

# KAKAO

## AI

AI CODE

```
public class ItemSimilarityExecutor extends HadoopExecutableService {
```

public int execute(EntityMap args) throws Exception {  
 String[] opts = new String[] {  
 "--similarityClassname", similarity.name(),  
 "--maxSimilaritiesPerItem", Integer.toString(maxSimilaritiesPerItem),  
 "--maxPrefs", Integer.toString(maxPrefs),  
 "--minPrefsPerUser", Integer.toString(minPrefsPerUser),  
 "--booleanData", Boolean.toString(booleanData),  
 "--threshold", Double.toString(threshold)  
 };  
  
 int result = ToolRunner.run(cfg, new ItemSimilarityJob(), applyPhase(opts, 0, 0));  
 if (result != 0) {  
 return result;  
 }  
  
 result = runRowSimilarityJob(tempDir);  
 if (result != 0) {  
 return result;  
 }  
  
 return ToolRunner.run(cfg, new ItemSimilarityJob(), applyPhase(opts, 2, Integer.MAX\_VALUE));  
}

}

kakao

2017.06

## REPORT



---

# KAKAO AI REPORT

---

Vol.04

---

발행일 | 2017년 6월 23일

발행처 | (주)카카오

발행인 | 카카오 정책지원팀

편집 | 김대원, 김명수, 정수현

디자인 | 허진아

메일 | kakaoaireport@kakaocorp.com

---

## COVER

카카오 AI 리포트의 표지에서는 AI와 관련된 의미 있는 코드들을 매월 소개할 예정입니다.

Vol.04 코드 | 윤병학 combine@loen.com

For you는 2004년부터 멜론에 쓰인 이용자들의 사용 데이터를 분석하여, 이용자들이 좋아할만한 음악을 다양한 방식으로 추천하는 '지능형' 음원 큐레이션 서비스입니다.

---

## contents

---

### preface

카카오 AI 리포트 4호를 내며

03

### review

#### AI와 여성: Women in AI

정수현 | 페이페이 리의 꿈과 도전, '모두를 위한 AI'

06

김대원 | 여성 AI 개발자들이 말하는 'AI와 나'

10

### industry

#### AI 알고리듬의 비밀

AI in Kakao

전상혁, 김광섭 | 내 손안의 AI 비서, 콘텐츠 추천 알고리듬

18

최성준, 이경재 | 알파고를 탄생시킨 강화학습의 비밀

24

### information

김연지 | 카카오 북클럽 추천 AI 도서 모음

30

### closing

마치며

32

# 카카오 AI 리포트

## 4호를 내며

먼 미래에 ‘AI(인공지능) 연대기’가 작성된다면, 현재 알파고 수준의 AI는 아마도 갓난아기에 비유될 듯 합니다. 방대한 데이터를 순식간에 학습할 수 있는 잠재력을 가졌지만 ‘지(知)’의 측면에서는 백지장이나 다름없는 AI에게 무엇을 가르쳐야 할까요. AI에게 건네질 ‘최초의 지식’이 성별, 인종, 지역, 계층 등 사회적 편견과 편향들로 오염된 데이터라면 인간의 편견을 그대로 답습할 것이란 우려가 갈수록 커집니다.

카카오 AI 리포트는 이번 호에서 ‘AI와 여성’을 주제로 AI 연구의 다양성 부족 문제를 살펴봤습니다. 미국 스탠퍼드대 인공지능 연구소를 이끌고 있는 페이페이 리(Fei-Fei Li) 교수는 “AI와 기술 연구는 여전히 남성 연구자들에 의해 주도되고 있다”며 “여성과 소수자 그룹 구성원들이 AI 분야에 더욱 적극적으로 참여해야 한다”고 주장합니다. 지난한 중국 이민자 가정에서 자라나 남성 연구자 일색인 AI 분야에서 최고 전문가로 인정받기까지, ‘소수자 집단’에 속해 직접 겪은 경험들에서 우러나온 주장이라 더욱 귀 기울여볼만 합니다. 카카오에서 AI를 개발하는 여성 개발자들은 ‘여성 개발자들이 말하는, AI와 나’란 주제로 ‘AI 톡(talk)’ 좌담회를 가졌습니다. 아기가 세상을 배워가는 모습을 지켜봤던 경이로운 경험들이 AI에 대한 이해와 통찰을 넓혀주었다는 경험담부터 IT 분야는 상대적으로 여성 차별이 적으니 AI 연구에 더 많은 여성들이 도전하길 바란다는 당부까지, 평소 듣기 힘들었던 여성 개발자들의 이야기들을 풍성하게 담았습니다.

카카오의 AI 추천 플랫폼 ‘토로스’는 글, 사진, 음악, 뉴스 등 다양한 영역에서 이용자들이 좋아할만한 콘텐츠를 추천해주는 인공지능 알고리듬입니다. 추천기술파트 전상혁 님과 김광섭 님이 ‘토로스’에 적용된 추천 기술을 머리에 쑥쑥 들어오는 쉬운 설명으로 풀어주셨습니다. 무적 알파고를 탄생시킨 비밀, ‘강화 학습’에 대해선 서울대학교 박사 과정 중인 최성준 님, 이경재 님이 다양한 함수와 수식을 통해 차근차근 설명해 주셨습니다. ‘학이시습지(學而時習之) 불역열호(不亦說乎)’의 시간이 되길 바랍니다.

끝으로, 카카오 사내 북클럽이 일반인들도 관심을 가져볼만한 AI 도서들을 엄선해 추천드립니다. AI의 미래를 함께 그려볼 수 있는 좋은 출발점이 되었으면 합니다.

2017년 6월 23일  
정책지원팀 드림

# AI 와 여성: Women in AI



인공지능은 인간이 제공해준 빅데이터를 통해 스스로 학습하는 과정을 거치지만 편견과 차별이 반영된 빅데이터가 제공되면 결국 인간의 편견이 그대로 반영될 수밖에 없습니다. 게다가 AI 연구가 남성, 그것도 소수의 백인 남성들이 주도하는 현실이 지속된다면 이런 편향들은 더욱 심각해질 것입니다. 페이페이 리 스탠퍼드대 교수는 AI 연구 분야에 내재된 다양성(diversity) 부족 문제를 해결하는데 가장 적극적인 여성 학자 중 한 명입니다. 소수자 그룹에 속했던 자신의 정체성(여성, 중국계)을 바탕으로 AI 연구에 내재된 편향성과 다양성 부족을 해결하기 위한 도전에 적극 나서고 있습니다. 첫 번째 글 '페이페이 리의 도전, 모두를 위한 AI'를 통해 그의 여정에 동참하실 수 있습니다. 카카오는 IT 분야에서 활약 중인 여성 AI 개발자의 목소리를 듣기 위해 사내 여성 개발자들을 한 자리에 초대했습니다. 음성처리, 자연어처리, 기계번역 등 각 전문 분야별 AI 전문가들이 모여, 여성 개발자의 시각으로 바라본 'AI' 관련 생각들을 자유롭게 나눴습니다. AI 연구는 실생활과 밀접한, 재미난 일들이 가득한 분야이니 관심 있는 여성들이라면 꼭 도전하길 바란다는 이들의 당부, 잊지 마시길 바랍니다.

# 페이페이 리의 꿈과 도전 ‘모두를 위한 AI’

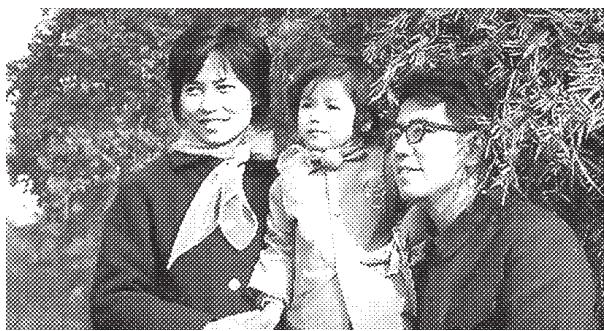
AI For All,  
Not only for guys with hoodies

많은 사람들이 AI가 바꿔갈 세상에 대해 이야기합니다. AI가 인류의 삶을 우리가 상상하는 수준 이상으로 바꿀 것이란 전망도 나옵니다. 과연 AI는 모두를 위한 기술(AI for All)이 될 수 있을까요? 미국 스탠퍼드 대학 인공지능연구소(Standford Artificial Intelligence Lab)와 컴퓨터 비전 연구소(Standford Vision Lab)를 이끌고 있는 페이페이 리(Fei-Fei Li) 교수는 AI와 빅데이터 분야의 세계 최고 전문가로 꼽힙니다. 특히 인공신경망 기반 딥러닝을 통해 기계에게 보는 법을 가르치는 ‘컴퓨터 비전(computer vision)’ 연구를 획기적으로 발전시킨 학자로 평가받습니다. 동시에 페이페이 리는 일명 ‘후드티를 입은 남자들(guys with hoodies)’로 불리는 남성 중심의 AI 연구 환경, 그리고 이로 인해 초래된 다양성(diversity) 부족 문제를 해결하는데 가장 적극적인 여성 학자이기도 합니다. 지난 5월 페이페이 리와 ‘빌 앤드 멜린다 게이츠 재단(Bill & Melinda Gates Foundation)’의 멜린다 게이츠 회장 간 좌담 내용, 그가 이끌고 있는 다양성 강화 캠페인, 그리고 그간의 주요 발언들을 통해 페이페이 리가 꿈꾸는 ‘모두를 위한 AI’를 탐구해보고자 합니다.

글 | 정수현 : noah.jung@kakao.com

숫자의 숨은 의미? 머니볼의 힘? 숫자들에서 남들이 찾지 못한 숨겨진 의미를 찾아내는 걸 좋아한다. 어릴적 모바일 게임을 개발하던 코딩 실력으로 딥러닝을 뜯어가려고 험덕거리며 달리고 있다. 하지만, 오래 달리는건 자신이다. 마라톤을 달리며 나와의 싸움을 이기는데 익숙해 있기 때문이다. 비록 늦게 출발했지만 언젠가는 트랙에서 함께 뛰고 있기를 기대하며, 지금도 비록 느리지만 달리고 있다.

페이페이 리 교수는 중국 베이징에서 태어나 16살 때 부모님과 함께 미국으로 건너왔습니다. 가난한 이민자였던 부모님은 고학력에도 불구하고 영어가 능숙치 않아 아버지는 카메라 수리공으로, 어머니는 캐셔로 일해야 했습니다. 어린 시절 페이페이 리는 벌이가 시원찮은 부모님 일을 도우면서도 좋은 성적을 거둬 프린스턴 대학에 입학해 물리학을 전공했습니다. 대학 입학 후에는 주말 동안 부모님이 운영하는 세탁소에서 일을 하고 주중엔 다시 학교로 돌아와 공부를 하는 생활을 이어가야 했습니다.<sup>1</sup> 대학 졸업 후 골드만삭스 등 월가의 입사 제의를 뿌리치고 티베트로 건너가 티벳 전통 의학을 1년간 공부하는 등 잠깐의 외도 기간을 거쳤지만 이후 캘리포니아 공과대학(California Institute of Technology)에 진학해 인공지능과 계산 신경과학 분야에서 석사와 박사 학위를 받았습니다.<sup>2</sup>



[사진 1] 어린 시절 중국에서 부모님과 함께 찍은 사진 (출처: CNNMoney)

페이페이 리는 현재 스탠퍼드대 인공지능연구소와 컴퓨터 비전 연구소 소장으로, 컴퓨터 시각인지와 머신 러닝·인공지능·인지 신경과학 및 빅데이터 연구를 종괄하고 있습니다. 올해 안식년 기간 동안은 구글에 합류해 클라우드 머신 러닝 부문을 총괄하고 있습니다. 그의 인공지능 연구는 기계가 단순히 물체를 '알아보는(recognition)' 수준을 넘어, 이미지 속 상황을 자연어로 설명할 수 있는 인공지능을 만드는 것입니다. 예를 들어, 고양이를 보면 이 물체가 '고양이'라고 인식할 뿐 아니라 '몸을 돌돌 만 채 잠든 고양이', '주인 무릎 위에서 먹이를 먹는 고양이'라고 설명할 수 있는 인공지능을 만드는 것입니다.

2007년 페이페이 리가 프린스턴 대학의 카이 리(Kai Li) 교수와 함께 시작한 이미지넷(ImageNet) 프로젝트는 갓난아기들이 방대한 양의 외부 이미지들을 보며 시각처리 능력을 발달시키듯이 컴퓨터에게 '보는' 법을 가르쳐 보자는 아이디어에서 시작했습니다. 페이페이 리는 컴퓨터에 보여줄 수억 장의 이미지를 모으기 위해 인터넷과 집단 지성, 크라우드 소싱 기술을 적극 활용했습니다. 5만 명에 가까운 작업자들이 세계 167개국에서 약 10억 장의 이미지를 분류하고, 레이블(label)을 붙이는 작업을 도왔습니다. 지금이야 방대한 양의 빅데이터가 딥러닝 방식으로 인공지능을 학습시키는

데 필수적이라는 사실이 상식이 되었지만 당시만 해도 다소 무모한 도전으로 여겨졌습니다. 동료 교수들은 종신 교수가 되려면 논문을 쓸 수 있는 다른 프로젝트를 찾아보라며 그를 말리기도 했습니다. 하지만 결국 2년 뒤인 2009년 무렵 약 2만 2,000여개의 범주로 분류한 1,500만 장의 이미지 데이터베이스를 갖추게 되었습니다. 방대한 양의 이미지와 연관된 정보는 이후 딥러닝 기술과 만나 오늘날의 딥러닝 기술을 꽂피우는 데 가장 중요한 자양분이자 기초가 되었습니다. 이미지넷의 방대한 이미지 데이터와 CPU, GPU 발전에 힘입어 딥러닝 기술이 적용된 컴퓨터는 이제 사진 속 고양이를 인식하는 차원을 넘어 고양이가 지금 무엇을 하고 있는지를 말할 수 있습니다.<sup>3</sup> 현재 페이페이 리의 연구팀이 운영하는 이미지넷은 매년 전 세계 인공지능 업체들이 이미지 인식 분야 기술을 겨루는 이미지 인식 경연대회(ImageNet Large Scale Visual Recognition Challenge, ILSVRC)를 열고 있습니다.

페이페이 리가 인공지능 연구의 다양성 부족 문제를 더욱 심각하게 인지할 수 있었던 데는 이처럼 10여년 전부터 딥러닝의 기초가 되는 빅데이터 연구를 일찌감치 경험할 수 있었던 덕분으로 여겨집니다.



