍스트 컴포넌트와 그 아래에 2 x 6 크기의 표 컴포넌트, 그 주위에 2 x 2 크기의 그래프 컴포넌트 7개를 배치한 형태이다. 이렇게 한 화면에 배치된 지표들의 모음을 페이지라고 하며, 여러 페이지를 만들어 하나의 워크스페이스(Workspace)에 모아둘 수 있다. 이렇게 복수의 페이지가 모여있는 워크스페이스 또한, 여러 개를 생성할 수 있는 구조이다. [그림 4-6]은 이런 구조의 예시이며, 하나의 워크스페이스 안에 여러 페이지가 있고, 페이지 역시 계층화 구조로 되어있는 것을 확인할 수 있다.



[그림 4-6] 페이지 구성 및 워크스페이스



[그림 4-7] 페이지 예시


[그림 4-7]은 페이지 구성 예시로 다양한 텍스트 컴포넌트로 구성된 지표들과 그래프 컴포넌트들로 구성되어 있다.

나) 자동운영 시스템의 구현

(1) 페이스북 카탈로그 광고 자동운영 시스템

페이스북 카탈로그 광고 자동운영 시스템의 구현은 본 연구에서 제안하는 알고리즘을 반영하여 구현하였으며, 그 외에도 최초 카탈로그 등록을 위한 광고 소재 추출 및 등록까지 자동화하여 구현하였다. 본 연구에서 제안하는 알고리즘은 광고주 사이트의 상품의 변동, 즉, 상품의 품질이나 새로운 상품의 등록, 베스트 상품 순위 변동을 파악하여 광고 소재에도 반영하는 것으로 광고비의 낭비를 막는 효과를 추구한다. 이러한 변동 이벤트는 변동 즉시 감지하는 것이 불가능하기 때문에, 1시간마다 주기적으로 확인하여 변동 사항이

있을 때, 광고 소재를 자동으로 변경해준다. 상품의 변동을 확인하는 것뿐만 아니라 페이스북 카탈로그 광고를 진행하기 위하여 초기 상품 카탈로그를 구성하는 작업이 필요하다. 카탈로그는 복수로 구성이 가능하기 때문에 다양한 카탈로그를 생성하여 광고를 운영한다. 카탈로그마다 많게는 수십 개의 광고 소재를 등록하기 때문에 카탈로그의 목적에 맞는 광고 소재를 광고주의 웹사이트에서 추출하여 페이스북에 하나하나 등록하는 것도 상당한 인적 리소스 투입이 필요하여 이를 자동으로 등록하는 프로그램도 구현하였다.



[그림 4-8] 페이스북 광고 소재 자동 등록 프로그램 인터페이스

[그림 4-8]은 카탈로그에 등록할 광고 소재를 목적에 따라 추출하여 페이스북에 자동으로 등록하는 프로그램의 인터페이스이다. 페이스북 카탈로그 광고 자동운영 시스템은 위와 같이 등록된 카탈로그 내 상품들의 상태가 광고주의 웹사이트에서 변동이 발생할 때 이를 반영하여 광고 소재를 자동으로 추가, 교체, 삭제하는 작업을 실행한다. 프로그램은 PHP와 C#으로 개발되었으며, 광고 소재의 등록, 변경, 삭제 기능은 페이스북에서 제공하는 API를 활용하여 개발하였다.

(2) 사전 정의된 규칙을 사용한 전환 목적 네이버 검색 광고 자동운영 시스템

사전 정의된 규칙을 사용한 전환 목적 네이버 검색 광고 자동운영 시스템은 백그라운드로 실행되며 1일 주기로 키워드 검색어의 성과를 체크하고, 사전에 정의된 규칙에 따라 각 키워드의 입찰가를 한 번에 수정한다. 입찰가 수정작업은 키워드 검색어의 수가 많고, 입찰가를 수정하는 과정에서 광고 성과에 영향을 미치면 안되기 때문에 광고 성과가 가장 낮은 시간대인 새벽에 실행한다.


keyword	date	impression	visit_a	order_a	order_p1	order_p7	order_p14	sales_a	sales_p1	sales_p7	sales_p14	ad_fee
587394	2020-03-01	5,112	853	24	11	14	-	1,355,862	688,303	873,652	-	113,982
587394	2020-03-02	3,990	659	13	7	7	1	707,962	471,637	289,812	53,100	92,675
587394	2020-03-03	4,135	692	24	16	30	6	921,053	630,614	1,086,171	262,085	92,290
587394	2020-03-04	3,809	648	36	9	22	1	1,473,353	338,535	887,597	29,600	83,523
587394	2020-03-05	3,843	637	10	5	3	1	372,110	168,960	60,730	15,360	78,309
587394	2020-03-06	3,794	601	17	7	11	-	1,108,627	349,970	647,180	-	74,723
587394	2020-03-07	4,027	607	12	6	8	2	603,690	320,340	358,413	77,033	77,132
587394	2020-03-08	4,584	694	13	7	9	1	690,256	334,090	508,076	57,790	79,123
587394	2020-03-09	4,701	724	19	12	13	-	692,145	593,558	687,433	-	85,679
587394	2020-03-10	4,173	625	18	6	12	-	792,642	299,620	470,800	-	78,452
587394	2020-03-11	4,162	660	16	11	11	1	716,746	578,460	422,290	46,500	79,079
587394	2020-03-12	3,445	554	16	10	18	4	625,030	364,480	525,000	85,950	69,916
587394	2020-03-13	3,354	441	9	5	6	-	245,800	240,520	243,330	-	53,526
587394	2020-03-14	3,500	514	11	7	6	4	317,190	173,870	151,180	108,700	63,206
587394	2020-03-15	4,188	648	15	6	6	-	756,901	313,382	379,410	-	78,045
587394	2020-03-16	3,703	580	16	8	11	2	554,295	312,900	305,400	81,000	70,873
587394	2020-03-17	3,812	514	21	6	12	-	1,003,788	346,020	494,674	-	64,009
587394	2020-03-18	3,423	501	23	7	9	3	798,036	315,500	407,300	186,000	61,919
587394	2020-03-19	3,457	513	12	7	8	-	597,320	390,420	316,600	-	61,765
587394	2020-03-20	3,172	487	11	4	7	-	636,180	141,400	370,040	-	59,235
587394	2020-03-21	3,152	527	15	7	12	-	592,011	484,280	552,240	-	62,590
587394	2020-03-22	4,020	626	22	13	24	3	956,669	701,480	1,039,114	117,300	77,748
587394	2020-03-23	3,394	562	11	10	5	-	474,900	466,500	229,300	-	77,517
587394	2020-03-24	3,337	486	12	2	6	-	320,606	50,400	218,612	-	64,174
587394	2020-03-25	3,553	527	15	2	8	-	486,630	75,205	207,080	-	69,729
587394	2020-03-26	3,581	529	15	2	2	-	591,935	99,700	87,800	-	71,181
587394	2020-03-27	2,992	472	15	6	8	1	556,330	205,481	362,501	64,281	62,568
587394	2020-03-28	3,314	515	11	4	3	-	443,177	204,900	88,577	-	69,300
587394	2020-03-29	3,698	583	12	9	11	1	762,715	631,620	772,650	105,675	76,912
587394	2020-03-30	3,229	476	20	4	14	-	1,006,502	222,130	715,892	-	61,127
587394	2020-03-31	2,962	451	11	1	3	-	349,100	44,200	138,635	-	54,285

[그림 4-9] 네이버 검색 광고 성과 데이터

[그림 4-9]는 사전 정의된 규칙을 사용한 전환 목적 네이버 검색 광고 자동운영 시스템이 읽어 들이는 데이터의 예시이다. 해당 키워드 검색어의 전일, 직전 3일, 직전 7일, 직전 14일, 직전 30일의 전환 성과 데이터를 읽어와서 조건에 따른 광고 On/Off, 입찰가 조정을 실행하는 절차를 수행한다. 프로그램은 PHP로 개발되었으며, 키워드 검색어의 On/Off, 입찰가 조정 기능은 네이버에서 제공하는 API를 활용하여 개발하였다.

(3) 인공지능을 활용한 유입 목적 네이버 검색 광고 자동운영 시스템

인공지능을 활용한 유입 목적 네이버 검색 광고 자동운영 시스템은 성능 검증이 가능한 단계의 인공지능 모델을 구현하였다. 인공지능 모델에 활용하기 위한 데이터는 조합된 데이터 소스 레이어를 통해 수집하였다. 인공지능을 활용한 유입 목적 네이버 검색 광고 자동운영 시스템은 수집된 데이터를 모아 하나의 데이터로 병합한 후 인공지능 데이터셋에 적합한 전처리 작업을 실행한다. 전처리 된 데이터셋을 사용하여 인공지능 모델링 훈련을 실행하고, 모델링 결과 데이터를 저장한다. 키워드 검색어와 광고 입찰가가 사용자 입력으로 들어오면, 모델링 결과 데이터에 적용하여 광고 성과를 예측하게 된다.



[그림 4-10] 인공지능 예측값을 활용한 수동 운영 예시

[그림 4-10]은 이해를 돕기 위한 그림으로 인공지능을 활용한 예측값을 수동 운영에 적용할 때의 사용자 UI 컨셉이다. 인공지능 모델링 프로그램은 Python으로 개발되었다.

2) 시스템 성능 지표

본 연구에서 제안하는 온라인 광고 자동운영 시스템은 SaaS(Software as a Service) 시스템으로 클라우드 환경에서 운영되기 때문에 하드웨어 성능은 처리 속도나 처리 용량이 부족하면 하드웨어를 추가하면 되기 때문에 큰 의미가 없다. 본 시스템에서 중요한 성능 지표는 각 자동운영 방식에 따라 아래와 같이 달라지게 된다.

가) 페이스북 카탈로그 광고 자동운영 시스템

광고 성과의 향상과 저하를 비교하기 위하여 광고 성과지표를 설정해야 한다. 이때 광고 목적에 따라 각기 다른 광고 성과지표를 설정하여 성과의 좋고 나쁨을 판단하게 된다. 예를 들어 광고의 목적이 광고를 통해 많은 방문자의 유입이라면 고객 유입 당 비용, 즉, CPC(Cost per Click)를 주요 성과지표로 삼는다. 이 CPC의 계산은 수식(4-1)과 같으며, 이 지표는 비용을 나타내는 지표이기 때문에 적을수록 좋은 성과로 판단한다.¹⁰⁴⁾

$$CPC = \frac{Clicks}{ADS} \quad (4-1)$$

온라인 쇼핑몰의 경우 광고의 주요 목적은 일반적으로 매출의 상승이다. 이를 위한 대표적인 광고 성과지표는 광고를 통한 전환 매출을 확인하기 위한 ROAS(Return on Advertising Spend), 즉, 지불한 광고 비용 대비 해당 광고를 통한 매출액의 비율을 주요 성과지표로 잡는다. ROAS의 계산 방법은 수식(2)와 같으며, 이 지표의 값은 클수록 좋은 성과로 판단한다.¹⁰⁵⁾

104) Aguilar, J., & Garcia, G. (2017). An adaptive intelligent management system of advertising for social networks: A case study of Facebook. *IEEE Transactions on Computational Social Systems*, 5(1), pp. 20-32.

105) Vaver, J., & Koehler, J. (2011). Measuring ad effectiveness using geo experiments. *Work Paper*, pp. 1-8.

$$ROAS(\%) = \frac{Sales}{Clicks \times Average\ CPC} \times 100 \quad (4-2)$$

온라인 쇼핑몰의 경우 또 다른 광고의 주요 목적으로 회원 가입을 증가시키고자 하는 경우도 있다. 이 경우 회원 가입률인 MRR(Membership Registration Rate)과 회원 가입 당 비용인 CPMR(Cost per Membership Registration)의 두 가지 지표를 주요 성과지표로 잡는다. MRR의 계산 방식은 수식(3)과 같으며, 이 지표의 값은 클수록 좋은 성과로 판단한다.

$$MRR(\%) = \frac{Number\ of\ sign-ups}{IMPR} \times 100 \quad (4-3)$$

CPMR의 계산 방식은 수식(4)와 같으며, 이 지표는 비용 지표이기 때문에 적을수록 좋은 성과로 판단한다.

$$CPMR = \frac{Number\ of\ sign-ups}{ADS} \quad (4-4)$$

나) 사전 정의된 규칙을 사용한 전환 목적 네이버 검색 광고 자동운영 시스템

사전 정의된 규칙을 사용한 전환 목적 네이버 검색 광고 자동운영 시스템에서 관리하는 성과지표는 누수율(Leakage Ratio)이다. 이 누수율을 관리하는 것으로 광고비를 절감하고, 고효율의 키워드 검색어에 더 많은 예산을 배분하여 전체 광고 성과를 향상시킬 수 있다. 누수율의 계산은 수식(5)와 같다.

$$Leakage\ Ratio(\%) = \frac{Low\ Performance\ AD\ Cost}{Total\ AD\ Cost} \times 100 \quad (4-5)$$

다) 인공지능을 활용한 유입 목적 네이버 검색 광고 자동운영 시스템

인공지능 모델링의 성능 지표이기 때문에 정확도(Accuracy)와 손실값 (Loss Value, Cost Value)을 확인한다.

제 2 절 시스템 성능 검증


1) 페이스북 카탈로그 광고 자동운영 시스템 성능 테스트

가) 실험 방법

본 연구에서는 페이스북 카탈로그 광고 자동운영 시스템의 성능을 실험하기 위하여 대한민국 인터넷 패션 쇼핑몰 중 연 매출 100억 원 이상인 중대형 쇼핑몰 중 한 곳을 선정하여 광고주의 동의를 얻어 3개월 간 기존의 방식을 유지하는 광고 운영과 본 연구에서 제안하는 자동운영 시스템을 통한 자동 광고 운영을 함께 병행하여 운영하면서 두 경우의 광고 성과를 비교하는 실험 데이터를 수집하여 비교하였다. 광고 성과는 실험 기간 동안 매일 취합하여 주간 단위로 합산한 후 비교하였다. 본 연구에서는 고객 유입당 비용, 즉, CPC(Cost per Click, 클릭당 비용), ROAS(Return on Advertising Spend), 즉, 지불한 광고비용 대비 해당 광고를 통한 매출액의 비율, 회원 가입률인 MRR(Membership Registration Rate), 회원 가입당 비용인 CPMR(Cost per Membership Registration), 이 4가지 광고 성과지표의 비교를 통하여 기존 광고 운영 방식과 자동 광고 운영 방식의 성과를 비교하였다.

나) 실험 결과


실험 결과는 [그림 4-10]에서 [그림 4-13]까지의 그래프를 통해 확인할 수 있다. 회색 그래프는 기존 광고 운영 방식의 광고 성과 데이터로 본 실험 이전과 본 실험 기간의 차이가 크게 나지 않는 것을 확인할 수 있다. 붉은색 그래프는 본 연구에서 제안하는 프로그램을 통한 자동 광고 운영 방식의 광고 성과 데이터이다.



[그림 4-11] 고객 유입당 비용(CPC) 비교


[그림 4-11]은 CPC(cost per click) 비교 그래프이다. 비용을 비교한 것이기 때문에 값이 적을수록 광고 성과가 좋은 것이다.¹⁰⁶⁾ 본 연구에서 제안하는 광고 자동운영 시스템을 통한 광고 자동운영 방식이 기존 광고 운영 방식 대비 CPC가 실험하는 모든 기간 동안 적은 값을 확인할 수 있다. 따라서 고객 유입당 비용을 비교하는 실험에서 자동운영 시스템의 성과가 더 높은 것을 확인할 수 있다.

106) Li, T., & Lee, K. J. (2008). Evaluation of Conversion Action Data Mechanisms in Cost-Per-Action Advertising. *Information Systems Review*, 10(2), pp. 123-135.




[그림 4-12] 회원 가입당 비용(CPMR) 비교

[그림 4-12]은 회원 가입 당 비용 비교 그래프이다. 비용 비교이기 때문에 적은 값이 광고 성과가 좋은 것을 의미한다. 기존 운영 방식의 경우 기본적으로 높은 비용을 유지하고 있으며, 큰 변동폭을 보인다. 본 연구에서 제안하는 광고 자동운영 시스템을 통한 광고 자동운영 방식의 회원 등록 1인당 비용은 기존 광고 운영 방식의 광고 성과에 비하여 실험하는 모든 기간 동안 현저히 적은 비용임을 확인할 수 있으며, 변동폭도 크지 않아 안정적임을 알 수 있다. 따라서 회원 가입당 비용(CPMR)을 비교하는 실험에서도 자동운영 시스템의 성과가 더 높은 것을 확인할 수 있다.



[그림 4-13] 광고비 대비 매출(ROAS) 비교

[그림 4-13]는 광고비 대비 매출액인 ROAS를 비교한 그래프로 값이 클수록 광고 성과가 좋은 것이다. 본 연구에서 제안하는 광고 자동운영 시스템을 통한 광고 자동운영 방식이 기존 광고 운영 방식 대비 실험하는 모든 기간 동안 큰 값임을 확인할 수 있다. 시기에 따른 차이는 있지만, 본 연구에서 제안하는 광고 자동운영 시스템을 통한 광고 자동운영 방식의 광고 성과가 최대 5배까지 향상되는 것을 확인할 수 있다. 따라서 광고비 대비 매출(ROAS)을 비교하는 실험에서도 자동운영 시스템의 성과가 더 높은 것을 확인할 수 있다.



[그림 4-14] 회원 가입률(MRR) 비교

[그림 4-14]은 광고 노출 대비 회원 가입자 수를 비교하는 그래프로 값이 클수록 광고 성과가 좋은 것을 의미한다. 본 연구에서 제안하는 광고 자동운영 시스템을 통한 광고 자동운영 방식이 기존 광고 운영 방식 대비 실험하는 모든 기간 동안 큰 값임을 확인할 수 있다. 따라서 회원 가입률(MRR)을 비교하는 실험에서도 자동운영 시스템의 성과가 더 높은 것을 확인할 수 있다.

실험 결과를 통해 본 연구에서 제안하는 광고 자동운영 시스템을 통한 광고 자동운영 방식이 기존 광고 운영 방식에 비하여 모든 실험에서 광고 성과가 향상되어 우수함을 확인할 수 있다.