[사진 2] 2015년 3월 지식강연 테드(TED)에서 '우리는 어떻게 컴퓨터에게 사진을 인식하도록 가르치는가'를 주제로 강연 중인 페이페이 리 (출처 : TED.COM)

인공지능은 인간이 제공해준 빅데이터를 통해 스스로 학습하는 과정을 거치게 되는데, 인간의 편견과 차별이 반영된 빅데이터가 제공되면 결국 인공지능 역시 인간의 편견을 그대로 답습하게 됩니다. 예를 들어, 2016년 3월 마이크로소프트(Microsoft)사는 테이(Tay)라는 AI 챗봇(chatbot) 서비스를 선보였지만 인종편향적(racist)이면서 잔혹한 단어들을 사용해 채팅을 진행하는

바람에 사용자들로부터 강한 비난을 받고 16시간만에 서비스를 중단해야 했습니다.<sup>4</sup> 테이는 공개된 데이터와 대화 내용을 통해 자율적으로 학습하고 대화 상대방에 반응하는 AI 서비스인데, 사용자들의 편견이나 욕설이 담긴 데이터들을 그대로 학습한 탓에 이런 결과가 초래된 것입니다.

“교육자, 엄마, 여자, 미국 사회 내 유색인종이란 정체성을 갖고 살아가는 입장에서 AI가 바꿔가는 미래 세상에 대한 우려가 큽니다”<sup>5</sup> 페이페이 리가 지난 5월 백채널과 가진 인터뷰에서 한 말입니다. 페이페이 리는 자신이 꿈꾸는 AI의 미래는 ‘모두를 위한 AI’라고 합니다. AI는 우리 삶의 모든 영역에 엄청난 영향을 미칠 기술이므로 소수의 남성 연구자 그룹 위주가 아닌, 더욱 다양한 배경을 가진 사람들이 AI 연구에 참여해야 한다고 주장합니다.

그는 이날 좌담에서 “인공지능처럼 사람들의 생활을 진보시켜나갈 분야에서도 많은 전문가와 리더들이 차별로 인해 배척받고 있다”며 “나는 실리콘밸리를 사랑하지만, 실리콘밸리에는 ‘기술은 쿨(cool)하고, 고짜스럽고(geeky), 후드티를 입은 남자들로 대표된다’는 목소리가 지배적”이라고 비판했습니다. 이에 멜린다 게이츠 회장은 “실력 있는 개발자, 기술자들이 성별이나, 피부색으로 인해 차별받는 상황이 지속된다면, 결국 하나의 악습으로 자리잡을 수밖에 없다”며 “10년, 20년 뒤에 이를 후회해도 아무 소용이 없을 것”이라고 답했습니다.

‘후드티를 입은 남성들(guys with hoodies)’로 비난받는 후드티 문화는 컴퓨터로 장시간 모든 업무를 진행해야 하는 남성 프로그래머(개발자)들이 후드티와 같은 편안한 복장을 즐겨 입는 문화를 뜻하는데, 여기에 이공계의 성비 불균형과 남성 위주의 개발 문화가 겹치면서 ‘남성 위주의 IT 개발 문화’를 비판하는 문구로 사용되고 있습니다. 미국에서도 컴퓨터 연구개발 분야의 여성 참여 비율은 매우 낮은 편입니다. 미국 전미대학여성협회에 따르면, 컴퓨터 분야 전문가들 중 여성의 비율은 1990년 35%에서 2013년 26%로 오히려 상당폭 하락했습니다.<sup>6</sup> 게다가 이 수치는 AI 분야로 옮겨가면 더욱 낮아집니다. 2016년 6월 블룸버그 보도에 따르면 인공지능 분야에서 가장 유명한 신경정보처리시스템 학회(Neural Information Processing Systems, NIPS)가 2015년 캐나다 몬트리올에서 개최한 학회에 참가한 연구자들 중 여성 참가자 비율은 13.7%에 불과했습니다.<sup>7</sup> 페이페이 리는 AI 기술은 우리 삶과 관련된 모든 문제들에 영향을 주고, 윤리, 편견, 정의, 접근성 등에 영향을 준다고 말합니다.<sup>8</sup> 그렇기 때문에 AI 연구와 인류의 다양성을 대표하는 기술자들이 함께 하지 못한다면, 필연적으로 모든 인류를 대표하는 기술이 될 수 없을 것이라고 우려를 표합니다.<sup>9</sup> 아울러 현실 속 편향이나 편견들이 AI 개발 과정에서 시정되지 않으면 AI 역시 우리가 성별, 인종, 소득 수준에 따라 갖고

있는 편견(bias)을 고스란히 답습할 수밖에 없기 때문에 다양성 부족 문제 해결이 시급하다고 말합니다.



[사진 3] 멜린다 게이츠 회장과 좌담 중인 페이페이 리 교수 (출처: 백채널 홈페이지)

‘세일러스(Stanford Artificial Intelligence Laboratory’s Outreach Summer, SAILORS)<sup>10</sup> 프로그램은 페이페이 리가 AI 연구 내 다양성 부족 문제를 해결하기 위해 직접 운영 중인 대안들 중 하나입니다. 그는 지난해 자신의 제자인 올가 러사코브스키(Olga Russakovsky) 박사와 함께 이 프로그램을 파일럿(pilot) 형태로 시작했습니다. 대상은 진학 결정을 앞두고 있는 미국 내 9학년 여학생들(한국 기준 중학교 3학년)입니다. 프로그램의 목표는 첫째, 여학생들이 AI에 대한 관심을 가지게 하고, 둘째, 사회적 영향력(social impact)을 통해 기술적으로 복잡한 AI를 이해하도록 하고, 셋째, 컴퓨터 과학을 전공하고 싶어하는 10학년 여학생들이 겪는 어려움 등을 미리 파악하고 그들의 진학 결정을 돋는 것입니다.<sup>11</sup> 파일럿 프로그램의 성공 덕분에 이 프로그램을 체계적으로 확대하기 위한 비영리재단 AI4ALL<sup>12</sup>이 빌앤드멜린다게이츠 재단과 엔비디아(Nvidia)의 창업자 젠센 후앙(Jensen Huang)의 후원으로 올해 설립됐습니다. AI4ALL 프로그램에는 올해 스탠퍼드 대학교뿐만 아니라, 프린斯顿 대학교(Princeton University), 버클리 대학교(Berkeley University of California), 카네기멜론 대학교(Carnegie Mellon University)가 참여하고 있습니다. 이 대학들은 AI 연구를 주도하고 있는 대표적인 대학들입니다.

세일러스 프로그램에 참여하는 대학들은 각자 강점을 가진 AI 연구 분야에서, 참가 여학생들이 2주간 마음껏 AI를 탐구하고 실습할 수 있는 프로그램을 제공합니다. 페이페이 리는 참가 여학생들이 편견이 없는, 모두를 위한 AI를 만들어 가고, AI가 바꿔가는 세상을 함께 경험하기를 원한다고 말합니다. 특히 이 프로그램을 통해서는 사회적 영향력을 고려한 AI 프로그램을 제공하고자 노력하고 있습니다. 예를 들어, 자율주행 자동차를 안전과 효율성, 에너지 측면에서만 접근하지 않고 이동이 불편한 노인들과 장애인들의 이동 편의성까지 모두 고려하는 등 ‘사회적 영향력을 고려한 AI 개발’을 여학생들에게 가르치고

있습니다.<sup>\*13</sup> 이런 경험은 학생들이 나중에 자신의 영역에서 AI를 개발하거나 활용할 때 다양한 가치들을 함께 고려할 수 있는 토대가 될 것입니다. 세일러스 프로그램은 이외에도 2명의 멘토와 함께 병원의 위생 상태 개선, 재난 상황시 구조를 돋는 방법, 게놈(genome)을 이용한 암 진단, 교통 약자를 위한 안전한 운전 등의 과제를 해결하기 위해 상상력과 인공지능 기술을 결합하는 다양한 프로젝트들을 수행하고 있습니다. 페이페이 리와 함께 세일러스 프로그램을 설립한 올가 러사코브스키 박사는 “AI에 다양한 생각과 목소리를 불어넣게 되면 더욱 활력있고, 효율적이고 민주적인 공간을 창조할 수 있을 것”이라며 “AI 연구자 그룹이 다양한 배경을 가진 이들로 구성되면 더 창의적인 해결책을 낼 수 있고, 사회 모든 구성원들에게 도움을 주는 AI를 만들어갈 수 있을 것”이라고 말합니다.<sup>\*14</sup>

페이페이 리는 “AI 내 여성 연구자들의 참여를 늘리려는 (나의) 노력은 여전히 바다에 잉크 한 방울 떨어뜨린 정도(a drop in an ocean)에 불과하며, AI 문화와 기술 분야는 여전히 남성 연구자 들에 의해 주도되고 있다”고 말합니다. “우리는 여성과 소수자 그룹들에게 (인공지능 분야에) 더욱 적극적으로 참여하라고 권해야 합니다. 저는 실리콘밸리의 리더들이 이 문제에 대해 더 자주 발언해야 한다고 생각합니다. 이들이 AI 연구 조직내 여성 참여 비율이 최소 30% 이상 되어야 한다고 말할 수 있다면 정말 굉장할 것입니다.” (지난 5월 31일 신화통신과의 인터뷰 내용 중).<sup>\*15</sup>

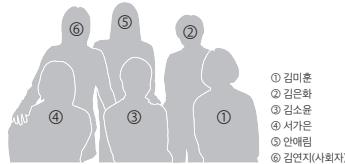
페이페이 리는 다양성 부족 문제에 대해 끊임없이 목소리를 내왔지만 AI의 미래에 대해서는 긍정적입니다. 그는 백채널과 가진 인터뷰 말미에서 다음과 같이 말합니다. “우리 사회는 소수의 인재들만 천재(genius)라고 부르는 경향이 있습니다. 보통 사람들은 자신이 천재가 아니라고 부정합니다. 이는 근거가 없는 말입니다. 생물학에 뛰어난 사람도 인공지능과 의료 분야에서 빛을 발휘할 수 있습니다. 이처럼 인공지능은 여러 분야에 존재하고, 모든 곳에 존재합니다. 결코 미래를 위협하는 두렵고 무서운 기술이 아닙니다. 인공지능은 이곳에서 우리와 함께 하고 있습니다.”

\*1 참고 : CNN 기사, One immigrant's path from cleaning houses to Stanford professor, 2016.7.22, <http://money.cnn.com/2016/07/21/news/economy/chinese-immigrant-stanford-professor/index.html> \*2 참고 : Fei Fei Li 교수 소개, <http://vision.stanford.edu/feifeili/wp-content/uploads/2014/09/LiFei-Fei.CV.pdf>  
 \*3 참고 : 페이페이 리 TED 강연, 2015년 3월, [https://www.ted.com/talks/fei\\_fei\\_li\\_how\\_we\\_re\\_teaching\\_computers\\_to\\_understand\\_pictures](https://www.ted.com/talks/fei_fei_li_how_we_re_teaching_computers_to_understand_pictures) \*4 참고 : 마이크로소프트사의 테이(Tay)서비스 관련 기사, <http://www.bbc.com/news/technology-35890188> \*5 참고 : 멜린다 게이츠 회장과 페이페이 리 교수의 인터뷰, <https://backchannel.com/melinda-gates-and-fei-fei-li-want-to-liberate-ai-from-guys-with-hoodies-17f058889a4c> \*6 참고 : 포춘지 기사, ‘Report: Disturbing drop in women in computing field’ 2015.5.25, <http://fortune.com/2015/03/26/report-the-number-of-women-entering-computing-took-a-nosedive/>  
 \*7 참고 : 블룸버그 기사, ‘Artificial Intelligence Has a ‘Sea of Dudes’ Problem’, 2016.6.23., <https://www.bloomberg.com/news/articles/2016-06-23/artificial-intelligence-has-a-sea-of-dudes-problem> \*8 원문 : AI is a technology that gets so close to everything we care about. It's going to carry the values that matter to our lives, be it the ethics, the bias, the justice, or the access. \*9 원문 : AI is a technology that gets so close to everything we care about. It's going to carry the values that matter to our lives, be it the ethics, the bias, the justice, or the access. \*10 참고 : 스텐포드대학교의 세일러스 프로그램, <http://sailors.stanford.edu/> \*11 논문 : 세일러스 프로그램과 운영성과에 대한 내용, <http://www.cs.stanford.edu/people/sorathan/papers/SAILORS-SIGCSE2016.pdf> \*12 참고 : AI4ALL 재단, <http://ai4-all.org/> \*13 참고 : MIT Sloan Review, [http://sloanreview.mit.edu/article/four-management-lessons-from-self-driving-cars/?utm\\_source=facebook&utm\\_medium=social&utm\\_campaign=sm-direct](http://sloanreview.mit.edu/article/four-management-lessons-from-self-driving-cars/?utm_source=facebook&utm_medium=social&utm_campaign=sm-direct) \*14 Kathy Davis, ‘Girl Power in the World of AI’ 2017.6.2, <https://kathydavis.com/girl-power-in-the-world-of-ai/> \*15 참고 : 신화통신 인터뷰 기사, Interview: “The ultimate power is love, not AI”: top artificial intelligence expert, 2017.5.31, [http://news.xinhuanet.com/english/2017-05/31/c\\_136329243.htm](http://news.xinhuanet.com/english/2017-05/31/c_136329243.htm)

# 여성 AI 개발자들이 말하는 'AI와 나'

여성 개발자들의 'AI 톡(AI Talk)' 좌담회

AI가 인간을 닮아갈수록 AI가 현실 세계의 편견과 편향을 그대로 답습할 것이라는 우려가 커지고 있습니다. 남성 연구자 위주의 IT 문화도 AI 연구 내 다양성 부족의 한 원인으로 꼽힙니다. 카카오는 현재 사내에서 AI 연구와 개발을 맡고 있는 여성 개발자들의 이야기에 귀 기울여보고자 지난 5월 15일 사내 좌담회를 개최했습니다. 좌담회에 참가한 한 여성 개발자는 갓난아기를 길렀던 육아 경험이 인간처럼 보고, 듣고, 판단할 수 있는 AI 서비스를 고민하는 과정에서 많은 통찰력을 줬다고 말합니다. 또 다른 개발자는 "AI 연구는 실생활과 밀접한, 재미난 일들이 가득한 분야"라며 관심이 있는 여성들이라면 꼭 한번 AI 연구에 도전해볼 것을 요청하기도 했습니다.



기획·정리 | 김대원 ive.kim@kakao.com

로봇저널리즘을 비롯해 로봇 그리고 인공지능이 사회에 어떻게 확산될지, 그리고 앞선 새로운 기술이 확산되기 위한 조건이 무엇인지를 살펴보고 있다. 로봇 그리고 인공지능의 건전한 발전을 위해서는, 사회과학도 공학에 버금가는 날개를 확보해야 한다고 생각한다. 두 날개로 날아야 새는 멀리 갈 수 있기에.