2) 전환 목적 네이버 검색 광고 자동운영 시스템 성능 테스트

가) 실험 방법

본 연구에서는 전환 목적 네이버 검색 광고 자동운영 시스템의 성능을 실험하기 위하여 실제로 운영되는 쇼핑몰들의 광고 운영에 누수율 관리를 적용하여 전체 광고 성과의 변화를 확인하였다. 실험은 국내 패션 전문 쇼핑몰 중 연 매출 100억 원 이상인 중대형 패션 전문 쇼핑몰 5곳을 대상으로 쇼핑몰

별로 3주에서 10주간 진행하였다.

[표 4-1] 누수율 관리를 위한 운영 조건표

Period	Condition(Click/Conversion)	Condition(ROAS)	Operation
The day before	Click occurred	0%	down 7%
	Click occurred	Below 100%	down 5%
	More than 1 conversions occurred	500% or more	up 3%
	More than 2 conversions occurred		up 5%
	More than 5 conversions occurred		up 7%
Recent 7days	Click occurred more than 5 days	0%	down 10%
		Below 100%	down 7%
		100%~200%	down 5%
	1 conversion occurred	500% or more	ON
	More than 1 conversions occurred		up 3%
	More than 2 conversions occurred		up 5%
	More than 5 conversions occurred		up 7%
Recent 3days	Click occurred more than 3 days	0%	down 10%
		Below 100%	down 7%
		100%~200%	down 5%
	1 conversion occurred	500% or more	ON
	More than 1 conversions occurred		up 3%
	More than 2 conversions occurred		up 5%
	More than 5 conversions occurred		up 7%
Recent 14days	Click occurred more than 10 days	0%	OFF
		Below 100%	down 10%
		100%~200%	down 7%
	1 conversion occurred	500% or more	ON
	More than 1 conversions occurred		up 3%
	More than 2 conversions occurred		up 5%
	More than 5 conversions occurred		up 7%
Recent 30days	Click occurred	1000% or more	ON
	Click occurred more than 20 days	0%	OFF
	1 conversion occurred	1000% or more	up 5%
	More than 2 conversions occurred		up 7%

누수율을 조정하기 위하여 매일 1회 성과 추이에 따라 입찰가를 조정하였다. 성과가 낮은 키워드는 입찰가를 낮추거나 운영하지 않도록 조정 하였으며, 성과가 높은 키워드는 입찰가를 높이거나 운영을 재개하도록 조정하였다. 조정 조건은 전일자 기준 이전 30일간의 클릭, 구매건수, ROAS 성과를 바탕

으로 [표 4-1]과 같이 30단계로 구분하였다. 누수율의 관리 전과 후의 누수율의 변화와 ROAS 및 매출액의 변화를 통하여 실험의 결과를 도출하였다.


나) 실험 결과

실험에 참가한 업체별 운영 키워드 수는 평균 7,300개이며, 실험을 통하여 입찰가가 변경된 키워드 수는 업체별로 일 평균 114개이다. [표 4-2]와 [그림 4-15], [그림 4-16]에서 보여지는 것처럼 실험 결과 5개 쇼핑물 모두에서 누수율 관리로 광고 효율성이 향상되었음을 확인할 수 있다.


[표 4-2] 누수율과 ROAS의 변화

쇼핑물	누수율(%)			ROAS(%)		
	누수율 관리전	누수율 관리후	감소율	누수율 관리전	누수율 관리후	증가율
A	65.35	57.00	8.3	220.13	229.42	9.3
B	46.77	40.79	6.0	248.70	293.23	44.5
C	35.33	19.20	16.1	291.12	318.48	27.4
D	17.70	10.59	7.1	288.07	384.46	96.4
E	16.35	12.71	3.6	405.12	459.66	54.5
평균			8.2			46.4

관리를 통하여 누수율이 가장 많이 낮아진 쇼핑물은 C로 35.33%에서 19.2%로 16.1% 감소하였다. 그러나 ROAS는 291.12%에서 318.48%로 27.4% 상승하였으며, 이는 누수율이 가장 많이 낮아진 것에 비해 ROAS가 가장 많이 상승한 것은 아니었다. 관리를 통하여 누수율이 가장 적게 낮아진 쇼핑물은 E로 16.35%에서 12.17%로 3.6% 감소하였다. ROAS는 405.12%에서 459.66%로 54.5% 상승하였으며, 이 역시 다른 쇼핑물과 비교하였을 때 가장 적게 상승한 것은 아니었다. 이를 통하여 누수율의 감소와 ROAS의 증가가 비례하는 것은 아님을 알 수 있다.



[그림 4-15] 누수율 관리 전후 누수율 변화



[그림 4-16] 누수율 관리 전후 ROAS 변화

실험은 개별 키워드의 입찰가 조정을 통해 성과가 낮은 키워드의 입찰가를 낮추거나 순차적으로 광고를 끄고, 성과가 올라갈 것으로 추정되는 키워드는 입찰가를 높이는 방식으로 진행하였으며, 이를 통해 전체 키워드 중 성과

가 낮은 키워드의 비율을 감소시키는 누수율 관리를 진행하였다. 실험 결과 5 곳의 쇼핑몰 모두 전체 광고 성과가 증가하였음을 확인할 수 있다.

3) 유입 목적 네이버 검색 광고 자동운영 시스템 성능 테스트

유입 목적 네이버 검색 광고 자동운영 시스템 성능 테스트는 2가지로 진행하였다. 우선 입찰가에 따른 클릭 수를 예측하는 테스트를 진행하였고, 이후 입찰가에 따라 클릭 수가 이전보다 증가할 것인지, 유지될 것인지, 감소할 것인지에 대한 추이를 예측하는 테스트를 진행하였다.

가) 입찰가에 따른 클릭 수 예측

(1) 실험 방법

실험을 위한 데이터는 검색 광고 운영 데이터와 운영 결과인 클릭 수 로그를 수집하여 사용하였다. 일반적으로 검색 광고의 운영에 대한 로그는 저장하거나 보관하는 경우가 드물지만, 본 연구를 위하여 2019년부터 네이버에 검색 광고를 집행하고 있는 중대형 온라인 쇼핑몰을 대상으로 검색 광고를 운영하면서 필요한 데이터 로그를 수집하였다. 실험에 사용되는 키워드는 총 5개를 선정하여 수집하였는데, 키워드의 선정 기준은 다음과 같다. 양적 요소로서 2020년 1년 간 광고 소재로 등록이 된 이력이 있으며, 하루 1회 이상 입찰가를 변경한 이력이 있는 키워드 중 입찰가 변경 이력이 많은 순서로 선정하였다. 1년 간 데이터를 수집하였기 때문에 키워드에 따라 계절이나 유행에 의해 성과가 차이가 발생하게 된다. 질적 요소로서 계절이나 유행에 민감하지 않은 상품에 대한 키워드를 기존 선별된 키워드 중에서 최종적으로 선정하였다. 이 키워드들의 2020년 1년 간 입찰가 변경 내역에 대한 로그를 수집하고, 해당 키워드를 통한 클릭 로그를 별도로 수집하였다. 두 가지 로그 데이터를 시간 순서에 따라 병합한 후, 입찰가 변경 후 다음 변경 전까지의 클릭 수를 합산하였다. 이를 통해 변경된 입찰가를 통해 유입된 클릭 수와 변

경 전 입찰가를 통한 클릭 수를 구할 수 있다. 병합된 데이터를 바탕으로 입찰가의 변경 간격과 입찰가 변동률을 입력값으로 하고, 입찰가 변동으로 인한 클릭 수의 합산을 결과값으로 하여 데이터셋을 준비하였다.¹⁰⁷⁾

[표 4-3] 키워드와 데이터셋 수

데이터셋 번호	키워드 검색어	데이터셋 수
1	여성속옷쇼핑몰	9,028
2	매직브라	8,506
3	여성속옷세트	8,429
4	20대여성속옷	8,700
5	브라팬티	8,618

각 키워드 내용, 키워드 입찰가 변경과 클릭 수 성과 데이터셋은 [표 4-3]과 같다. 데이터셋은 트레이닝을 위하여 80%를 사용하고 테스트를 위하여 20%를 사용하였다. 인공지능 모델링을 구현하고 테스트를 진행한 시스템 환경은 [표 4-4]와 같다.

[표 4-4] 인공지능을 활용한 유입 목적 네이버 검색 광고 자동운영 시스템 구현 환경

구분	내용
OS	Ubuntu 18.04.5
CPU	Intel(R) Xeon(R) CPU @ 2.00GHz x 2ea
GPU	None
Memory	16GB
Language	Python 3.7.11
Library	Tensorflow 2.6.0

인공지능 모델링과 설정은 [표 4-5]와 같다. 모델링 설정의 변화에 따른 정확도를 비교하기 위하여 활성화 함수(Activation function)는 sigmoid 함수

107) 이정우, 김승천. (2021). ANN를 활용한 입찰가 변경 데이터 기반 키워드 검색광고 성과 예측방법. 『전자공학회논문지』.

와 ReLU 함수를 사용하여 차이를 비교하였고, 학습률은 0.0001에서 0.1까지 적용한 후 가장 최상의 결과를 내는 값을 찾고자 하였다. 검증데이터의 손실 값을 모니터링하여 성능이 증가되지 않으면 중지하도록 설정하였다.

[표 4-5] 인공지능 모델 환경

구분	내용
AI모델	DNN : 히든레이어2개
노드카운트	256
Dropout	20%
최적화 알고리즘	Adam
활성화 함수	Sigmoid / ReLU
학습률	0.1~0.0001
손실함수	평균 제곱 오차(MSE: Mean Squared Error)
Epoch수	100


(2) 실험 결과

키워드 별로 학습률과 활성화 함수를 변경하여 실험하였으며, 실험 결과로 나온 정확도(Accuracy)는 [표 4-5]에 정리하였다.

[표 4-6] 정확도(Accuracy) 비교


데이터셋 번호	데이터셋 수	활성화 함수	학습률			
			0.1	0.01	0.001	0.0001
1	9,028	Sigmoid	0.8291	0.8313	0.8042	0.8286
		ReLU	0.8247	0.8308	0.8247	0.8291
2	8,506	Sigmoid	0.8001	0.7995	0.7995	0.7995
		ReLU	0.7995	0.7989	0.7995	0.7989
3	8,429	Sigmoid	0.7998	0.7998	0.7998	0.7998
		ReLU	0.8004	0.7992	0.8004	0.8004
4	8,700	Sigmoid	0.8471	0.8471	0.8471	0.8448
		ReLU	0.8362	0.8454	0.8437	0.8448
5	8,618	Sigmoid	0.4887	0.4835	0.5450	0.4870
		ReLU	0.6111	0.4046	0.5926	0.5903

키워드 검색어별로 학습률에 따라 정확도는 40% 초반에서 80% 중반까지 값이 나오는 것을 알 수 있다.



[그림 4-17] 활성화 함수별 정확도 비교


[그림 4-17]은 각 데이터셋 별로 활성화 함수에 따른 정확도의 차이를 보여주는 그래프이다. 4가지 데이터셋에 있어서는 활성화 함수에 따른 큰 차이를 보이지 않고 있으나, 5번째 데이터셋의 경우 활성화 함수를 ReLU로 설정하였을 때가 sigmoid로 설정하였을 때보다 다소 높은 정확성을 보임을 알 수 있다.



[그림 4-18] 학습률별 정확도 비교

[그림 4-18]은 첫 번째 키워드의 학습률 별로 40 epoch까지의 정확도 값의 변화를 보여준다. 학습률을 0.0001 값으로 설정한 경우를 제외하면, 학습률을 일정 수치 이하로 설정하는 것으로 정확도에 큰 차이가 없는 것을 알 수 있다. [표 4-5]에서 알 수 있듯이 4가지 데이터셋에 있어서는 정확도는 큰 차이가 없다. 5번째 데이터셋의 경우 학습률이 0.1 값인 경우가 가장 높은 정확도를 보였으나 학습률을 다르게 설정한 결과와 크게 차이가 나는 것은 아니다. 학습률을 0.0001 값으로 설정한 경우 40회의 epoch까지는 충분한 정확도에 도달하지 못하였으나 100회의 epoch 실행시 다른 학습률 값으로 설정한 실험과 큰 차이를 보이지 않는다.

[그림 4-19]는 첫 번째 키워드의 학습률 별로 40 epoch까지의 손실값의 변화를 보여준다. 학습률을 0.0001로 한 경우를 제외하고는 손실값이 적절하게 감소하였다. 학습률을 0.0001 값으로 설정한 경우에도 100 epoch까지 진행하면 다른 값의 학습률로 설정하여 진행한 실험의 결과값과 큰 차이가 나지 않아 훈련이 적절하게 이루어지는 것을 확인할 수 있다.



[그림 4-19] 학습률별 손실값 비교

실험 결과 활성화 함수는 시그모이드보다 ReLU를 사용하는 것이 좋은 결과를 도출할 수 있었고, 학습률은 0.1에서 0.0001 사이 어떠한 값을 설정하더라도 비슷한 결과를 낸다는 것을 확인할 수 있었다. 예측의 정확도는 80%대로 90% 후반의 매우 높은 정확도를 보이는 진보된 인공지능 모델을 사용한 선행연구들에 비해 낮은 결과를 보이지만, 새로운 데이터셋을 활용한 연구라는 점에서 유의미한 실험 결과라고 할 수 있다.

나) 입찰가에 따른 클릭 수 추이 예측

입찰가에 따른 클릭 수 예측 방식은 크게 2가지 문제점을 가지고 있다. 하나는 데이터셋의 데이터들이 일정한 시간 간격으로 측정된 것이 아니기 때문에 발생하는 시간의 비균일성이고, 다른 하나는 입력값이 특정 값에 편중될 경우 예측 정확도가 높아도 왜곡될 가능성이 있다는 것이다. 이러한 문제를 극복하고 예측의 정확도를 높이기 위해 수치를 예측하는 것이 아니라 추이를 예측하는 분류 방법으로 변경하여 실험을 하였다.

(1) 실험 방법

실험을 위한 데이터는 입찰가에 따른 클릭 수 예측 모델과 동일한 데이터셋으로 준비하였으며, 추이를 예측하기 위해 추가로 데이터의 전처리 작업을 진행하였다. 기존 데이터셋은 입찰가 변경 시마다 데이터셋을 하나씩 생성하기 때문에 데이터셋 양은 많으나 각 데이터셋의 시간 간격이 일정하지 못하다. 이를 통일해주기 위하여 1시간 단위로 데이터를 병합하였다. 입찰가는 1시간 동안의 평균 입찰가로 설정하였고, 클릭 수는 1시간 동안의 모든 클릭 수를 합산하였다. 시간 데이터는 1~24의 값을 부여하여 원핫인코딩(One-Hot Encoding) 처리를 통해 원핫벡터(One-Hot vector) 값으로 변환하였다. 또한, 넓은 범위의 숫자를 예측하는 것이 아니라 다음 결과값의 추이를 예측하는 것이기 때문에 결과값으로 클릭 수가 이전 대비 증가하였는지, 감소하였는지, 유지되었는지에 대한 분류값으로 변경하였다. [그림 4-20]은 실험을 위한 데이터셋의 예제이다.

[	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	1.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	3.646667e+01	5.100000e+02	5.300000e+02	2.000000e+01	3.921568e-02]	
[	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	1.000000e+00	0.000000e+00	0.000000e+00
	1.823999e+02	5.300000e+02	5.100000e+02	-2.000000e+01	-3.773585e-02]	
[	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	1.000000e+00	0.000000e+00
	3.650000e+01	5.100000e+02	5.300000e+02	2.000000e+01	3.921568e-02]	
[	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	1.000000e+00
	7.293333e+01	5.300000e+02	5.100000e+02	-2.000000e+01	-3.773585e-02]	
[	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00
	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	1.000000e+00
	3.651666e+01	5.100000e+02	5.300000e+02	2.000000e+01	3.921568e-02]	

[그림 4-20] 데이터셋 예제

각 키워드 내용, 키워드 입찰가 변경 로그와 클릭 수의 성과 데이터셋은 [표 4-6]과 같다. 이전의 실험과 동일한 시스템 환경에서 실험을 진행하였으며, 데이터 전처리 과정에서 데이터셋의 수가 감소하였다. 이번 실험에서도 데이터셋은 트레이닝을 위하여 80%를 사용하고 테스트를 위하여 20%를 사용하였다.

[표 4-7] 키워드와 데이터셋 수

데이터셋 번호	키워드 검색어	데이터셋 수
1	여성속옷쇼핑몰	7,286
2	매직브라	7,088
3	여성속옷세트	6,562
4	20대여성속옷	7,289
5	브라팬티	6,644

인공지능 모델링과 설정은 [표 4-8]과 같다. 분류(Classification)의 결과값을 출력하기 때문에 마지막 노드의 활성화 함수는 소프트맥스(Softmax)를 사용하고, 손실함수 역시 분류 문제에 적합한 다중 분류 손실함수(Categorical Crossentropy)를 사용하였다. 모델링 설정의 변화에 따른 정확도를 비교하기 위하여 노드카운트(Node count)를 256과 512로 설정하여 차이를 비교하였고, 배치사이즈(Batch size)도 32와 64로 설정하여 차이를 비교하였다. 학습률은 0.001과 0.0001로 설정하여 차이를 비교하였다. 검증데이터의 손실값을 모니터링하여 성능이 증가되지 않으면 중지하도록 설정하였다.

[표 4-8] 인공지능 모델 환경


구분	내용
AI모델	DNN : 히든레이어3개
노드카운트	256 / 512
배치사이즈	32 / 64
Dropout	20%
최적화 알고리즘	Adam
활성화 함수	소프트맥스(Softmax)
학습률	0.001 / 0.0001
손실함수	다중 분류 손실함수(Categorical Crossentropy)
Epoch수	100

(2) 실험 결과

키워드 별로 학습률과 배치사이즈, 노드 카운트를 변경하여 실험하였으며, 실험 결과로 나온 정확도(Accuracy)는 [표 4-8]에 정리하였다. 키워드 검색어별로 조건에 따라 정확도는 50% 후반에서 80% 후반까지 값이 나오는 것을 알 수 있다.