이날 좌담회에는 5명의 카카오 여성 개발자(김미훈, 김은화, 김소윤, 서가은, 안애림)(가나다 순)들이 참여했습니다. 이날 사회는 경력 16년차의 여성 개발자인 김연지 님(카카오 인프라실\*)이 맡았습니다. 공대 출신의 여성 개발자가 여성 AI 연구자들의 이야기를 풀어내는 사회자로 적격이라 여겼기 때문입니다.

참석자 소개는 현재 AI 개발 부문 내에서 각자 맡고 있는 역할, 개발자로서 특기와 관심 분야, 유관 경력, 본인이 연구 및 개발 중인 AI 분야의 매력 등 공통 질문들에 대해 답변하는 방식으로 진행됐습니다. 참가자들의 간략한 자기 소개는 아래와 같습니다.

### 김미훈 님(AI 브리지 TF)

현재 카카오 AI팀에 소속되어 시퀀스-투-시퀀스(sequence-to-sequence)라는 모델링 방법으로 심층신경망기반 기계번역기를 개발 중이다. 이 모델링 방법은 기계번역뿐만 아니라 최근 음성인식, TTS(text-to-speech), 이미지 캡션(image caption) 등에도 사용되어 좋은 성능을 보여주고 있는 방법이지만 인간의 인지와는 다른 방식으로 작동하고 있어, 과연 러닝이 무엇일까 하는 질문을 자주 한다. 사람과 같이 언어를 인지하는 기계를 만드는 것이 목표였는데, 알파고가 프로기사들에게 한수 가르치는 것을 보면서, 사람보다 인간의 언어를 더 잘 이해하는 기계를 상상해 본다.

### 김은화 님(AI 자연어처리파트)

언어처리 모듈에 필요한 언어지식을 개발하고 있다. 현재는 챗봇을 위한 도메인별 발화문의 의도 분석 및 언어처리 업무를 수행 중이다. 자연스러운 대화와 인공지능적 처리를 위해 상황에 따른

문맥을 잘 이해하고 대화할 수 있도록 하는 담화 분석에 관심이 많다. 졸업 후 언어처리 연구실의 프로젝트 참여를 계기로 자연어처리 기반 기술 회사에서 자동응답, 오피니언 마이닝, 대화형 챗봇 개발에 참여하는 등 16년째 이 분야를 연구 중이다. 사람의 언어를 기계가 이해하고 대화할 수 있다는 것, 이보다 매력적인 것이 있을까? 속된 말로 '개떡같이 말해도 찰떡같이 알아듣는' AI 친구가 생길 날을 기대해 본다.



### 김소윤 님(AI 음성처리파트)

음성처리 파트에서 음성인식 엔진의 언어모델링을 담당하고 있다. 데이터 정제, 형태소 분석, 발음열 생성, 인식 네트워크 구성 등을 맡고 있다. 언어모델을 확률 기반이 아닌 신경망(Neural Network) 기반으로 바꾸는 테스트도 진행 중이다. 기계와 사람과의 상호 작용이 음성으로 이루어질 것이라 예상이 늘고 있고, 음성인식/합성은 곧 AI 플랫폼의 연결 고리가 될 것이라 생각한다. 아직 모든 목소리를 완벽하게 인식하고 사람처럼 대화를 나눌 수 있는 정도는 아니지만 계속해서 더 성능이 업그레이드될 것으로 기대한다.

### 서가은 님(AI 자연어처리파트)

대화처리시스템 내 자연언어이해(natural language understanding, NLU) 개발을 담당하고 있다. NLU는 사용자 발화의 의도를 인식하는 부분이다. 예를 들어 보면, “오늘 우산 챙길까?”라고 말했을 때 발화자의 의도는 ‘오늘 비올 확률’을 묻는 것이다. 이렇듯 발화자의 언어 속에 숨은 의미까지 파악하는 것을 NLU로 이해하면 된다. 학부 시절 자연어처리 연구실에서 오피니언 마이닝(opinion mining) 분야를 접하게 되면서 흥미를 가지게 되었고, 자연스레 자연어 처리에 관심을 갖게 됐다. 실무 경력은 5년이다. 자연어 처리 분야는 검색, 추천, 대화 등 쓰임도 많고, 인공지능 시대를 맞아 더 큰 가능성을 갖게 됐다. 자연어 처리가 발달하면 연쇄적으로 많은 분야들이 개선될 것이라고 생각한다.

### 안애림 님(AI 자연어처리파트)

한국어를 자동으로 분석, 처리하는 데 필요한 언어학적 데이터베이스를 개발하고 있다. 사전과 규칙 기반의 데이터 구축과 시스템 성능을 높이기 위한 언어 분석이 주 업무다. 자연어처리는 형태소 분석뿐만 아니라 통사(구조) 분석, 의미 분석, 담화 분석 등 다양한 레벨에서 기술이 축적되어야 한다. 각 기술별로 필요한 언어 분석과 데이터 구축에 큰 관심을 가지고 있고, 적용 가능한 응용언어학 이론을 꾸준히 연구, 개발하고 있다. 대학원에서 전산언어학을 공부하며 배운 지식이 실제로 사람들에게 도움이 될 수 있다는 기대감에서 이 분야 개발 일을 시작하게 됐다. 자연어처리 실무 경력은 만 5년. 자연어처리는 서비스의 뒷단에 있어 크게 드러나지 않지만, AI의 기반 기술로서 매우 중요한 역할을 하고 있다. 개발한 데이터가 적용된 모듈이 전반적인 시스템 성능 향상에 기여를 하는 과정을 볼 때 가장 큰 보람을 느낀다.

\*글 들어가기에 앞서: 좌담회에 참가한 여성 AI 개발자들은 각자의 이름을 발언별로 표기했습니다. 사회자 질문은 Q로 표기했습니다.

**Q** 최일선에서 인공지능(*artificial intelligence, AI*)의 개발 업무를 하고 계신 여러분들이 생각하시는 AI 개념은 무엇인지 물어보고 싶다.

**A** 서가온 : AI에 대한 개념은 현재 그려지고 있는 단계라고 본다. AI는 관점에 따라 다양하게 해석되고 있다. AI가 가진 개념의 외연을 크게 느끼는 사람도 있고, 좁게 생각하는 사람도 있다. 말 그대로 인공지능은 나중에 사람이 할 수 있는 모든 액션 자체를 대체할 수 있을 것이라 생각한다. 지금은 반복적인 업무를 수행하거나, 사람의 말을 인식한 뒤 답을 해주는 기술이 인공지능으로 간주되지만, 향후에는 지금은 상상도 못할 만한 기술들이 인공지능의 범주 안에 속하게 될 것이다.

**안애림** : 언어학을 전공했다. 그래서 언어학적 지식이 컴퓨터 공학과 접목하여 어떻게 활용될 수 있을까라는 관점에서 AI를 생각해보게 된다. 기계가 사람처럼 행동하고 말하고, 사람의 요구를 이해하는 것이 가장 인간을 닮아가는 모습으로 볼 수 있다. 이러한 모습 중에 언어를 듣고 이해하는 게, 기계가 사람다워 보이는 가장 대표적인 모습이라고 생각한다. 이 정도에서 AI 개념을 생각하고 있다.

**서가온** : 음성인식, 즉 말을 인지하는 것만을 AI라고 하는 것은 매우 미시적인 규정이라고 생각한다. 우리는 말 이외에 여러 가지 행동으로 생각을 표현한다. 말하면서 취하는 제스처, 상대를 바라보는 태도 등 이런 모든 것들을 이해할 수 있는 것이 AI라고 생각한다. 사람을 닮아가는 것이 AI라고 볼 수 있다.

**김소윤** : 음성 인식의 경우, 신경망(*neural network*)을 적용시키기 전과 후의 성능 차이를 비교해보면, 신경망의 적용 이후 음성 인식의 성능이 향상되면서 이와 관련된 용어로 AI라는 용어가 부상했다고 본다. 전반적으로 AI의 개념이 모호해진 것은 AI의 적용 범위에 대한 고민이 확장되면서부터이다. 적용 범위가 어디까지 확장될지 모르는 시점에서 AI의 개념은 더욱 모호해질 것 같다. 현재 AI에 대한 연구나 개발은 ‘과연 이게 될까?’라는 물음에서 시작된다. 이후 한 곳에서 관련 유의성이 확인되면, 다른 분야에서 AI 적용 가능성을 고민하는 그런 단계이다.

**김미훈** : AI의 폭이 넓어졌다가보다는, AI에 대한 일반 사람들의 관심이 많아졌다고 생각한다. AI 연구를 한다고 포괄적으로 말하지만, 예전에는 음성 인식, 컴퓨터 시각(*computer vision*) 등 구체적인 범위를 특정해 자신의 연구 분야를 설명했다. 지금 논문을 보면 20~30년 전에 이미 공개된 알고리듬들이 지금 빛을

보는 경우가 많다. 역설적인 것은 그 알고리듬을 10여년 전 어떤 과제(task)에 적용해 보니 성능이 가장 낮게 나오기도 했다. 이전과 다른 결과가 나오는 까닭은 데이터와 컴퓨터 능력(*computing power*) 때문이다. 여러 여건들이 맞물려 성능이 좋게 나오면서 AI에 대한 관심이 사회적으로 엄청 넓어졌다. 사회적 주목도가 높아지고, 관련된 일을 조금이라도 된다면 너도 나도 AI라고 하면서 AI 개념의 외연이 넓어졌지 AI, 그 자체 범주가 넓어진 것은 아니라고 생각한다.

**Q** AI의 발전은 순조로울 것으로 생각하나?  
그리고 향후 AI 발전의 관건은 무엇일까요?

**A** 김소윤 : 개인적으로는 음식인식이 어느 정도 성능까지 올라가게 되면, 더 이상 성능을 향상시킬 수 없는 한계점에 맞닥뜨릴 것이라고 생각한다. 그때가 되면 개발자로서 무엇을 어떻게 해야하는지에 대한 고민이 더욱 깊어질 것 같다.

**안애림** : 딥러닝이나 학습기반의 자동화로 가고 있는데, 어느 정도의 성능에 다다랐을 때 언어 공학자로서 할 수 있는 역할이 뭘까라는 고민을 많이 하게 된다. 사람만이 갖고 있는 정교함을 AI에 녹여내는 것이 향후 AI 발전의 관건이다.

**김은화** : 비서형 AI는 제공되는 정보량에 따라 충분히 만족하는 단계에 이를 것으로 기대되지만, 더 진화하여 감정 소통까지 하는 AI 발전까지는 길 길이 멀다. 지속적인 연구와 투자가 필요하다.

**김미훈** : 신경정보처리시스템 학회(NIPS<sup>2</sup>)는 예전에는 변두리 학회였다. 예전에는 (주요 연구진의 소재지인) 캐나다에서만 개최되었는데, 작년에는 스페인 바르셀로나에서 개최했고 가장 주목받는 학회가 됐다. NIPS의 성장에는 자기 분야에 확신을 가지고 경주한 연구자들의 공도 크지만 캐나다 정부의 지원 및 투자 역시 중요한 역할을 했다. 지금 화두가 되는 딥러닝에서 제일 유명한 세 교수 중 두 명이 캐나다에서 연구를 했는데, 모두가 신경망 연구가 죽었다고 평가했을 때, 캐나다 정부는 10년간 이상 투자를 해줬다.

**서가온** : AI의 미래상을 정확하게 전망하기는 어렵다. 그러나 지금 AI가 예전의 ‘빅데이터’같은 느낌이 들긴 한다. 빅데이터는 마치 적용을 하기만 하면 무엇이든 다 되는 듯한 이미지가 있었다. 지금 AI가 우리 사회에서 그런 느낌을 주고 있는 것 같다. 관건은 AI에

내재된 가치가 꾸준히 발현되는 것이다. 이를 위해서는 개발자와 연구자들이 각자의 역할을 다 잘할 수 있도록 회사든, 국가든 그 가치를 알고 투자해주고, 기다려주는 체계가 갖춰져야 한다.

## Q AI 연구 및 개발을 진행하는 과정에서 가장 어려운 점은 무엇인가?

**A 안애림** : AI 분야는 아직 미지의 세계인 것 같다. 어디까지 가능한지 알 수 없고, 아직 아무도 도달하지 않은 것이기 때문에 일반 사람들의 기대치도 높다. 요즘 구글과 같은 글로벌 기업에서 개발한 AI 서비스가 대중들에게 소개되는 소식을 자주 들을 수 있다. 우리가 가진 컴퓨터 공학적 기술은 이러한 기업을 쫓아가기에 충분하다고 생각하지만, 분명 '영어'와 '한국어'가 가지는 언어 분석의 난이도는 큰 차이가 있다. 한국어 분석이 훨씬 까다롭다는 것도 대부분의 사람들이 알고 있는 사실이다. 더욱이 말뭉치인 코퍼스(corpus) 등과 같은 언어 자원의 양도 매우 부족한 실정이다. 한국어 AI 연구가 성공하기 위해서는 단기간에 성과를 바라는 것보다는 지속적으로 투자하고 꾸준히 연구할 수 있는 분위기가 마련되어야 할 거 같다.

**서가은** : 정해진 답이 없다. 이 부분이 제일 어렵다. 인공지능이라는 분야에 대해서 어디까지 상상하고, 기대하고 있는지 사람마다 다르다. 그렇다고 다른 사람들의 상상력이 틀렸다 말할 수는 없다. 다른 개발 분야와는 달리 뚜렷한 정답이 없다. 그래서 너무 어렵다.

**김은화** : 상황에 따른 문맥을 파악하는 일이 가장 어렵다. 같은 문장이어도 상황에 따라 다른 의도로 해석되어야 하기도 하는데, 사람끼리의 대화 간에도 파악하기 어려운 일이라 어느 수준까지 끌어올릴 수 있을지 고민이다.

**김소윤** : 대학원의 경험이 없어서인지 처음에 논문을 보는 게 너무나 어려웠다. 욕심을 버리고 한번 보고 모든 걸 다 이해하려고 하지 않고, 언젠가는 이해가 되겠지 하는 편한 마음으로 논문을 마주하고 있다. 그리고 이전에 다른 사람들이 시도해 보지 않은 무언가를 만들 때가 가장 힘들다. 내가 지금 구현하는 이 방법이 맞는 과정인지 혼자서는 판단하기 어려울 때가 힘들다. 실험해보지 않으면 이 시도가 맞는지 알 수 없다. 그래서 AI 연구는 많은 경험치가 능력을 만드는 그런 분야라고 생각한다.