[표 4-9] 조건별 정확도

데이터셋 번호	node count	batch size	accuracy
1	256	32	0.8470
		64	0.8461
	512	32	0.8450
		64	0.8465
2	256	32	0.8272
		64	0.8271
	512	32	0.8463
		64	0.8262
3	256	32	0.8426
		64	0.8435
	512	32	0.8420
		64	0.8434
4	256	32	0.8968
		64	0.8976
	512	32	0.8977
		64	0.8968
5	256	32	0.5999
		64	0.5673
	512	32	0.5772
		64	0.5647



[그림 4-21] 첫 번째 데이터셋 조건별 정확도 비교

[그림 4-21]은 첫 번째 키워드의 노드 카운트 수와 배치사이즈별로 40 epoch까지의 정확도 값의 변화를 보여준다. 모든 조합의 결과값이 큰 차이나지 않아 실험을 위한 데이터셋이 노드 카운트 수와 배치사이즈에 큰 영향을 받지 않는다는 것을 알 수 있다. 정확도 향상을 위해서는 순위나 경쟁키워드 등 환경 변수의 추가가 필요할 것으로 보인다. 첫 번째 키워드의 실험 결과 정확도는 80%대 중반으로 실제로 적용하여 자동운영 시스템을 운영하기에는 충분한 결과는 아니며, 결정을 위한 참고 데이터로 제시하는 가능할 것으로 판단된다.




[그림 4-22] 데이터셋별 정확도 비교

[그림 4-22]은 각 키워드 별로 정확도를 비교한 그래프이다. 4번째 키워드는 80% 후반의 정확도를 보였으며, 5번째 키워드는 50% 후반의 정확도를 보였다. 나머지 3개의 키워드는 80% 중반의 정확도를 보였다. 이를 통해 키워드 별로 정확도의 차이가 크게 나는 것을 확인할 수 있으며, 추후 더 많은 키워드를 실험하여 차이가 나는 이유와 정확도가 낮은 키워드의 특징을 파악하는 것이 필요하다. 아울러 정확도를 높이기 위한 추가 연구도 필요하다.

다) 입찰가에 따른 클릭 수 예측 모델과 클릭 수 추이 예측 모델 비교

본 연구에서는 인공지능을 활용하여 네이버 키워드 검색 광고의 예측 모델을 두 가지로 제안하였다. 하나는 광고 입찰가를 통해 클릭 수를 예측하는 모델이며, 다른 하나는 이전 클릭 수 대비 증감을 통해 클릭 추이를 예측하는 모델이다. 일반적으로 클릭 추이를 예측하는 모델의 성능이 좋을 것으로 기대되는데, 동일한 조건에서 클릭 수 예측은 클릭 수가 0부터 10 이상의 10개가

넘는 결과값을 예측하는 것인데 비해 클릭 추이 예측은 3가지로 분류하는 예측이기 때문이다.



[그림 4-23] 두 가지 모델의 정확도 비교

[그림 4-23]은 두 가지 예측모델의 정확도를 비교한 그래프이다. 실험 결과에서도 모든 키워드에서 클릭 추이를 예측한 경우가 더 높은 정확도를 보임을 알 수 있다. 실제 산업에 적용할 때에도 클릭 수를 예측할 경우의 난이도가 더 높다고 할 수 있다. 예측 결과값의 절대값에 따라 광고비 입찰가를 어떤 기준으로 결정할 것인가에 대한 추가 연구가 필요하기 때문이다. 예를 들어 입찰가가 100원일 때 예측 클릭 수가 3인 경우와 입찰가가 150원일 때 예측 클릭 수가 4인 경우 어느 입찰가가 더 높은 성과를 추구할 수 있는가에 대한 결정을 위한 추가 연구가 필요한 것이다. 그에 반해 추이를 예측하는 경우 기존 성과보다 개선될 것으로 예측되는 입찰가 중 최저가를 선택하는 것을 반복하는 것으로 지속적인 성과 향상을 추구할 수 있다.

제 3 절 연구의 성과

1) 온라인 광고 자동운영 시스템 활용의 일반적 기대 효과

본 연구에서 제안하는 온라인 광고 자동운영 시스템을 통해 크게 3가지 효과를 기대할 수 있다.

가) 인적 리소스 감소

온라인 광고 자동운영 시스템을 통해 기대할 수 있는 가장 큰 효과는 인적 리소스 감소이다. 마케터의 업무시간 중 가장 많은 시간을 차지하는 업무는 광고 성과분석 보고서 작성이다. 온라인 광고 성과분석 시스템은 성과 보고서 작성이 불필요하여 마케터의 업무시간을 크게 단축시켜줄 수 있다. 또한, 광고 성과를 파악한 후 광고매체마다 접속하여 작업해야 했던 광고 운영 작업을 한 번의 접속 환경 하에서 일괄 처리가 가능하고, 자동으로도 운영이 가능하기 때문에 마케터의 업무시간을 추가로 단축시켜줄 수 있다. 온라인 광고 자동운영 시스템 도입으로 인적 리소스를 상당 부분 감소시킬 수 있을 것으로 기대할 수 있다.

나) 불가능한 광고 운영 처리

온라인 광고 운영작업을 상세하게 살펴보면, 세밀한 운영작업을 위해 광고 소재 하나하나의 성과를 확인해야 하고, 광고의 운영 성과에 따라 광고 운영 작업인 광고비 입찰가를 증액하는 절차는 광고매체에 따라 적게는 3개의 웹 페이지, 많게는 8개의 웹페이지를 거쳐야 한다. 하나의 광고 소재의 성과를 확인하고, 해당 광고 소재의 운영작업을 하는 것으로도 상당한 처리 시간이 필요하다는 것이다. 온라인 쇼핑몰과 같이 광고 소재가 많은 광고주의 광고 운영은 광고 소재 별로 광고 성과를 확인하고 성과를 반영하여 광고 운영을 한다는 것은 이런 점에서 불가능하다. 온라인 쇼핑몰이 아니어도 키워드 검색

광고의 경우 주요 검색 키워드뿐만 아니라 연관 검색어, 검색어의 조합 등으로 수백 개에서 수천 개의 키워드가 광고 소재로 동시에 운영된다. 온라인 쇼핑몰에 비하여 적은 수의 광고 소재이지만, 이 역시 실시간으로 각 소재의 광고 성과를 확인하고 운영하는 것은 인적 리소스 투입만으로는 불가능하다.

본 연구에서 제안하는 온라인 광고 자동운영 시스템은 운영 규칙이 사전에 설정된 규칙이거나 인공지능을 통한 예측을 활용하거나 등의 방법과 관계 없이 수백만 개가 넘는 수의 광고 소재라도 실시간으로 개별 광고 소재의 광고 운영 성과를 확인하고, 성과에 따른 운영작업 역시 실시간으로 처리가 가능하다. 온라인 광고 자동운영 시스템 도입을 통해 사람이 할 수 없었던 세밀한 광고 운영작업이 가능하게 될 것으로 기대할 수 있다.

다) 광고 성과 향상

온라인 광고의 성과를 향상시키기 위한 광고 운영 방법은 기존 성과를 참고하여 입찰가를 조정하는 것이다. 광고 소재가 이전 광고 운영 성과를 고려할 때 더 많은 광고비를 집행하여 성과를 극대화하는 것이 좋을지, 광고비를 축소하여 광고비의 낭비를 막고 절감된 광고비를 성과가 좋은 광고 소재의 추가 광고비로 소진할지를 결정하고 실시간으로 운영을 할 수 있다면 광고의 전체 성과는 상승하게 된다. 온라인 광고 자동운영 시스템은 그러한 목적에 부합하게 구현되어 실제 산업에 적용할 경우 온라인 광고의 성과 향상을 기대할 수 있다.

2) 온라인 광고 자동운영 시스템 활용의 시사점

가) 페이스북 카탈로그 광고 자동운영 시스템

온라인 쇼핑몰은 24시간 운영이 되며, 상품의 상태가 지속적으로 변한다. 그러나 마케터가 24시간 내내 직접 쇼핑몰 내 상품들의 상태 변화를 감지하여 광고 소재를 업데이트하는 것은 불가능한 일이다. 본 연구에서는 인터넷

쇼핑몰이 페이스북 카탈로그 광고에 사용하는 광고 소재 세트 내 광고 소재를 쇼핑몰 내 상품의 상태에 따라 자동으로 업데이트하는 프로그램을 제안하고, 제안하는 프로그램을 활용하여 광고 운영을 자동화하는 방식과 기존 광고 운영 방식의 광고 성과 차이를 실제로 광고비를 집행하여 운영하며 비교하는 실험을 진행하였다. 실험 결과 본 연구에서 제안하는 광고 운영 자동화 프로그램을 통한 광고 운영이 기존 광고 운영 방식에 비하여 광고 성과가 월등히 좋은 것을 확인할 수 있었다. 본 연구에서 제안하는 알고리즘을 활용하여 자동화 프로그램을 사용하는 것으로 광고비의 낭비를 막고, 효율이 높은 광고 운영이 가능하게 될 것이다.

나) 전환 목적 네이버 검색 광고 자동운영 시스템

본 연구에서는 그동안 관리되지 않은 광고 비용의 누수율에 대한 아이디어를 제안하고 이를 중대형 쇼핑몰의 실제 광고 운영을 통해 실험을 진행되었다. 그 결과 누수율을 낮추기 위한 관리만으로 광고 비용을 높이지 않고도 매출이 증가하는 것으로 확인되었다. 이를 통해 온라인 광고 운영 성과의 새로운 지표로서 누수율이 유효함을 확인할 수 있었으며, 누수율 관리를 통해 광고 성과 향상을 기대할 수 있게 될 것이다.

다) 유입 목적 네이버 검색 광고 자동운영 시스템

본 연구에서는 강화된 개인정보보호 정책에 따라 사용자 정보 이외의 정보인 입찰가 변경 정보를 이용하여 검색 광고 성과 중 클릭을 통한 방문자수를 예측하는 프로그램을 설계하고, 실제 운영 데이터를 활용하여 실험하였다. 그 결과 일부 키워드에서는 약 60% 정도로 예측 정확성이 상대적으로 떨어지는 결과를 보였으나 대부분의 키워드에서는 80% 이상의 예측 정확성을 보여 유의미한 결과가 나오는 것을 확인할 수 있었다. 실험 결과의 예측 정확성은 온라인 광고 자동운영에 적용하기에 충분히 높지 않으나, 온라인 광고 수동운영 시 참고값으로 활용 가능한 수준이다. 여러 발전된 인공지능 모

델링 기법을 사용한 기존의 연구들이 90% 이상의 예측 정확성을 보이는 것에 비해 성능이 낮은 결과를 보였지만, 개인정보나 컨텍스트 정보를 사용하지 않고 운영작업 로그만으로 예측을 시도했다는 점에서 의미 있는 연구라고 할 수 있다. 이와 같은 연구를 실제 산업에 적용 시, 방문자 수를 늘리기 위해 키워드마다 현재 광고비를 유지하는 것이 좋을지, 높이는 것이 좋을지, 낮추는 것이 좋을지에 대한 예측 데이터를 제공하여 광고비 변경 전략에 도움을 줄 수 있게 된다.

제 5 장 결론

전 세계 온라인 광고 산업은 지속적으로 성장하고 있다. 온라인 광고의 성과를 극대화하기 위한 연구도 지속적으로 이루어지고 있다. 본 연구에서는 이러한 연구의 일환으로 온라인 광고 성과분석 시스템과 온라인 광고 자동운영 시스템을 제안하고 구현하였다. 구현된 시스템의 성능 실험을 통해 유의미한 결과를 도출하여 제안한 온라인 광고 자동운영 시스템의 활용 가능성을 확인하였다. 온라인 광고 자동운영 시스템을 실제 광고 산업에 도입함으로써 마케터의 인적 리소스 낭비를 줄이고, 효율적인 광고비 집행 유도를 통해 광고 성과를 높이는 것이 가능할 것이다.

본 연구에서는 세 가지 자동운영 방법을 제시하였다. 페이스북의 디스플레이 광고 자동운영은 광고 소재를 자동으로 업데이트 하는 것으로 광고주의 광고비 낭비를 줄일 수 있다는 것을 확인하였고, 실제 광고 산업에 바로 적용이 가능하다. 향후 성능의 개선을 위해서는 광고 소재 이미지에 대한 추가 연구가 필요하다. 광고 소재로 활용되는 이미지는 상품의 대표 이미지를 추출하여 생성한다. 이미지로 된 광고 소재는 페이스북뿐만 아니라 다양한 광고매체의 디스플레이 광고에 사용될 수 있다. 이때, 각 광고매체에서 요구하는 이미지 크기로 변환이 필요하며, 자동으로 이미지를 변환하거나 이미지의 일부분을 잘라낼 때 인공지능을 활용할 수 있다. 본 연구에서는 페이스북 카탈로그 광고에 한하여 자동운영 기능을 구현하였기 때문에 추가로 이미지 변환에 대한 연구는 진행하지 않았으며, 광고 소재로 사용되는 이미지가 적절하지 않은 경우 페이스북에서 사전 검열을 통해 제외하기 때문에 잘못된 이미지가 광고 소재로 사용되어 광고주의 광고비를 낭비하는 상황은 발생하지 않는다. 향후, 광고 소재로 대표 이미지뿐만 아니라 상품 상세 설명 페이지에 사용되는 이미지 중에서 광고 성과가 가장 잘 나올 것으로 예측되는 이미지를 선택하기 위한 인공지능 연구가 추가로 필요하다.

두 번째로 전환을 목적으로 하는 네이버 키워드 검색 광고의 자동운영 방법으로 누수율이라는 새로운 온라인 광고 성과지표를 제시하였다. 누수율 관

리를 통하여 광고의 성과가 향상되는 것을 확인하였으며, 이 방법 또한 실제 광고 산업에 바로 적용이 가능하다. 실험을 위해 사전 조사한 온라인 패션 쇼핑몰 중에는 ROAS가 220%였으며, 전체 키워드 2,695개 중 9개의 키워드에서 매출의 80%가 발생하는 사례가 있었다. 이 경우는 누수율이 85%에 달하였으며, 누수율 관리를 통하여 광고비를 50%로 낮춰도 매출의 변화가 거의 없게 되고, 이렇게 절감한 광고비를 주요 키워드에 사용할 경우 매출이 큰 폭으로 상승하는 결과를 확인할 수 있게 된다. 다만, 해당 업체의 경우 주요 키워드 9개 중에도 누수율 관리 기준에 못 미치는 키워드가 있을 경우 광고비 감소가 자칫 총 매출의 급격한 감소를 유발하여 왜곡된 데이터가 나올 수 있기 때문에 실험 대상군에 포함하지는 않았다. 이와 같이 모든 상황에서 동일한 기준을 적용할 수는 없어 이와 관련된 표준화 연구가 필요하다. 본 연구에서 제시하는 자동운영 방법에 대한 실험은 중대형 온라인 쇼핑몰을 대상으로 진행되었다. 작은 쇼핑몰에서는 광고 실적이 높지 않고 운영되는 검색 키워드의 수가 상대적으로 적다. 따라서 동일한 규칙을 적용하면 결과가 달라질 수 있다. 쇼핑몰의 크기에 따라 누출 비율이 ROAS의 몇 퍼센트로 설정되었는지 여부를 확인하려면 추가 조사가 필요하다. 또한, 이 실험에 적용된 쇼핑몰과 달리 구매 전환으로 인해 수량적 지표가 확인되지 않은 광고주의 광고를 검색하기 위해 ROAS 이외의 지표로 누수 비율의 기준을 설정해야 하는가에 대한 연구도 추가로 필요하다.

이와 같이 인공지능을 활용하지 않고 사전 설정된 규칙에 의해 자동으로 운영하는 방법도 실제로 성과의 향상을 확인할 수 있었다. 그러나 빠르게 변화하는 온라인 광고의 변화를 따라가며 지속적인 업데이트를 해야 하며, 일부 성과에 대하여는 통계적 분석을 통하여 규칙을 수립할 수 있으나 너무 많은 외적 변수에 의해 대부분 통계적 분석이 어려운 경우가 많아 인공지능을 도입하는 것이 바람직하다고 판단된다.

마지막으로 유입을 목적으로 하는 네이버 키워드 검색 광고의 자동운영 방법으로 인공지능을 도입하여 방문자 수와 방문자 수의 추이를 예측하는 방법을 제시하였다. 방문자 수 예측과 방문자 수의 추이를 예측하는 방법을 각기 다르게 구현하여 실험하였으며, 80%대의 예측 정확도를 확인할 수 있었

다. 온라인 광고 운영에 인공지능을 활용하기 위한 연구는 활발하게 진행되어 왔다. 기존의 인공지능을 활용한 클릭률 예측은 인공지능 모델에 따라 90%대 후반의 높은 정확도를 보인다. 그러나 기존의 연구는 모두 개인정보를 활용하기 때문에 전 세계적으로 개인정보가 강화되고 있는 현재의 시점에서 실제 산업에 활용하기가 어렵다. 본 연구에서 제안하는 방식은 정확도가 80%대 중 후반으로 기존 연구에 비해 정확도가 다소 낮으나 개인정보를 활용하지 않는다는 점에서 실제 산업에 활용 가능성이 높다. 그러나 광고주의 광고비가 실제로 소진되는 것을 고려할 때 충분히 높은 정확도는 아니며, 예측 오류에 대한 회피 방법도 미흡한 상황이다. 따라서 추가 연구를 통해 예측의 정확도를 높이고, 예측값의 변동성이 크거나 광고비가 과다하게 집행될 소지가 있을 때 광고를 운영하는 마케터의 확인 절차를 추가하는 등의 방법이 필요하다.

인공지능의 도입 초창기에는 다양한 인공지능 모델 연구가 부족했고, 예측값의 정확도도 높지 않았다. 현재는 다양한 인공지능 모델 연구가 진행되어왔고, 분야에 따라 높은 예측값을 보이는 연구들도 많기 때문에 본 연구에서 제안하는 방법도 추가 연구를 통하여 빠르게 정확도를 높여 실 산업에 적용하는 것이 가능할 것으로 예측하고 있다. 앞으로 다른 구성의 데이터셋과 다양한 인공지능 모델링의 적용을 통해 향상된 성능을 보이는 연구가 계속되기를 기대한다. 향후 추가 연구를 통해 실험 데이터의 다양화와 인공지능 모델링 개선, 하이퍼파라미터 변경 등을 통해 정확도를 높일 수 있다면, 실 산업에서도 활용할 수 있을 것으로 기대가 된다. 이를 통해 광고주의 광고비를 낭비하지 않고, 높은 효율의 광고비 운영이 가능해질 것이다.