**Q 개발자로 일하면서 사회자 본인은 여성 차별을 느낀 것이 별로 없었다. 그래서 많은 여성들이 차별없는 이 분야에 적극적으로 진입해야 한다는 생각도 듈다. 여러분들은 어떻게 생각하는가?**

**A 서가은** : IT 직종이 차별이 더 적은 것 같기는 하다. 학부 때 연구실에 한 2년 정도 있었는데, 선배들이 여자라고 봐주는 거 없다 하더니 정말 같이 밤새고 눈꼽 떨 시간도 안주고 남자처럼 대했다. 회사에서도 여성 차별적인 요소들이 없다. 오히려 연구실에 있을 때보다 남자 동료들이 더 조심하는 모습을 보인다. 동종 업계에 다니는 친구들로부터 여성이기 때문에 혹은 나이가 어리다는 이유로 의견이 묵살되고 주요 논의 자리에 배제되는 사례를 전해 들었는데, 카카오에서는 그런 차별은 별로 없는 것 같다. 사실, 나이가 어리고 경험이 적은 경우에도 의견이 참신하고 보다 큰 능력을 갖고 있을 수 있지 않은가? 학력, 성별, 나이에 상관없이 커뮤니케이션이 수월하게 이뤄진다. 카카오만의 특징일 수 있다.

**김소윤** : 자유롭고 수평적인 문화를 가진 곳이 IT 업계 외에는 흔하지 않은 것 같다. 개발자는 성별, 나이 상관없이 개인 역량으로 인정받을 수 있는 분야라고 본다. 여성 개발자분들이 빨리 더 많아졌으면 하는 바람이다. 요즘 후배들 얘기를 들어 보면 여학생들이 과 상위권을 훨씬고 있다고 들었다. 곧 현업에서도 여성 개발자가 더 많아질거라고 본다.

**Q AI를 분석하고 공부하는데 있어 남성들에 비해 여성이 조금 더 유리하다고 볼 수 있는 환경이나 조건은 무엇인가?**

**A 김미훈** : 아이를 키우면서, AI 연구에 대한 생각을 새롭게 할 수 있었다. 대학원에서 공부하던 시기와 아기를 키우는 시기가 겹쳤다. 아이가 자라며 이것저것을 터득해 가는 과정을 보면서, '아기는 어떻게 배우지?'라는 고민을 하게 됐다. 그리고 이것을 기술에 어떻게 적용할 지도 고민하게 됐다. 그리고 이런 경험을 통해 기술이 인간을 닮는 것은 쉽지 않은 일이라는 생각도 하게 됐다. 일반적인 생각과 달리, 기계와 사람이 배우는 방식은 다르다. 자연어처리를 예로 들어 보면 자연어처리는 동사 중심으로 이뤄지는 데 반해, 아이는 명사 중심으로 말을 배운다. 차가 지나갈 때, 아이는 "차가 지나간다"고 말을 하지 않고, "차" 이렇게 명사만을 말한다. 아이에게는 본질(entity)이 중요한 것이다. 이 차이를 어떻게 줄일 수 있을지를 자연어 처리 시스템을 만들 때 고민하곤 한다.

**안애림** : AI 연구 내 다른 분야는 모르겠지만, 현재 연구하는 분야(자연어처리)는 여성들이 경쟁력을 더 발휘할 수 있는 분야라 생각한다. 현재 내가 개발하는 분야는 많은 양의 언어 데이터를 보고 분석하는 일이 주 업무이다. 일반적인 규칙에 적용 가능한 언어 현상들 외에 예외적인 언어 현상들을 기계가 자동으로 처리할 수 있도록 하는 깊이 있는 분석이 요구된다. 이 분야에서 여성 연구자가 다양한 관점으로 데이터를 세심하게 처리할 수 있다면 경쟁력을 더욱 잘 발휘될 수 있지 않을까 생각한다.

**김소윤** : 굉장히 거대한 데이터를 다루는 작업이다 보니 개발을 하면 결과가 바로 나오지 않는다. 몇 시간부터 최대 며칠째 결과를 기다려야 하는 일이 많다. 인내심이 필요하다. 그리고 한 분야를 깊게 공부해야 해서 끈기도 필요하다. 조금 더 세심하게 데이터 관리를 해야 하는 부분도 필요하다. 이 부분에서는 여성들이 조금 더 능력이 있지 않나 싶다. 물론 개인차가 있을 수 있다.

**김은화** : AI 연구를 위해 행동이나 언어 패턴을 분석함에 있어서 언어적인 부분에서는 여성이 남성보다 강하다는 생각이 일반적인 것 같다. 하지만, 여성이라서기 보다는 개인의 성격과 성향 차이가 있을 수 있다고 본다. 함께 일하는 동료 중에 섬세한 성격의 남성 언어학자도 있다.

**Q** 이번엔 사회자로서 개인적인 이야기를 나누고자 한다.  
개인적으로 공학자가 되고 싶다는 생각을 처음으로 가졌을 때는 중학교 1학년 과학시간 때 이슬점 배우는 공식이 잘 이해가 됐을 때였다. 공학 분야에 종사하고 계시는 아버지의 영향도 공대를 택하게 된 주요 요인이 됐다. 다른 분들의 경우, 공대 혹은 공학과 관련된 진로를 택하게 된 이유 또는 계기가 무엇이었는가?

**A** 서가은 : 7살 위인 둘째 언니가 컴퓨터 공학 전공이었는데, 그런 언니가 멋있어 보였다. 지금 생각하면 별거 아닌 거 같은데, 언니가 코딩(coding)을 하는 모습이 꽤 멋있어 보였다. 그래서 고등학교 때 “나도 그럼 컴퓨터 할래”라고 진로를 결정했다. 언니의 꿈에 넘어간 면도 있다. 언니는 “컴퓨터는 계속 쓰이게 될 것이고, 그러면 나중에 나이 들어서도 계속 일할 수 있을 거야”라고 조언했다.

**안애림** : 인문계를 졸업해서 언어학을 전공했다. 언어학은 말을 잘하고 싶어서였다. 아나운서처럼 말을 잘하는 사람들이

멋있어 보였다. 그리고 대학 4년을 보낸 어느 날, ‘배운 걸 어디에 써먹지?’라는 고민을 하게 됐다. 그러던 중 우연히 학부 수업중에 컴퓨터 공학과 언어지식을 접목해서 결과물을 내는 수업을 수강하게 됐는데, 그게 너무 재밌었다. 내가 배운 것과 알고 있는 지식을 엮어 바로 눈에 보이는 결과물을 낼 수 있다는 사실이 즐거웠다. 대학원에서 전산언어학을 전공했고, 전산 지식과 언어가 합쳐지면 많은 것들을 할 수 있음을 그때 깨달았다. 지금 개발 직군에서 다른 개발자들과 협업을 하며 기여할 수 있는 것에 굉장히 큰 보람을 느끼고 있다.

**김은화** : 전형적인 문과생이다. 사실 수학을 좋아하지도 않았다. 졸업 후 전산학과 자연어처리 연구실에서 교수님 연구 자료를 관리하다가 언어처리 국책 프로젝트에 참여하면서 자연어처리 연구 분야를 접하게 됐다. 수학적인 것은 서툴지만, 언어학적인 자연어 처리를 위해 문장 구조, 문맥, 동의어 관계 등을 파악하는 과정에서 개인적으로 가진 장점이 시너지를 내는 것을 확인할 수 있었다. 비록 컴퓨터 공학 전공자는 아니지만 언어학적 접근으로 AI가 발달하는데 한 몫을 하고 있다는데 보람을 느낀다.

**김소윤** : 정보컴퓨터공학부로 대학에 입학했다. 산업공학자의 길을 택할 생각이었지만, 수업을 들으면서 컴퓨터공학과로 방향을 틀었다. 그러나 전공이 어려워서 3학년 때까지 헤맸다. 3학년 때 연합개발동아리에서 디자이너, 기획자, 개발자와 같이 프로젝트를 하면서 개발의 재미를 알게 됐다. 어떤 값을 입력했을 때 정확한 결과가 나오는 구조가 매력적이었다.

**김미훈** : 고등학교 수업시간에 선생님이 탁구 공의 둘레에 있는 점이랑 지구 적도에 있는 점의 개수가 어떤 게 더 많은지를 질문하셨다. 탁구공은 작고 지구는 큰 데 어떻게 점의 개수 차이를 물어볼 수 있을까라는 생각이 들었다. 집에 와서도 학교에서도 며칠째 그 문제를 고민하고 찾고 하면서 처음으로 맵핑(mapping)이라는 개념을 이해했다. 그때부터 수학이란 걸 좋아하게 됐고, 대학 전공을 수학과로 정했다. 처음에 상상했던 전공과는 차이가 있었지만, 그래도 수학이란 학문 그 자체로 좋았다. 졸업 후, 우연치 않게 자연어 처리 프로젝트를 하게 됐는데, 이를 계기로 대학원 전공을 자연어 처리분야로 하게 됐다. 앞서 말씀드렸던 것처럼 아기를 키우면서 진짜 지능이 무엇일까 계속 고민하게 됐고 그래서 더욱 흥미를 갖고 연구를 계속하며 여기까지 오게 됐다. 지금 딥러닝을 연구 중인데 관련 논문에 나오는 전문지식들뿐만 아니라, 그 안에 내재된 통찰력을 배우는 그 자체가 너무 재밌다.

**Q** 참가자들이 AI 분야를 택하게 된 계기를 들어보니,  
노출된 주변 환경 영향이 크다는 생각이 새삼스레 듣다.  
후배 여성들에게 AI 개발(연구)을 추천해주고 싶은지, 아울러 AI  
개발(연구)을 희망하는 사람들이 어떤 역량을 가지게 되면 좋을  
지에 대한 조언을 부탁한다.

**A** 서가은 : 일단 개발을 하려면 개발이 재미있어야 한다.  
일명 '개발 덕심'이 있어야 한다. 성적에 맞춰서 전공을  
택한 친구들은 필기 시험은 잘 보는데, 코딩 공부를 할 생각은 없는  
사례들이 많았다. 학문적으로는 선형대수학을 AI 개발자가 갖춰야  
할 지식으로 꼽을 수 있다. 사실 덕목과 기술도 중요하지만, 흥미와  
욕심이 있다면 꼭 한번 도전해보길 바란다. 생소한 것 같지만  
실생활과 굉장히 밀접하고 재밌는 일들이 많다.

김소윤 : 학부 1학년 때까지 개발에 흥미를 못 가지다가 이후  
재미있는 프로젝트에 참여하게 되면서 (개발에) 흥미를 가졌다.  
1학년 때 개발이 재미없다고 해도 너무 절망하지 않았으면 한다.  
학교 과제가 아닌 흥미로운 프로젝트 하나만 해봐도 재미를 느낄 수  
있다. 포기하지 않았으면 한다.

김은화 : AI는 결국 사람을 연구하는 것이라고 볼 수 있는데, 그만큼  
다양하고 굉장히 많은 데이터를 분석해야 한다. 분석하고, 결과를  
확인하고, 수정하는 일이 반복되면서 점점 품질이 좋아지는 만큼  
반복적으로 하는 일에 대한 끈기가 중요하다.

김미훈 : 일단은 자신의 일을 좋아해야 최고의 창조물이 나온다.  
지금 딥러닝 연구의 진입장벽은 낮은 편이지만 뭔가 깊이 하고  
싶다면 전문가들은 세 가지 요소를 갖춰야 한다고 말한다.  
첫 번째는 코딩 실력이다. 남성 개발자들은 코딩에 필요한 툴(tool)을  
잘 찾아서 쓰는 편인 반면 여성 개발자들은 그런 부분들이 좀 약하다.  
두 번째는 수학 실력이다. 공업수학, 통계, 그리고 미적분은 기본이고,  
선형 대수는 최소한 알아야 한다. 또한 정보 이론(information  
theory), 최적화(optimization) 이런 것까지 알면 대부분의 딥러닝  
연구를 할 수 있다. 세 번째는 도메인 지식이다. 여러 도메인,  
자연어처리, 음성인식 등 여러 도메인에 쓰는 알고리듬들은 모두  
유사하다. 하지만 타겟팅하는 결과는 다르다. 이런 의미에서 내가  
해결하려는 문제를 잘 이해하는데 도메인 지식이 필요하다. 많은  
경우 현업에서 경험하게 된다. 한 가지를 추가한다면, 뇌과학  
분야에도 관심을 가지는 것도 도움이 될 것 같다. 알파고 개발  
회사인 구글 딥마인드(Google DeepMind)의 CEO인 데미스  
하사비스(Demis Hassabis)도 뇌과학(인지신경과학) 전공자이다.

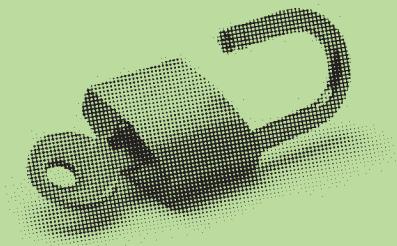
안애림 : 물론 다양한 학문적인 지식도 중요하지만 사실, 빠르게  
변하는 세상에 민감하게 반응하고 적응하는 능력 또한 중요하다.  
아울러 자신의 분야에서 진정한 '전문가'가 되길 바란다. 사회적인  
트렌드와 분위기에 휩쓸려 '나도 AI 개발자가 되어야지'가 아닌,  
자신이 흥미를 가지고 연구하는 분야에서 성실하게 전문적인  
지식을 쌓았으면 한다.

\*1 설명 : 김연지 님은 카카오 임팩트 북클럽의 리더로서 이번 호 'information' 파트에 실린 'AI 그리고 미래사회를 위한 책들'을 쓴 필자이기도 합니다. \*2 설명 : 신경정보처리시스템학회(Neural Information Processing Systems)의 각 영문 글자 앞자를 따서 만든 말. NIPS는 AI연구 분야에서 기계학습 국제컨퍼런스(International Conference on Machine Learning, ICML)과 더불어 AI 연구 결과가 발표되는 대표적인 학회로 꼽힌다. 2017년 5월에 발행된 카카오AI리포트 3호에는 2005년부터 2016년 사이 두 학회를 통해 발표된 논문 6,163건에 대한 메타 분석 결과가 담겨 있다(<https://brunch.co.kr/@kakao-it/63>).

AI

알고리듬의

비밀



이용자들이 무심코 지나쳤을지 모르지만 카카오의 다양한 서비스들에는 ‘내 손 안의 추천 비서’가 이미 곳곳에 적용되어 있습니다. 하루에 수만 개씩 쏟아져 나오는 콘텐츠들 중에서 내가 좋아할만한 콘텐츠를 뽑아내는 일은 이미 사람이 아닌 기계학습 기반의 추천기술이 담당하고 있고, 카카오에서는 AI 추천 플랫폼인 ‘토로스’가 그 역할을 맡고 있습니다. 첫 번째 글에서는 협업필터링, 콘텐츠 기반 필터링, 양상블 기법 등 ‘토로스’에 탑재된 추천 알고리듬의 핵심 개념과 주요 기술들을 확인하실 수 있습니다. 두 번째 글 ‘알파고를 탄생시킨 강화학습의 비밀(1편)’에서는 알파고를 덕분에 인공지능에 대해 관심이 있는 사람이라면 누구나 들어봤을 ‘강화 학습’에 대해 공부할 수 있는 기회를 마련했습니다. 여러 복잡한 함수와 수식들이 포함돼 있어서 비전문가들에게는 난이도가 높은 편이지만 국내에서 ‘강화학습’을 이만큼 쉽게 풀어서 쓴 글을 찾아보기 힘든 것 같습니다. 우리 실생활 속으로 성큼 들어온 AI 기술들의 비밀을 함께 풀어보시기 바랍니다.

# 내 손안의 AI 비서 콘텐츠 추천 알고리듬

카카오의 AI 추천 플랫폼,  
'토로스(TOROS)'

우리는 매일매일 수많은 선택을 한다. 점심 메뉴를 선택하고, 새로 입을 옷을 선택하고, 재밌어 보이는 콘텐츠를 고른다. 하지만 내가 원하는 선택지를 찾는 것이 항상 유쾌하고 쉬운 것은 아니다. 선택지가 무수히 많은 인터넷 서비스에서 소비자들은 더욱더 새롭고 입맛에 맞는 양질의 콘텐츠를 원하고 있다. 하루에 쏟아지는 뉴스 기사는 수십만 건이 넘는다. 이 많은 기사를 전부 읽는 사람은 없으므로 사용자 마음에 들만한 기사를 수십 개 내외로 잘 뽑아서 제공하는 일이 필요하다. 당연히 어떤 기사를 제공하느냐에 따라 사용자들의 만족도가 크게 변하므로 사용자들이 좋아할 만한 선택지를 미리 잘 예측해 '추천'하는 것이 서비스의 품질과 직접 연결된다. 하지만 현실적으로 이 많은 콘텐츠 중에 사용자가 좋아할 만한 것을 뽑는 일을 사람이 손으로 매번 할 수 없으므로 기계학습 기반의 추천 기술은 필수불가결하다.

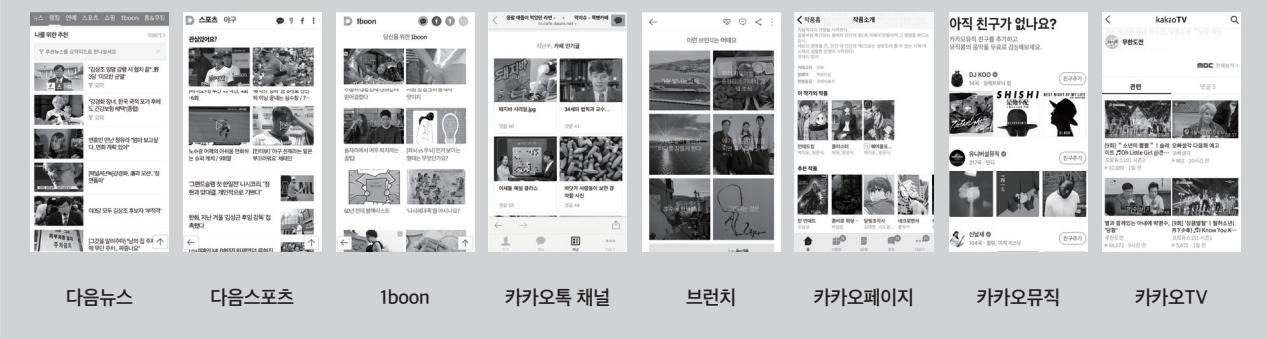
글 | 전상혁 larry.chun@kakaocorp.com

카카오의 추천 기술을 연구하고 개발하는 일을 맡고 있습니다. 제가 알고 있는 지식을 사용해 실제 세상의 문제를 풀 때 큰 즐거움을 느낍니다. 아직 부족한 것이 많아 요즈음 하루하루 빠르게 바뀌는 세상을 따라만 가기에도 벅차지만, 계속 연구와 개발에 정진해 둘 다 놓치지 않고 잘 해낼 수 있는 사람이 되고 싶습니다.

글 | 김광섭 lucas.kim@kakaocorp.com

카카오 추천기술파트의 파트장을 맡고 있습니다. 기계 학습과 추천 시스템 전반에 관심이 많으며 매니저의 역할보다는 프로그래밍을 하는 것에서 더 재미를 느끼고 좋아합니다.

[그림 1] 카카오의 다양한 추천 서비스 예시



카카오는 ‘토로스(TOROS)’라는 자체 개발 인공지능 추천 플랫폼을 보유하고 있다. 위의 [그림 1]은 토로스가 적용된 대표적인 카카오 서비스들이다.<sup>1)</sup> 카카오는 다음뉴스, 1boon, 브런치, 다음웹툰, 다음카페, 다음TIP, 카카오TV, 카카오뮤직, 카카오페이지, 카카오메이커스, 카카오헤어샵 등 카카오에서 제공하는 다양한 서비스들에 토로스 추천 시스템을 적용했고, 앞으로는 카카오내비, 멜론 등의 서비스에도 확장할 계획이다. 서비스가 다양한 것처럼 추천이 사용되는 방식도 다양하다. 특정 콘텐츠를 소비한 후에 추가적인 소비를 이끌어내기 위한 연관 콘텐츠 추천을 제공하기도 하고, 사용자 콘텐츠 소비 이력을 통해 개인화된 맞춤형 추천을 제공하기도 한다. 또한 특정 콘텐츠를 좋아할 만한 사람들을 알고리듬으로 분석해 타겟팅 푸쉬를 하기도 한다. 이 기술들은 전부 다른 기술처럼 보이지만 모두 추천 기술이라는 큰 범주로 묶어서 설명할 수 있다.

서비스와 필요한 기능이 다양한 만큼 여러 기술을 복합적으로 사용해야 한다. 추천 기술에 가장 많이 쓰이는 기술인 협업 필터링(Collaborative Filtering, CF) 기술은 물론이고, 콘텐츠 자체를 분석하는 콘텐츠 기반 필터링(Contents Based Filtering, CB) 기술도 사용하고 있다. 또한, 추천 결과를 더 풍성하게 하고 정밀하게 만들기 위하여 여러 전통적인 통계 모델이나 기계학습 방법들 역시 꼭넓게 사용하고 있다. 다양한 기술들을 복합적으로 사용해야 하는 이유는 한 기술만 사용하는 것보다 여러 기술의 장점을 잘 조합했을 때 더 좋은 결과가 나오고 서비스에 따라, 혹은 심지어 같은 서비스라 하더라도 추천이 필요한 맥락(context)에 따라 추천해야 하는 목적과 대상이 달라지므로 다양한 상황에 적절히 대응하기 위함이다.

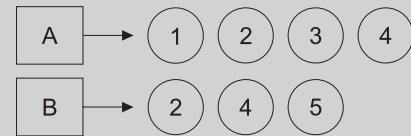
### 협업 필터링(Collaborative Filtering): 너무나 비슷한 너와 나, 내가 좋아하는 이건 어때?

협업 필터링(CF)은 사람들의 콘텐츠 사용 패턴을 분석해 추천하는

방법이다. 콘텐츠 사용 패턴이 비슷한 사람들이 서로 비슷한 선호를 가지고 있다고 가정하고 추천을 한다. 사용자의 클릭, 좋아요/싫어요, 혹은 직접 준 점수 등의 기호(preference) 데이터 등이 주로 사용된다. 아래 [그림 2]는 다양한 모습의 데이터로 사용자 행동 패턴을 표현한다. 어떤 데이터를 사용하느냐에 따라 적합한 모델과 알고리듬이 달라진다.

[그림 2] 추천 데이터의 다양한 형태

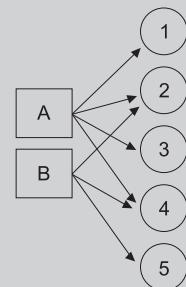
‘사용자 A가 아이템 1, 2, 3, 4를 클릭했다’, ‘사용자 B가 아이템 2, 4, 5를 클릭했다’와 같은 데이터를 표현하기 위한 가장 간단한 방법은 (a)와 같은 스트림(stream) 데이터이다. 이 데이터를 수학적으로 설명하기 위해 (b)처럼 행렬로 표현하거나 혹은 (c)에서 볼 수 있듯 그래프 형태로 표현하는 방법이 있다. 데이터 형태에 따라 사용하는 모델과 이를 학습하기 위한 알고리듬이 다르다.



a. 스트림 데이터

	A	B
1	1	0
2	1	1
3	1	0
4	1	1
5	0	1

b. 행렬 데이터



c. 그래프 데이터

가장 널리 쓰이는 CF 기술은 행렬 분해(Matrix Factorization, MF) 기법이다. MF는 먼저 사용자의 기호 데이터를 그림 2의 b와 같은 행렬로 만든다. 모든 사용자가 모든 콘텐츠를 소비할 수는 없기 때문에 이 행렬은 비어있는(sparse) 행렬이 된다. MF는 이렇게 표현한 행렬의 비어있는 부분을 채우는 기술을 통틀어 이르는 말이다.

토로스에서는 ALS(Alternating Least Square)<sup>\*2</sup>, BPR-MF (Bayesian Personalized Ranking MF)<sup>\*3</sup>, LMF(Logistic Matrix Factorization MF)<sup>\*4</sup> 등의 MF 기술을 사용하고 있다. 각각의 MF 기법마다 목적이 다르기 때문에 하나의 방법론만 사용하는 것이 아니라 여러 MF 기법들을 지속적으로 연구 개발하고 있다. 예를 들어 최근에는 딥러닝 기술이 발전하면서 추천 시스템 분야에서도 MF에 딥러닝을 접목한 심층 행렬 분해(Deep MF) 기법이 유튜브<sup>\*5</sup> 등에서 활발하게 연구되고 있다. 카카오 역시 연관 및 개인화 추천을 위한 자체 Deep MF 기술을 연구 개발하여 보유하고 있다.

MF 이외에도 CF 기술은 다양하다. 스트림 데이터(그림2의 a)를 사용할 때는 언어 모델링(Language Modeling<sup>\*6</sup>)에서 많이 사용하는 word2vec<sup>\*7</sup> 등의 기술들이 많이 쓰인다. 최근에는 LSTM 기반의 딥러닝 기술을 사용하는 추천 기술 연구들도 많이 진행되고 있다. 스트림과 행렬 데이터뿐 아니라 그림2의 c 그래프 데이터 역시 추천에 많이 사용된다. 이때는 주로 개인화 페이지 랭크 (Personalized Pagerank<sup>\*8</sup>)나 신뢰전파(Belief Propagation, BP<sup>\*9</sup>)와 같은 그래프 알고리듬들을 사용한다.

CF를 실제 서비스에 적용할 때는 규모성(scalability)을 반드시 고려하여야 한다. 예를 들어 다음뉴스는 하루 사용자 수가 수백만 명이나 되고, 새로 등록되는 기사의 개수도 하루에 수십만 개가 넘는다. 게다가 새로운 기사가 추가되기도 하고 오래된 기사가 추천 대상에서 제외되기도 한다. 이처럼 큰 데이터가 빠른 속도로 변경되기 때문에 분산처리나 증분 처리 그리고 알고리듬 최적화가 반드시 필요하다. 예를 들어 토로스에서 가장 많이 쓰이는 CF 알고리듬인 ALS와 word2vec은 다음뉴스 정도의 큰 행렬에서도 모델을 하나 학습하는 데에 평균적으로 수분이 채 걸리지 않는다. 만약 알고리듬의 실행 시간이 너무 오래 걸리는 경우에는 SIMD(Single Instruction Multiple Data) 연산이나, GPU 연산을 사용하는 등의 방법을 사용해 알고리듬을 더 빠르게 만들거나 음성 샘플링(negative sampling<sup>\*10</sup>) 등의 방법으로 알고리듬의 복잡도를 직접 낮추기도 한다. CF의 장점은 클릭 등의 사용자 선호 데이터를 직접 사용하기 때문에 대중적이고, 친숙한 결과를 얻을 수 있다는 것이다. 또한 사용자 선호 데이터를 직접 최적화하기 때문에 다른 추천 방법론들과 비교했을 때 성능이 우수한 편이기도 하다. 그러나 CF에도 여러 단점들이 있다. 먼저 기존 데이터에서 관측하지 못한 콘텐츠를 추천하는 것이 불가능하다. 이를 추천에서는 콜드 스타트 (cold start) 문제라고 한다. 콘텐츠 소비 이력만을 사용하기 때문에 실제 내용이 매우 상이한 콘텐츠도 추천 결과에 노출될 위험이 있으며, 인기있는 콘텐츠만 추천 결과에 너무 자주 노출되는 인기 편향 문제(popularity bias)가 발생하기도 한다. 이런 문제를 해결 및 보완하기 위해서 CF뿐 아니라 다른 추천 기술들도 필요하다.

**콘텐츠 기반 필터링(Contents Based Filtering): 라디오헤드를 좋아하는 당신, 혹시 콜드플레이도 좋아하나요?**

콘텐츠 기반 필터링(Contents Based Filtering), 줄여서 CB 추천은 콘텐츠 자체의 내용을 분석해 유사한 콘텐츠를 찾는 방법론이다. 예를 들어 라디오헤드 음악을 좋아하는 사람에게 라디오헤드와 분위기가 비슷한 콜드플레이 음악을 추천하는 것이다. CF가 하나의 기법만을 부르는 이름이 아니듯 CB 역시 여러 기법을 한데 묶어 부르는 이름이다. 우리가 추천할 콘텐츠는 글이 될 수도, 사진이 될 수도, 음악이 될 수도 있다. 그렇기 때문에 다양한 데이터 모데인을 위해 각기 다른 여러 종류의 CB 기술이 필요하다. 예를 들어 라디오 헤드와 비슷한 음악을 추천하려면 음악의 파형을 직접 분석할 수 있는 신호처리 기술이 필요하다. 반면 야구 기사를 읽고 있는 사람에게 류현진의 등판 소식을 알리기 위해서는 자연언어처리(Natural Language Processing, NLP<sup>\*11</sup>) 기술을 사용해 글 내용을 분석해야 한다.

텍스트는 카카오 서비스에서 가장 흔히 볼 수 있는 데이터이다. 예를 들어 다음뉴스, 다음카페, 1boon, 브런치 등의 서비스에서 공급하는 콘텐츠들은 모두 텍스트이다. 이를 위해 카카오는 단어를 실수 벡터(real number vector)로 바꾸는 단어 임베딩(word embedding) 기술을 사용한다. 대표적인 단어 임베딩 기술로는 word2vec 같은 인공 신경망 기법이 있다. 또한, 토픽 모델링(topic modeling)이나 클러스터링(clustering) 등을 사용해 비슷한 주제를 가진 글들을 묶어 사용하기도 한다. 잠재 디리클레 할당(Latent Dirichlet Allocation, LDA) 같은 베이지안 통계 기반 기술이 대표적인 토픽 모델링 기술의 예시이다.