참 고 문 헌

1. 국내문헌

- 강창완, 최승배, 박현정. (2020). 시계열 예측을 위한 인공신경망의 입력노드 수 결정. *Journal of The Korean Data Analysis Society*, 22(3), pp. 1055-1065.
- 김경훈. (2016). 성공하는 모바일 광고의 특징. 『동아 비즈니스 리뷰』, 11(2).
- 김도연, 임규건, 이대철. (2011). 키워드 검색 광고 운영 DB 데이터 분석을 통한 CPM 와 CPC 방식의 광고효과 연구. 『한국전자거래학회지』, 16(4), pp. 139-154.
- 김도형, 김태성, 박준규. (2017). 머신러닝을 이용한 키워드 광고 입찰가격 예측 모델에 관한 연구. 『한국정보과학회 학술발표논문집』, pp. 1910-1913.
- 김정국, 이상원, 최동운. (2016). 전자상거래에서 온라인 광고와 매출의 관련성 분석(Relevance Analysis of Online Advertisement and e-Commerce Sales). 『한국엔터테인먼트산업학회논문지』, 10(2), pp. 27-35.
- 김준기, 조완현, 나명환, 전명희. (2019). 영상처리와 딥러닝 기법을 사용한 채소의 등급별 자동 분류시스템 개발. *Journal of The Korean Data Analysis Society*, 21(1), pp. 63-73.
- 김태석. (2020). CNN을 활용한 CTR 예측 시각화 분석. *Journal of The Korean Data Analysis Society (JKDAS)*, 22, pp. 2603-2614.
- 네이버 검색 광고 센터. <https://searchad.naver.com/>.
- 딥러닝, 손실함수, 평균제곱오차(MSE). <https://gooopy.tistory.com/61>.
- 백광일, 강창완, 최승배, 김규곤. (2016). 신경망모형을 이용한 민간아파트 분

- 양가격 보조지표에 관한 연구. *Journal of The Korean Data Analysis Society*, 18(3), pp. 1367-1376.
- 백지오. (2020). Convexity와 딥러닝(Convex Function과 Convex Set). <https://skyil.tistory.com/33>.
- 손미영. (2020). 소자본 온라인 패션쇼핑몰 운영 사례 연구 - 4P mix 중심으로 -. 『복식』, 70(2), pp. 117-134.
- 오창우. (2008). 인터넷 검색광고 요금체계의 특징 및 부정클릭 유형에 관한 연구. 『광고학연구』, 19(4), pp. 7-27.
- 유원준 et al. (2021). 딥러닝을 이용한 자연어 처리 입문.
- 유원준. 딥러닝을 이용한 자연어 처리 입문. <https://wikidocs.net/24987>.
- 이강희. (2020). 활성화 함수(Activation Function) 종류 및 정리. <https://ganghee-lee.tistory.com/32>.
- 이슬전. (2021). 소프트웨어와 융합하는 전자상거래 시장 동향. 『월간 SW 중심사회』, pp. 14-23.
- 이정우, 김승천. (2021). ANN를 활용한 입찰가 변경 데이터 기반 키워드 검색광고 성과 예측방법. 『전자공학회논문지』.
- 이정우, 김승천. (2021). 국내 패션 이커머스 사업자의 디스플레이 광고 실적 개선을 위한 자동 광고 운영 기법. 『전자공학회논문지』, 58(10), pp. 35-41.
- 이철, 이경전. (2008). Cost-Per-Action 광고 방법을 이용한 Conversion Action Data 메커니즘의 평가. *Information Systems Review*, 10(2), pp. 123-135.
- 장규리. (2020). 딥러닝을 이용한 키워드 목표 순위를 위한 최소 낙찰가 예측 / Prediction for Suggesting Minimum Bidding Price of Keyword Using Deep Learning. 『경상대학교 대학원』.
- 정문성, 손방용. (2018). 컨볼루션 신경망을 기반으로 한 한글 음악 리뷰 감

- 정 분류 모델 설계 및 분석. *Journal of The Korean Data Analysis Society*, 20(4), pp. 1863-1871.
- 지민준, 박현희. (2018). TensorFlow를 활용한 검색 키워드의 최적 순위 예측 알고리즘. 『한국통신학회논문지』, 43(8), pp. 1347-1356.
- 최예림, 김관호. (2016). 인공지능 개요 및 적용 사례. 『ie 매거진』, 23(2), pp. 23-29.
- 페이스북 비즈니스 고객센터. Apple iOS 14 릴리스용 보고서 업데이트. <https://www.facebook.com/business/help/584603712214119?id=428636648170202>.
- 페이스북 비즈니스 관리자. <https://business.facebook.com/>.
- 한국방송온라인 광고진흥공사. (2018). 『2018년 방송통신온라인 광고비 조사』.
- Facebook. 광고 품질 및 성과 개선을 위해 피해야 할 광고 속성 <https://ko-kr.facebook.com/business/help/1767120243598011>
- Facebook. (2015). Drive Conversions on Every Device with Dynamic Product Ads. *Facebook for Business*.
- facebook. facebook Pixel. <https://developers.facebook.com/docs/facebook-pixel/get-started/>.
- Kim, M. S., Lee, J. K., Choi, Y. H., Kim, S. H., Jeong, K. W., Kim, K. L., & Lee, S. S. (2020). A Study on the Optimal Setting of Large Uncharged Hole Boring Machine for Reducing Blast-induced Vibration using Deep Learning. *Explosives and Blasting*, 38(4), pp. 16-25.
- Korea Internet & Security Agency. (2017). Online advertising industry trend research and analysis.
- NAVER Corp. NAVER AD SERVICES. <https://saedu.naver.com/adguide/eng.nhn>.

2. 국외문헌

- Agarap, A. F. (2018). Deep learning using rectified linear units (relu).
- Aguilar, J., & Garcia, G. (2017). An adaptive intelligent management system of advertising for social networks: A case study of Facebook. *IEEE Transactions on Computational Social Systems*, 5(1), pp. 20–32.
- An, W., Wang, H., Zhang, Y., & Dai, Q. (2017). Exponential decay sine wave learning rate for fast deep neural network training. In *2017 IEEE Visual Communications and Image Processing (VCIP)*, pp. 1–4.
- Asadi, B., & Jiang, H. (2020). On approximation capabilities of ReLU activation and softmax output layer in neural networks.
- Bengio, Y., Ducharme, R., Vincent, P., & Janvin, C. (2003). A neural probabilistic language model. *The journal of machine learning research*, 3, pp. 1137–1155.
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of machine learning research*, 13(2).
- Bergstra, J., Bardenet, R., Bengio, Y., & Kégl, B. (2011). Algorithms for hyper-parameter optimization. *Advances in neural information processing systems*, 24.
- Cheng, H. T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., & Shah, H. (2016). Wide & deep learning for recommender systems. In *Proceedings of the 1st workshop on deep learning for recommender systems*, pp. 7–10.
- Cho, K., Van Merriënboer, B., Bahdanau, D., & Bengio, Y. (2014). On

the properties of neural machine translation: Encoder–decoder approaches.

- Chrupała, G., Kádár, A., & Alishahi, A. (2015). Learning language through pictures.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2015). Gated feedback recurrent neural networks. In *International conference on machine learning*, pp. 2067–2075.
- Clevert, D. A., Unterthiner, T., & Hochreiter, S. (2015). Fast and accurate deep network learning by exponential linear units (elus).
- Dozat, T. (2016). Incorporating nesterov momentum into adam.
- Dubey, A. K., & Jain, V. (2019). Comparative study of convolution neural network’s relu and leaky-relu activation functions. In *Applications of Computing, Automation and Wireless Systems in Electrical Engineering*, pp. 873–880
- Duchi, J., Hazan, E., & Singer, Y. (2011). Adaptive subgradient methods for online learning and stochastic optimization. *Journal of machine learning research*, 12(7), pp. 2121–2159.
- Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. In *Automated machine learning*, pp. 3–33.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Guo, H., Tang, R., Ye, Y., Li, Z., & He, X. (2017). DeepFM: a factorization–machine based neural network for CTR prediction.