이미지 데이터는 잘 사용하면 추천 시스템의 성능을 크게 끌어올릴 수 있는 데이터이다. 예를 들어 연관 웹툰을 추천할 때 그림체가 비슷한 웹툰을 추천해주거나, 카카오TV의 섬네일(thumbnail)을 추천에 활용한다면 더 좋은 추천이 가능할 것이다. 카카오에서는 이미지 데이터 분석에 컨볼루션 신경망(convolutional neural network, CNN)을 사용한 이미지 CB 기술을 사용하고 있으며 꾸준히 연구 개발을 지속하고 있다. 카카오뮤직과 멜론이라는 국내 최대 음악 플랫폼이 있으므로 음악 역시 카카오에서 빼놓을 수 없는 중요한 데이터이다. 보통 음악을 분석할 때는 스펙트로그램 (spectrogram<sup>\*12</sup>), MFCC (Mel-frequency cepstrum<sup>\*13</sup>) 등의 신호처리 기술들이 많이 쓰인다. 주어진 곡이 잔잔한 곡인지 신나는 곡인지 분류하거나, 코드나 템포가 비슷한 곡을 찾는다거나 하는 등 서비스에서 요구하는 맥락에 따라 서로 다른 신호 처리 기술이 필요하다. 최근에는 전통적인 신호처리 기술들의 단점을 해결하기 위해 딥러닝을 사용한 음악 처리 기술들이 많이 연구되고 있다. 카카오 역시

CNN과 AutoEncoder 등의 딥러닝 모델을 사용한 음악 CB 기술들을 보유하고 있다.

CB 추천은 사용자들의 선호 데이터가 없는 콘텐츠도 추천할 수 있고, 내용을 보고 추천을 하기 때문에 생뚱맞은 콘텐츠가 덜 추천된다는 장점이 있다. 그러나 CF처럼 사용자들의 선호 데이터를 사용하지 않기 때문에 인기 편향 문제에서 자유롭지만, 이로 인해 다소 의외의 상황이 연출되기도 한다. 하지만 다양하고 참신한 추천을 위해서는 이러한 특징이 장점이기도 하다. CF와 CB는 각 방식이 가지는 장단점들은 상호 보완해줄 수 있는 부분이 많다.

### 양상블 기법(Ensemble Method): 너무 다른 너와 나, A모델과 B모델을 어떻게 조합해야 할까?

토로스는 CF와 CB 그리고 각종 통계 모델과 일반적인 기계학습 모델들을 포함해 적게는 3개, 많게는 5개 이상의 모델을 사용한다. 이 모델들이 항상 전부 다 중요한 것은 아니다. 추천 상황에 따라 CF보다 CB가 더 잘 동작하는 경우도 있고, 반대의 경우도 있다. 그러므로 모델별 추천 결과를 잘 조합하는 것은 중요한 문제다. 이런 문제를 양상블(ensemble) 문제라고 부른다.

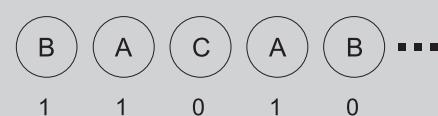
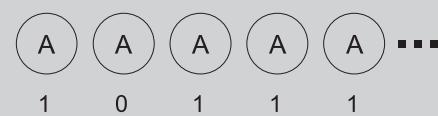
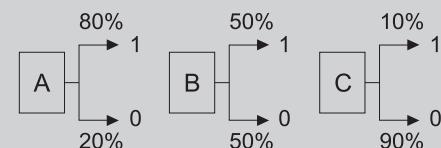
양상블 방법에는 여러 가지가 있다. 가장 간단한 양상블 방법은 모델마다 가중치를 주어 모델별 결과를 가중합(weighted sum)하는 것이다. 상황에 따라 모델별 중요도가 바뀌기 때문에 이 가중치를 잘 설정하는 것이 중요하다. 이런 모델 가중치처럼 알고리듬을 최적화하는 것이 아니라 사람이 직접 설정해야 하는 매개변수를 하이퍼 파라미터(hyper-parameter)라고 부르는데, 모델 가중치 같은 하이퍼 파라미터는 경우의 수가 매우 많기 때문에 적절한 값을 찾는 것이 어렵다. 이를 해결하기 위해 TPE 알고리듬<sup>14</sup>, HyperOpt 알고리듬<sup>15</sup>, HyperBand 알고리듬<sup>16</sup> 등의 각종 하이퍼 파라미터 최적화 방법론을 사용한 하이퍼 파라미터 최적화를 연구하고 있다. 가중합은 가장 직관적이고 간단한 알고리듬이지만 항상 사용할 수 있는 것은 아니다. 가중합을 사용하기 위해서는 추천을 할 때 추천 점수가 항상 필요하지만 모든 모델이 항상 점수화된 추천 결과를 주는 것은 아니다. 게다가 모델별로 점수가 동일한 의미를 가지는 것도 아니기 때문에 선형합을 하는 가중합이 잘 동작하지 않는 경우가 많다. 이런 경우는 모델별 추천 순위(ranking)를 사용하는 양상블 방법을 사용한다. 정보 검색(information retrieval<sup>17</sup>)에서 많이 사용하는 순위 결합(rank aggregation<sup>18</sup>) 알고리듬을 주로 사용하는데, 대표적인 알고리듬으로는 상호랭킹결합(reciprocal rank fusion<sup>19</sup>), comb mzn<sup>20</sup> 등의 알고리듬들이 있다. 좋은 추천을 하려면 양상블만으로는 충분하지 않다. 대부분의 양상블 방법론들은 사용자 반응을 고려하지

않으므로 모델에 사용자 반응이 반영되기 전까지 사용자 반응에 둔감하기 때문이다. 그렇기 때문에 사용자들에게 추천 결과가 정적으로 느껴질 수 있고, 반응률이 좋은 콘텐츠를 추천 결과에 더 자주 노출하거나 반응이 나쁜 콘텐츠는 추천 결과에서 빼버리는 등의 메커니즘을 적용하기 어렵다. 사용자 반응을 알고 있을 때 전체 추천 결과의 반응률을 가장 최대화하는 방법은 반응률이 높은 순서대로 추천 결과를 정렬하는 것이다. 그러나 콘텐츠를 실제로 노출하기 전에는 콘텐츠들의 반응률을 알 수 없다는 문제가 있다.

### 멀티암드밴딧(Multi-armed Bandit): 이 많은 콘텐츠 중에서 사람들이 정말로 좋아하는 것은 무엇일까?

[ 그림 3 ] Multi armed bandit (MAB)

아래와 같이 A, B, C 세 슬롯머신이 있다고 가정했을 때 (a) 이익을 최대화하는 최적하는 (b)처럼 가장 승률이 좋은 A를 고르는 것이다. 실제로는 A, B, C의 승률을 모르므로 (c)처럼 다양한 슬롯 머신들을 번갈아가며 승률을 유추해나가야 좋은 결과를 얻을 수 있다.



토로스는 양상블 알고리듬만으로는 사용자 반응을 반영하지 못하는 문제를 해결하기 위해 멀티암드밴딧(Multi-armed Bandit, MAB) 기술을 사용한다. MAB는 서로 다른 승률을 가지고 있는 여러 슬롯머신이 있고 정해진 횟수만큼 슬롯머신을 시도해볼 수 있을 때, 어떤 순서로 슬롯머신을 시도해야 가장 돈을 많이 벌 수 있는지 찾는 문제이다. [그림 3]은 간단한 MAB 문제의 예시이다. 각 슬롯머신 별 승률이 그림 3의 a처럼 정의되어있고, 슬롯머신을 총 T번 시도할 수 있을 때, 가장 좋은 전략은 그림 3의 b처럼 A만 계속 시도하는 전략이다. 그러나 맨 처음에는 A의 승률이 80%인지 알 수 있는 방법이 없기 때문에 여러 슬롯머신을 번갈아가면서 시도해야 한다. 가장 간단한 전략 중 하나는 10%의 확률로 아무

슬롯머신을 시도해보며 정보가 부족한 슬롯머신들의 승률을 유추하고 90%의 확률로는 지금까지 관측한 슬롯머신 중 승률이 제일 좋은 것만 시도해 이익을 최대화하는 것이다. 임의로 아무 슬롯머신을 시도해보며 슬롯머신들의 승률을 유추하는 과정을 탐색(explore)이라고 부르며, 지금까지 승률이 제일 높았던 슬롯머신을 시도하는 것을 활용(exploit)이라고 부른다. 탐색과 활용은 서로 트레이드오프(trade-off) 관계이기 때문에 이 둘을 잘 조정하는 것이 MAB의 핵심이다. MAB에는 이를 조정하기 위한 많은 방법론이 있으며 토로스에서는 톰슨 샘플링(Thompson sampling) 기술을 사용한다. [그림 3]에서 슬롯머신을 콘텐츠로, 슬롯머신을 시도하는 것을 콘텐츠를 추천 결과에 노출하는 것으로, 보상을 클릭으로, 승률을 반응률로 바꾸면 우리가 해결하고 싶은 문제와 동일한 문제가 된다. 그러나 현실에 MAB를 적용하기 위해서는 풀어야 할 문제가 많아 이를 바로 사용할 수는 없다.

먼저 일반적인 MAB는 그림3의 c처럼 한 번에 하나의 슬롯머신만 시도할 수 있지만, 현실에서는 한 번에 여러 콘텐츠를 추천할 수 있으므로 여러 슬롯머신을 시도하는 상황으로 문제를 바꾸어야 한다. 또한 슬롯머신들의 승률이 한 번 정해지면 같은 승률을 가진다고 가정하는데, 실제로는 콘텐츠 수명이나 트렌드 때문에 시간에 따라 승률이 계속 변한다.<sup>21</sup> 심지어 같은 시간이라도 추천하는 위치에 따라 편향이 발생해 위치에 따라 승률이 다르다. 이외에도 새로운 슬롯머신(콘텐츠)이 계속 추가될 때 초기화를 어떻게 하느냐 등의 이슈가 있다. 기술적으로 생기는 문제들도 있다. 이론적인 MAB는 슬롯머신을 시도할 때마다 결과를 바로 알 수 있지만, 현실에서는 추천 결과를 노출하자마자 사용자들이 반응하는 것이 아니므로 약간 지연된 결과를 얻는다.

[ 표 1 ] 사용자 반응 수집 지연에 따른 상태 CTR 변화

지연시간	상대 CTR
10초	1.71
20초	1.42
60초	1.15
120초	1.0

주: 숫자는 대조군 대비 상대적인 CTR 값을 나타내며 클수록 좋은 값이다.

위 [표 1]은 미디어다음뉴스 데이터에서 추천 피드백 지연 시간과 추천 시스템 성능의 관계를 나타낸다.<sup>22</sup> 추천 시스템의 성능 측정에는 노출 대비 클릭 비율을 의미하는 CTR(click through ratio)을 사용하였으며, 기본 대조군 로직 대비 상대 CTR을 사용하였다. [표 1]에서 확인할 수 있듯 사용자로부터의 반응을 빠르게 수집해 반영할수록 지표는 더 개선된다. 그러나 보통 수집 속도를 빠르게 할수록 시스템 부하가 커지고 리소스가 증가되므로 추천 성능과 시스템 효율을 잘 조율하는 것이 무척 중요하다.

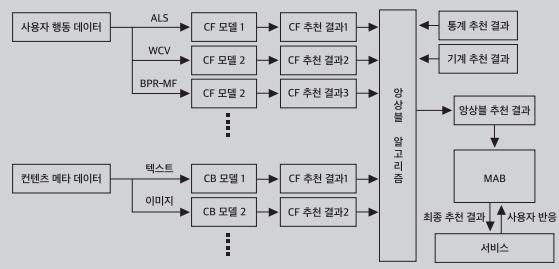
## A/B 테스트: 새로운 추천 로직은 기존보다 얼마나 좋은 걸까?

이렇게 여러 모델과 알고리듬을 연구하고 개발하는 것도 중요하지만, 그 성능을 측정하는 것은 그보다 더 중요하다. 제대로 된 측정이 있어야 어느 로직이 더 나은지 비교할 수 있고, 전체 추천 시스템도 개선할 수 있기 때문이다. 보통 기계학습에서는 데이터를 학습(train)과 검증(validation)으로 나누어 학습 데이터로 학습한 모델이 검증 데이터에서 얼마나 잘 동작하는지 확인하지만 추천 데이터는 사용자가 관측한 콘텐츠에 대해서만 결과를 가지고 있으므로 그 방법이 쉽지 않다. 이를 위해 사용자들이 관측하지 않은 콘텐츠에 대한 반응을 유추하여 평가하는 방법도 있으나 실제 데이터를 사용하지 않았기 때문에 정확한 성능 비교가 어렵다. 그렇기 때문에 실제로 서비스에 적용하여 직접 지표를 확인해야만 한다.\*23

가장 간단한 측정 방법은 전후 비교이다. 새로운 로직 적용 이전과 이후의 지표를 비교하는 것이다. 그러나 이 방법은 공정하지 않다. 순간적인 유행의 변화, 새로운 콘텐츠의 등장, 요일이나 시간대에 따른 행동 패턴 변화 등 로직 이외에도 지표에 영향을 주는 요소가 많기 때문이다. 온라인 A/B 테스트는 사용자들에게 동시에 A와 B 결과를 노출하고 이 둘의 결과를 비교하는 지표 측정 방법론이다. 일부 사용자들에게는 A로직을 보여주고 다른 일부 사용자들에게 B로직을 보여주면서 더 반응이 좋은 로직이 무엇인지 비교하는 것이다. 이 방법은 동일한 조건에서 비교를 하므로 공정하다. 카카오에서는 신규 로직을 5%에서 10% 정도의 작은 확률로 노출해 기존 로직과 성능을 비교한다. 만약 기존 로직보다 좋은 신규 로직이 나타나면 그 로직이 기본 로직이 되고 또 다른 A/B 테스트를 반복한다.

[ 그림 4 ] 토로스 추천 개요

토로스는 CF, CB, 통계 모델, 일반적인 기계학습 모델 등 다양한 모델들에서 추천 결과를 뽑고 뽑은 추천 결과를 양상별하여 하나의 추천 결과로 병합한다. 만드러진 추천 결과가 사용자들에게 노출되기 시작하면 MAB를 사용해 가장 좋은 추천 결과가 무엇일지 찾아낸다.