- Hand, D. J., & Yu, K. (2001). Idiot's Bayes—not so stupid after all?. *International statistical review*, 69(3), pp. 385–398.
- Hinton, G., Srivastava, N., & Swersky, K. (2012). Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. *Cited on*, 14(8), 2.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), pp. 1735–1780.
- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), pp. 31–44.
- Joydeep Bhattacharya. 9 Rules for Creating Ads that Convert.
<https://www.singlegrain.com/pay-per-click-2/9-rules-for-ads-that-convert/>
- Jozefowicz, R., Zaremba, W., & Sutskever, I. (2015). An empirical exploration of Recurrent Network architectures. in *32nd International Conference on Machine Learning, ICML 2015*, 3, pp. 2332–2340.
- Juan, Y., Lefortier, D., & Chapelle, O. (2017). Field-aware factorization machines in a real-world online advertising system. In *Proceedings of the 26th International Conference on World Wide Web Companion*, pp. 680–688.
- Karlik, B., & Olgac, A. V. (2011). Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4), pp. 111–122.
- Khan, Z., Khan, S. M., Dey, K., & Chowdhury, M. (2019). Development and evaluation of recurrent neural network-based models for

- hourly traffic volume and annual average daily traffic prediction. *Transportation Research Record*, 2673(7), pp. 489–503.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, pp. 1097–1105.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), pp. 2278–2324.
- Lee, Jung-Woo, et al. (2019). A study of Leakage Ratio for increasing performance of online keyword search advertising. *Restaurant Business*, 118(8), pp. 308–314.
- Li, T., & Lee, K. J. (2008). Evaluation of Conversion Action Data Mechanisms in Cost-Per-Action Advertising. *Information Systems Review*, 10(2), pp. 123–135.
- Lian, J., Zhou, X., Zhang, F., Chen, Z., Xie, X., & Sun, G. (2018). xdeepfm: Combining explicit and implicit feature interactions for recommender systems. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp. 1754–1763.
- Liu, B., Tang, R., Chen, Y., Yu, J., Guo, H., & Zhang, Y. (2019). Feature generation by convolutional neural network for click-through rate prediction. In *The World Wide Web Conference*, pp. 1119–1129.
- Liu, Q., Yu, F., Wu, S., & Wang, L. (2015). A convolutional click

- prediction model. In *Proceedings of the 24th ACM international on conference on information and knowledge management*, pp. 1743–1746.
- Lu, L., Shin, Y., Su, Y., & Karniadakis, G. E. (2019). Dying relu and initialization: Theory and numerical examples.
- McMahan, H. B., Holt, G., Sculley, D., Young, M., Ebner, D., Grady, J., & Kubica, J. (2013). Ad click prediction: a view from the trenches. In *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 1222–1230.
- Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural networks*, 12(1), pp. 145–151.
- Qu, Y., Cai, H., Ren, K., Zhang, W., Yu, Y., Wen, Y., & Wang, J. (2016). Product-based neural networks for user response prediction. In *2016 IEEE 16th International Conference on Data Mining (ICDM)*, pp. 1149–1154.
- Qu, Y., Fang, B., Zhang, W., Tang, R., Niu, M., Guo, H., & He, X. (2018). Product-based neural networks for user response prediction over multi-field categorical data. *ACM Transactions on Information Systems (TOIS)*, 37(1), pp. 1–35.
- Rendle, S. (2010). Factorization machines. In *2010 IEEE International conference on data mining*, pp. 995–1000.
- Richardson, M., Dominowska, E., & Ragno, R. (2007). Predicting clicks: estimating the click-through rate for new ads. In *Proceedings of the 16th international conference on World Wide Web*, pp. 521–530.

- Robbins, H., & Monro, S. (1951). A stochastic approximation method. *The annals of mathematical statistics*, pp. 400–407.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), pp. 533–536.
- Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *towards data science*, 6(12), pp. 310–316.
- Sibi, P., Jones, S. A., & Siddarth, P. (2013). Analysis of different activation functions using back propagation neural networks. *Journal of theoretical and applied information technology*, 47(3), pp. 1264–1268.
- Smith, S. L., Kindermans, P. J., Ying, C., & Le, Q. V. (2017). Don't decay the learning rate, increase the batch size.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), pp. 1929–1958.
- Srivastava, R. K., Greff, K., & Schmidhuber, J. (2015). Highway networks.
- Stanford University. Convolutional Neural Networks for Visual Recognition. <https://cs231n.github.io/convolutional-networks/>.
- Vaver, J., & Koehler, J. (2011). Measuring ad effectiveness using geo experiments. *Work. Paper*, pp. 1–8.
- Wang, R., Fu, B., Fu, G., & Wang, M. (2017). Deep & cross network

- for ad click predictions. In *Proceedings of the ADKDD'17*, pp. 1–7.
- Ward, R., Wu, X., & Bottou, L. (2019). AdaGrad stepsizes: Sharp convergence over nonconvex landscapes. In *International Conference on Machine Learning*, pp. 6677–6686.
- Xu, D., Zhang, S., Zhang, H., & Mandic, D. P. (2021). Convergence of the rmsprop deep learning method with penalty for nonconvex optimization. *Neural Networks*, 139, pp. 17–23.
- Ying, X. (2019). An overview of overfitting and its solutions. In *Journal of Physics: Conference Series*, 1168(2), p. 022022.
- You, K., Long, M., Wang, J., & Jordan, M. I. (2019). How does learning rate decay help modern neural networks?
- Zeiler, M. D. (2012). Adadelat: an adaptive learning rate method.
- ZenithOptimedia. (2020). Advertising Expenditure Forecasts.
- Zhang, W., Du, T., & Wang, J. (2016). Deep learning over multi-field categorical data. In *European conference on information retrieval*, pp. 45–57.
- Zhang, Z., & Sabuncu, M. R. (2018). Generalized cross entropy loss for training deep neural networks with noisy labels. In *32nd Conference on Neural Information Processing Systems (NeurIPS)*.
- Zhou, X., & Shi, Y. (2020). DeepFaFM: A Field-array Factorization Machine based Neural Network for CTR Prediction. In *2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, 1, pp. 2559–2563.
- Zou, F., Shen, L., Jie, Z., Zhang, W., & Liu, W. (2019). A sufficient condition for convergences of adam and rmsprop. In *Proceedings*

of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 11127–11135.

ABSTRACT

An Improvement Scheme of Online Advertising Performance using Artificial Intelligence

- Focusing on Naver Keyword Search Ads and Facebook
Display Ads -

Lee, Jung-Woo

Major in Smart Convergence Product

Dept. of Smart Convergence Consulting

The Graduate School

Hansung University

Since online advertising sales volume surpassed TV advertising in 2012, the online advertising market has been continuously growing. The e-commerce market, that is, the online shopping mall industry, which is growing as much as online advertising, is an area that is highly dependent on online advertising. Online advertising operation to improve the performance of online advertising is experiencing difficulties due to difficulties in checking advertising performance and managing too many advertising creatives. In addition, the reduction of online advertising performance due to the policy to strengthen personal information protection in the global market is also a big problem. The ideal online

advertising operation method to improve the performance of online advertising is to check the advertising performance in real-time in units of advertising creatives and execute advertising operation tasks according to the performance. In reality, it is impossible to implement with human resources, so automation is required.

In this study, I proposed and implemented an online advertising performance analysis system with a structure that can collect and reprocess data flexibly for the automation of online advertising operations. In addition, based on the data analyzed in the online advertising performance analysis system, four methods of an online advertising automatic operation system that can improve advertising performance were presented and implemented, and then a performance test was conducted. First, the Facebook catalog advertising automatic operation system is a method to prevent wastage of advertising costs and improve performance by updating the advertising creatives registered in the advertising media by reflecting the advertising product status of the advertiser site. The experiment was conducted as an operation experiment in which the advertising creatives of the advertising media are automatically updated according to the product status of the advertiser's site every hour which medium and large size Internet shopping malls with annual sales of KRW 10 billion or more. It was confirmed that the performance of the operation was greatly improved through the method proposed in the study. Second, the automatic operation for the purpose of conversion among the Naver search advertising automatic operation systems is a method to prevent wastage of advertising costs and improve performance by managing the Leakage Ratio, which is a new advertising performance indicator. The experiment was conducted on search keywords of medium and large size Internet shopping malls with annual sales of more than KRW 10 billion, adjusting bids based on existing

performance on a daily basis to manage Leakage Ratio and comparing changes in advertising sales performance. Through the experiment, it was confirmed that the waste of advertising expenses was reduced by managing the Leakage Ratio and the sales through advertising increased. Third, the automatic operation for the purpose of visit among the Naver search advertising automatic operation system is divided into the method of predicting the number of visitors and the method of predicting the trend of visitors. The method of predicting the number of visitors is predicted by using the advertising cost for each search keyword as an input value. For the experiment, AI training data was created based on the operational data and performance data of search keywords for a year, and an AI model was implemented to compare the accuracy of predicting the number of visitors. Fourth, the method of predicting the visitor trend is a method of predicting the increase or decrease of the visitor by using the advertising cost for each search keyword as an input value. The biggest difference from the method of predicting the number of visitors is that it does not predict a wide range of visitor numbers but only predicts three trends. The experiment is similar to the experiment for predicting the number of visitors, but an experiment was conducted to compare the accuracy of visitor trend prediction by changing the AI modeling and implementing it. The prediction accuracy as a result of the third and fourth experiment is under 90%, which is not high compared to the previous studies, but it can be applied to the actual industry as a reference for the manual operation of online advertising.

When the automatic online advertisement operation methods proposed in this study are applied to actual industries, it is possible to reduce human resources, and enable ideal advertising operation methods that were not previously possible, and through this, the effect of improving advertising performance can be expected. The prediction method through

AI can also directly help with the advertising cost planning strategy of manually operated online advertising. Through these advertising operation methods, it will be possible to operate advertising that can increase advertising performance without wasting the advertising costs of advertisers.

【Key word】 Online Advertising, Online Advertising Performance, Online Advertising Auto Operation, Performance Marketing, Artificial Intelligence