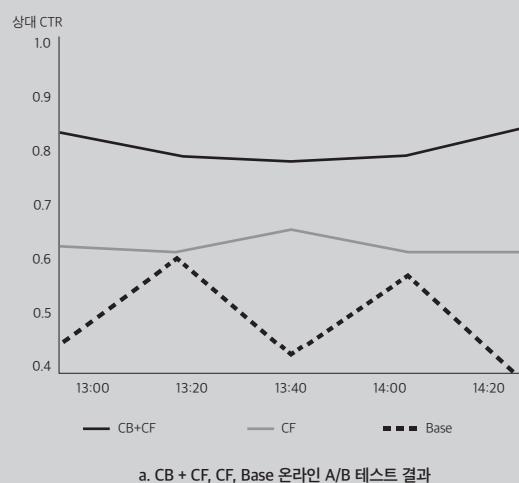
위 [그림 4]는 토로스 추천 시스템의 개요이다. 개요에서 볼 수 있듯 토로스는 수많은 모델과 알고리듬들을 사용한다.

이 중 어느 모델 혹은 알고리듬을 선택하는 것이 좋을지 검증할 때 A/B 테스트를 사용한다. 예를 들어 어떤 양상부 알고리듬을

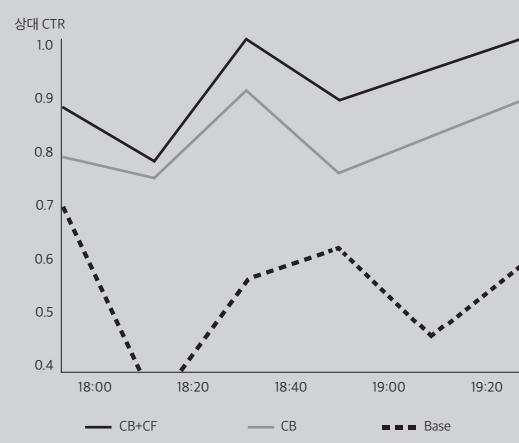
사용할지, 새로운 모델을 추가했을 때 성능이 어떻게 될지, MAB에 새로운 방법론을 적용했을 때 얼마나 추천 결과가 좋아질지 등을 검증하는 것이다. 이렇게 카카오의 추천 기술은 한 자리에 정지해있지 않고 매일매일 발전하고 있다.

아래 [그림 5]는 카카오페이지 연관 추천 영역에서 여러 추천 로직들을 A/B 테스트해가며 지표를 측정한 결과이다.\*24 비교한 로직은 기본 추천 로직과 CB와 CF, 그리고 CB와 CF를 양상별한 로직 총 네 가지를 비교하였다. 지표는 상대적인 값을 사용하였다. 이 값이 높을수록 추천 로직 성능이 우수하다. 그림 5의 a는 CF와 양상을 로직을 비교하였고 그림 5의 b는 CB와 양상을 로직을 비교한 결과이다. 두 경우 모두 기본 로직보다는 추천 로직이 성능이 좋고, 한 로직만 사용한 것보다는 두 로직을 함께 사용했을 때 더 좋은 결과를 낸다는 것을 알 수 있다.

[그림 5] 여러 추천 로직의 성능 비교



a. CB + CF, CF, Base 온라인 A/B 테스트 결과



b. CB + CF, CB, Base 온라인 A/B 테스트 결과

## 마치며

과거에는 전문가가 편집한 콘텐츠나 인구통계학과 같은 단순 방법론으로 소비자에게 콘텐츠를 제안했지만, 이제는 추천 기술을 통해 콘텐츠를 소비하는 새로운 경험을 제안하고 있고, 성공을 거두고 있다. 추천 기술은 콘텐츠 서비스의 핵심 기술 중 하나이며, 그 중요도가 계속 증가하고 있을 뿐 아니라 적용 분야도 넓어지고 있다. 딥러닝을 통해 AI 기술이 재조명받으면서 추천 시스템에도 파급 효과가 전달되고 있다. 추천 시스템의 기반 기술을 한 단계 끌어올리기도 하였으며, 음성 비서나 자율 주행과 같은 새로운 서비스와 환경에서도 추천이 필요한 상황이 되었다. 앞으로도 추천 기술의 중요도와 필요성은 계속 증가할 것이고 AI와의 관계도 더욱 밀접해질 것으로 보인다.

\*1 참고 : 좌측 상단부터 순서대로 다음 앤의 '나를 위한 추천 뉴스', 모바일 다음뉴스 하단의 '연관 추천 뉴스'와 동영상, lboon의 '연관 추천', 카카오톡 체널별 인기 카페글 하단의 '지난 주 인기 카페글 추천', 브런치 하단의 '연관 브런치 글 추천', 카카오페이지 작품 상세 영역의 '연관 작품 추천' 카카오유저 유저들의 '친구 추천', 카카오TV 하단의 '연관 동영상 추천'. 이외에도 많은 서비스들에 토포스를 사용한 추천 서비스가 제공되고 있다. \*2 논문 : Hu, Yifan, Yehuda Koren, and Chris Volinsky. "Collaborative filtering for implicit feedback datasets." Data Mining, 2008. ICDM'08. Eighth IEEE International Conference on. Ieee, 2008. \*3 논문 : Rendle, Steffen, et al. "BPR: Bayesian personalized ranking from implicit feedback." Proceedings of the twenty-fifth conference on uncertainty in artificial intelligence. AUAI Press, 2009. \*4 논문 : Johnson, Christopher C. "Logistic matrix factorization for implicit feedback data." Advances in Neural Information Processing Systems 27 (2014). \*5 논문 : Covington, Paul, Jay Adams, and Emre Sargin. "Deep neural networks for youtube recommendations." Proceedings of the 10th ACM Conference on Recommender Systems, ACM, 2016. \*6 설명 : 단어 시퀀스(sequence)의 확률 분포를 추정하는 문제로, 자연언어처리 분야에서 활발하게 연구되고 있다. \*7 논문 : Mikolov, Tomas, et al. "Efficient estimation of word representations in vector space." arXiv preprint arXiv:1301.3781 (2013). \*8 설명 : 구글의 검색 알고리듬으로 유명한 pagerank를 추천에 적용한 기술 \*9 설명 : 확률 그래프 모델(probabilistic graphical model)에서 그 래프로 표현한 분포의 최대 사후 분포(posterior) 혹은 최대 우도(likelihood)를 계산하기 위해 사용되는 알고리듬 중 하나 \*10 설명 : 계산량을 줄이기 위해 모든 값을 전부 사용하는 연산을 전체가 아닌 일부만 사용해 근사값을 사용하는 방법론. word2vec, LMF 등의 방법론에서 많이 사용한다. \*11 설명 : 사람이 사용하는 언어를 기계가 이해하고 분석할 수 있도록 하는 연구 분야를 통하여 일컫는 말이다 \*12 설명 : 소리나 파동을 이미지로 시각화하는 기술로, 시간과 진폭의 관계로인 파형(waveform)과 주파수와 진폭의 관계인 스펙트럼(spectrum)의 특징을 동시에 표현할 수 있는 방법이다. \*13 설명 : 인간의 청각 시스템을 국내내 만든 신호 처리 기법으로 음성 인식 등의 분야에서 많이 사용하는 기술이다. \*14 논문 : Bergstra, James S., et al. "Algorithms for hyper-parameter optimization." Advances in Neural Information Processing Systems. 2011. \*15 논문 : Snoek, Jasper, Hugo Larochelle, and Ryan P. Adams. "Practical bayesian optimization of machine learning algorithms." Advances in neural information processing systems. 2012. \*16 논문 : Li, Lisha, et al. "Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization." arXiv preprint arXiv:1603.06560 (2016). \*17 설명 : 수없이 많은 정보에서 질의와 관련된 정보를 얻어내는 기술을 통틀어 일컫는 말 \*18 설명 : 서로 다른 순위(rank)들을 결합해 하나의 순위를 얻어내는 기술 \*19 논문 : orrmack, Gordon V., Charles LA Clarke, and Stefan Buettcher. "Reciprocal rank fusion outperforms condorcet and individual rank learning methods." Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval. ACM, 2009. \*20 논문 : Fox, Edward A., and Joseph A. Shaw. "Combination of multiple searches." NIST SPECIAL PUBLICATION SP 243 (1994). \*21 설명 : 수학적으로는 승률이 변하지 않는 환경을 분포가 고정되어있다고('stationary'하다고) 표현하고, 승률이 계속 변하는 환경을 분포가 고정되어있지 않다고('non-stationary'하다고) 표현한다. \*22 설명 : 2017년 6월 5일 16시부터 16시 15분까지 총 15분 동안 미디어 노출 Top 1 상위 아이템 연관 추천 영역에서 네 로직을 온라인 A/B 테스트 한 결과 \*23 설명 : 전자처럼 현실에 직접 적용하는 대신 정해진 데이터셋에서 성능 평가를 하는 것을 오프라인 평가로 부르고 후자처럼 직접 현실에 적용해 실시간으로 모델을 평가하는 것을 온라인 평가로 부른다. \*24 설명 : 2017년 6월 4일 13시부터 15시, 18시부터 20시까지 카카오페이지 연관 추천 영역에서 각종 로직을 A/B 테스트한 결과. 베이스 로직은 서비스에서 기준에 사용하던 기존 로직이다.

# 알파고를 탄생시킨 강화학습의 비밀 part 1. (1/2)

강화학습(reinforcement learning) 스터디

2016년 자동차와 IT 업계의 화두 중 하나는 무인자동차였다. 도요타, 다임러-벤츠 등 굵직 굵직한 자동차 제조 회사들뿐 아니라 테슬라, 구글, 애플 등과 같은 IT 회사들도 모두 무인 자동차를 연구 개발 중에 있다. 만약 이들 회사에 자극을 받으신 회장님의 어느 날 갑자기 무인 자동차에 탑재될 주행 알고리듬을 개발하라고 지시했다면, 어떻게 이 난관을 해쳐나가야 할까? 테스트 드라이버 때 회장님이 직접 시승하겠다고 지시하셨다면 정말 안전하게 시험 주행을 마칠 수 있어야 한다. 위의 무인 자동차용 주행 알고리듬과 연관된 인공 지능에 있어서 가장 중요한 문제 중 하나는 확률계(stochastic system)에서 순차적 의사결정(sequential decision) 문제를 푸는 것이다. 앞서 예를 든 자동차 운전을 생각해보자. 우리가 엑셀을 밟고 핸들을 돌렸을 때, 자동차는 우리가 제어하는 그대로 움직이지는 않는다. 강한 바람 등의 외인, 비포장 도로 등의 원인으로 바퀴가 미끄러질 수도 있다. 이렇듯 외부의 영향으로 자동차의 상태가 우리가 예상한 것과 일치하지 않는 상황을 확률계라 지칭한다. 또한 자동차를 안전하게 운전한다는 것은 사진을 보고 사진 속의 얼굴이 누군지 분류하는 것과는 다르다. 안전하게 운전하기 위해서는 매 순간, 연속적인 결정들을 내리고, 일련의 결정들의 결과로 얻어지는 상태들이 모두 안전해야 하는 것을 의미한다. 이번 글의 주제인 '강화학습(reinforcement learning)'은 확률적 의사결정(stochastic decision) 문제를 푸는 방법론들을 지칭한다. 다른 지도학습 방법론과는 차별되는 강화학습의 몇 가지 주요 특징들에 대해 알아보자.<sup>1</sup>

글 | 최성준 : sungjoon.choi@cplab.snu.ac.kr

서울대 전기 컴퓨터 공학부를 졸업하고, 동 대학원에서 박사 과정 중에 있다. 학부 때는 리눅스 커널을 열심히 짰었고, 회사에서 청소 로봇을 만들기도 하다가, 대학원에 와서는 기계학습과 로보틱스를 결합하는 연구를 진행하고 있다. 주로 연구하는 분야는 강화 학습과 모방 학습으로 비슷한 분야의 연구자들을 항상 찾고 있다(연구 얘기는 언제든 환영입니다). 주된 업무는 크게 두 가지로 나눌 수 있는데. 하나는 논문을 읽고 쓰는 것이고 다른 하나는 영수증 및 서류 처리이다. 아, 그리고 가끔씩 회사원들을 상대로 딥러닝 수업을 하기도 한다. 박사 졸업이 가까워짐에 따라 페이스북에 자주 출몰하며 최근 들어 그 정점을 찍고 있다.

글 | 이경재 : kyungjae.lee@cplab.snu.ac.kr

서울대 전기 컴퓨터 공학부를 졸업한 뒤, 동 대학원 석박사 통합과정으로 입학하였다. 현재는 박사과정에 있으며, 주 연구 분야는 모방학습과 지능형 로보틱스이다. 좀 더 세부적으로는 역 강화 학습을 연구하고 있다. 나름 재미있는 분야라고 생각해서 시작했는데 한국에서는 비슷한 연구를 하는 연구자를 만나기 어려운 것 같아 아쉽다. 관심 있는 사람이나 이 연구를 하고 있는 사람과의 만남이라면 언제든 환영이다. 한동안 군대 문제를 해결하기 위해 연구를 접고 영어공부에 매진했으나 영어실력은 그대로라고 한다. 최근 다시 연구를 시작하였으며 인공지능 및 로보틱스 분야의 많은 사람들과 교류하고 싶다.

## 강화 학습의 의미

강화 학습을 본격적으로 다루기 전에 지도 학습(supervised learning)에 대해서 짧게 다뤄보자. 지도 학습은 학습 데이터를 통해서 유의미한 정보를 얻어내는 기계 학습 방법론에 속한다. 입력과 출력 데이터가 주어졌을 때 새로운 입력에 대한 출력을 예측하는 방법론을 지칭하며 입력과 출력 데이터가 모두 주어진 상태에서 학습을 한다고 해서 ‘지도 학습’이라 불린다. 예를 들어 강아지와 고양이 사진이 잔뜩 주어졌을 때, 새로운 사진에 있는 동물이 강아지인지 고양이인지를 맞추는 문제라 생각하면 크게 틀리지 않다. 강화 학습이 지도 학습과 대비되는 가장 큰 특징은 학습 데이터가 주어지지 않는다는 점이다. 그 대신 강화 학습 문제에 주어지는 것은 보상(reward) 함수이다. 그리고 강화 학습을 푼다는 것의 정의는 미래에 얻어질 보상값들의 평균을 최대로 하는 정책 함수를 찾는 것이다. ‘강화 학습을 푼다’의 정의는 이번 글의 가장 중요한 부분으로 다음과 같이 설명할 수 있다.

“강화 학습을 푼다는 것은 최적의 정책 함수를 찾는 것과 같다. 그리고 이 최적의 정책 함수는 불확실한 미래에 얻을 수 있는 보상 함수의 기대값을 최대로 하는 행동을 매번 고른다.” 여기서 눈여겨볼 단어가 두 개 있는데 하나는 ‘미래’라는 것이고, 두 번째는 ‘기대값’이라는 것이다. 이 두 의미만 제대로 깨달아도 강화 학습에 대해서 어느 정도는 이해했다고 볼 수 있다. 연구자들은 이 강화 학습 문제를 풀기 위해서 수학적 모델을 하나 차용했는데, 그것이 바로 마코프 의사결정 과정(Markov decision process, MDP)이다. MDP는 우리가 앞서 다룬 순차적 의사결정(sequential decision) 문제를 다루기 위해 사용하는 일종의 수학적 기술 정도로 보면 될 것 같다.

## 마코프 의사결정 과정(Markov decision process, MDP)

MDP라는 이름만 가지고도 우리는 대략적으로 이것이 무엇인지 유추할 수 있다. MDP의 첫 번째 단어인 마코프(Markov)는 19세기 수학자 앤디 마코프(Andrey Markov)의 성을 딴 마코프 특징(Markov property)을 의미한다. 마코프 특징을 직관적으로 설명하자면 현재가 주어졌을 때, 과거와 미래가 독립적임을 의미한다. 예를 들어서 내가 내일 얻을 시험 점수는 현재 내 상태와 오늘 내가 공부하는 양에만 의존함을 의미한다. 얼핏 보면 이러한 세상이 참 아름다워 보일 수 있으나 현재 상태(지금까지 얼마나 공부를 했는지)에도 의존함을 주의하자.

물론 우리의 관심인 무인자동차는 나 자신의 상태만으로는 진정한 의미의 최적을 알 수가 없다. 나쁜 아니라 도로 위 다른 운전자들의 상태도 고려해야 하지만, 이 정보는 우리가 완벽히 파악할 수 없

다. 이렇듯 나에게 주어진 것이 부분적인 정보라고 가정하는 MDP를 부분적으로 관찰가능한 마코프 의사결정 과정(partially observable Markov decision process, POMDP)이라 부른다. 최근 인텔에 약 17조 원에 인수된 모빌아이는 이러한 마코프 특징을 가정하지 않고, 강화 학습을 푸는 논문<sup>\*2</sup>을 발표하였다.

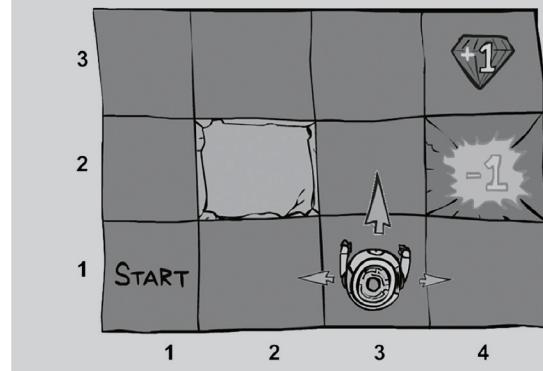
일반적인 MDP는 크게 보면 아래 네 가지로 구성된다.

- |                          |                      |
|--------------------------|----------------------|
| 1. A set of states       | 2. A set of actions  |
| 3. A transition function | 4. A reward function |

위의 네 가지를 아래의 예제를 통해 살펴보도록 하자.

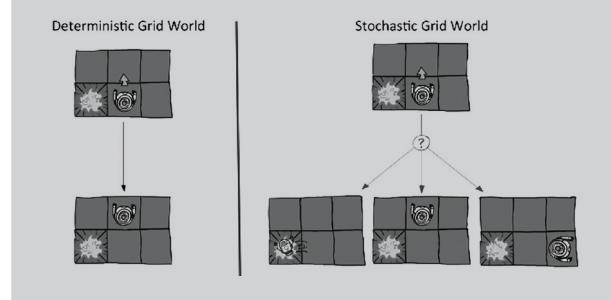
MDP를 설명하는데 있어서 가장 흔하게 사용되는 예제는 아래와 같은 격자 공간 속에 로봇이 있는 상황이다.

[그림 1] 격자 세상 속의 로봇<sup>\*3</sup>



위의 [그림1]에 나와 있듯이 로봇이 있을 수 있는 상태는 12개의 격자 중 하나이고, 이것이 상태 공간(state space)이다. 각 격자에서 로봇은 상하좌우로 이동하거나 제자리에 있을 수 있고, 이 다섯 가지의 행동이 행동 공간(action space)에 해당한다. 로봇의 격자 이동이 결정된 경우에는 원하는 방향으로 이동하게 되지만, 확률적인 경우에는 로봇이 위로 이동하려고 해도, 일정 확률로 오른쪽 혹은 왼쪽으로 이동하게 된다. 이를 확률계(stochastic system)라고 하고, 아래 그림에서 왼쪽이 결정론 세계(deterministic world), 오른쪽이 확률적 세계(stochastic world)를 나타낸다.

[그림 2] 결정론적 세계(Deterministic world)와 확률적 세계(stochastic world)



이렇듯 특정 상태에서 특정 행동을 했을 때, 다음 번에 도달할 상태들의 확률을 나타낸 것이 전이 함수(transition function)이다. 마지막으로 강화 학습에서 가장 중요한 보상 함수는 각 상태에 정의되는데, 위의 격자 공간에서 보석에 도달하면 +1의 보상을, 불에 도달하면 -1의 보상을 얻게 된다. 물론 조금 더 복잡한 모델에서는 각 상태에서 어떤 행동을 했을 때, 즉  $R(s, a)$   $R(s, a)$ 에 보상 함수가 정의되기도 한다. MDP가 주어졌을 때, 강화 학습을 푼다는 것은 기대되는 미래 보상의 합(expected sum of future reward)을 최대로 하는 정책 함수를 찾는 것을 의미한다. 여기에는 여러 의미가 담겨있는데, 한 가지 중요한 점은 미래에 얻을 보상(reward)이 포함되어 있다는 점이다. 즉 내가 현재 행동을 통해서 얻어지는 보상도 중요하지만, 궁극적으로는 현재뿐만 아니라 미래에 얻어지는 보상들도 다 고려를 해야 한다. 예를 들어서 바둑과 같은 게임을 예로 들어보면, 보상 함수는 경기가 끝나고, 계가(計家) 후에 한번 주어지게 된다. 즉 내가 현재 하는 행동의 결과가 상당히 먼 미래에 나타나게 되고, 이를 일반적으로 지연 보상(delayed return)이라 부른다. 바로 이 점이 강화 학습을 매우 어렵게 만든다. 이에 대해 자세히 살펴볼 예정이다.

다음으로 고려해야 하는 점은 우리가 확률계(stochastic system)를 가정한다는 점이다. 즉 내가 현재 어떤 행동을 한다고 해서 원하는 상태에 도달하지 못할 수도 있게 되고, 이는 같은 보상을 얻을 수 있다면, 최대한 ‘빨리’ 그 보상을 얻는 것이 더 좋음을 의미한다. 이러한 현상을 반영하는 것이 할인율(discount factor)이다. 이 값은 1보다 작은 값으로 설정되며, 시간이 지남에 따라서 얻어지는 보상에 이 값을 곱하게 된다. 만약 보상 함수에 대해 매번 보상 함수를 최대로 하는 행동을 선택하면, 그것이 최적의 정책 함수가 아닐까 하는 의문을 가질 수 있다. 하지만 이렇게 행동을 하는 것은 바둑을 둘 때 매번 상대방 돌을 잡을 수 있을 때마다 잡는 것과 비슷한 행동이다. 바둑을 잘 모르는 사람이라 하더라도, 이런 식으로 바둑을 둘 경우엔 이기기 힘들다는 것을 알고 있을 것이다. 이러한 근시안적인 방법이 잘 동작하지 않는 이유는 강화 학습의 목적이 기대되는 미래 보상의 합(expected sum of future reward)을 최대로 하는 정책 함수를 찾기 위해서이기 때문이다.

### 최적 정책 함수(optimal policy function)를 찾는 방법

그렇다면, 우리에게 MDP가 주어졌을 때, 최적의 정책 함수는 어떻게 찾을 수 있을까? 강화 학습을 푸는 가장 기본적인 방법 두 가지는 값 반복(value iteration)과 정책 반복(policy iteration)이다.<sup>4</sup> 이를 설명하기 위해서는 먼저 값(value)을 정의할

필요가 있다. 만약 우리가 특정 상태에서 시작했을 때, 얻을 수 있을 것으로 기대하는 미래 보상의 합을 구할 수만 있다면 어떨까? 즉 현재 내가 즉각적으로 얻을 수 있는 보상뿐만 아니라, 해당 상태에서 시작했을 때 얻을 수 있는 보상들의 합의 기대값을 알 수 있다면, 우리는 해당 함수를 매번 최대로 만드는 행동을 선택할 수 있을 것이고, 이렇게 최적의 정책 함수를 구할 수 있게 된다. 바로 이 미래에 얻을 수 있는 보상들 합의 기대값을 값 함수(value function),  $V(s)$ 라고 부른다. 또한 비슷하게 현재 어떤 상태에서 어떤 행동을 했을 때, 미래에 얻을 수 있는 기대 보상을 행동값 함수(action value function) 혹은  $Q$  function,  $Q(s, a)$ 라고 부른다. 값 반복(value iteration)은 바로 이 값 함수를 구하는 방법을 지칭한다. 값 함수는 현재 상태뿐 아니라 미래의 상태들, 혹은 그 상태에서 얻을 수 있는 보상을 구해야 하기 때문에 직관적으로 정의할 수 없다. 일반적으로 강화 학습에서는 이 값 함수를 구하기 위해서 벨만 이퀘이션(Bellman equation)을 활용하고, 그 식은 다음과 같다

$$V(s) = \max_a \sum_{s'} T(s, a, s') [R(s, a, s') + \gamma V(s')]$$

위의 수식은 좌변과 우변에 구하고 싶은 값 함수  $V(s)$ 가 들어가있는 재귀식(recursive equation)임을 알 수 있고,  $V(s)$ 를 제외한 나머지는 MDP와 같은 내용이다.  $V(s)$ 를 임의의 값으로 초기화하고, 모든 상태  $s$ 에 대해서 위의 재귀식을 수렴할 때 까지 수행하면 항상 최적의  $V(s)$ 를 구할 수 있다.

지금까지의 내용인 강화 학습 문제를 MDP 문제로 표현하고, 그 방법론으로 벨만 이퀘이션을 이용하여 해결하는 방식은 대부분의 교재에 나오는 내용이다. 이를 유도하는 과정에서 최적성의 원리(principle of optimality)에서 벨만 이퀘이션이 유도된다고 한 줄 적곤 한다. 최적성의 원리는 리차드 벨만(Richard Bellman, 벨만 이퀘이션의 창시자)이 정립한 내용으로, 최적의 정책 함수란, 초기 상태와 초기 행동 결정이 무엇이든지 간에 그 후에 이뤄지는 결정들이 최적의 정책 함수에서 기여를 해야한다는 내용이다.<sup>5</sup> 하지만 정말 ‘어떻게’ 벨만 이퀘이션이 유도되는지는 제대로 설명된 자료가 많지 않다. 신기하게도 MDP와 벨만 이퀘이션 사이의 관계는 MDP라는 최적의 정책 함수를 찾는 최적화 문제의 카루스-쿠-터커 조건(Karush-Kuhn-Tucker condition)을 통해서 유도가 가능하다. 이 과정이 상당히 흥미롭다. 먼저 MDP를 최적화 문제 형태로 써보면 다음과 같다.

$$\begin{aligned} \max_{\pi} \quad & \mathbb{E} \left[ \sum_{t=0}^{\infty} r^t r(s_t, a_t) \right] \\ \text{subject to} \quad & \forall s \sum_{a'} \pi(a'|s) = 1, \forall s, a \pi(a|s) \geq 0 \end{aligned}$$

최적화의 목적은 어떤 정책 함수  $\pi(a|s)$ 를 찾는 것인데, 그 함수가 주어진 MDP 조건에서 미래에 얻을 수 있는 보상의 할인된 합(discounted sum)의 기대값을 최대로 하게 하고 싶은 것이다. 위의 최적화 문제만 봐서는 벨만 이퀘이션과의 연결 고리가 쉽게 보이지 않지만, 위의 수식을 행렬 형태로 잘 변환한 후에 카루스-쿠-터커 조건을 구해보면 최적의 정책 함수가 가져야 하는 조건이 바로 벨만 이퀘이션과 동일하게 된다. 또한 이 문제는 최적화에서 말하는 강한 이중성(strong duality)을 만족하기 때문에 MDP를 푸는 것과 벨만 이퀘이션을 푸는 것은 수학적으로 동치가 된다. 벨만 이퀘이션을 직접 이용해서 값 반복(value iteration) 문제를 풀어 값(value)을 구하고, 이 값을 최대로 하는 정책(policy)을 찾으면 이것이 최적의 정책이 된다. 하지만 값 함수(value function)는 MDP 문제의 해(solution)인 최적의 정책 함수를 구하기 위해서 필요한 것이지, 그 자체가 큰 의미가 있지는 않다. 앞서 강화 학습의 정의는 최적의 정책 함수를 찾는 것임을 상기하자. 그래서 직접 정책 함수를 찾는 정책 반복(policy iteration)이 등장하게 된다.

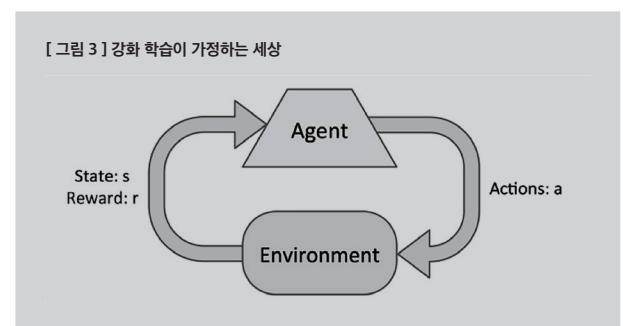
정책 반복은 값 반복과 다르게 현재 가지고 있는 정책 함수의 성능을 평가하는 정책 평가(policy evaluation)와 이를 바탕으로 정책을 개선하는 정책 개선(policy improvement)의 단계로 이뤄져 있고, 이 두 단계들을 정책 함수가 수렴할 때까지 번갈아가면서 수행한다. 일반적으로 정책 반복이 값 반복보다 빠르게 최적의 정책 함수로 수렴한다고 알려져 있다.

위에서 언급한 두 방법은 모두 모델기반 강화 학습(model-based reinforcement learning)으로 알려져 있다. 여기서 모델은 MDP에서 전이 모델(transition model)을 지칭한다. 즉 어떤 상태와 이 상태에서 어떤 행동을 한다고 했을 때, 다음 번 상태가 될 확률을 나타낸다. 얼핏 생각해서는 이 모델이 손쉽게 주어질 것이라고 예상될 수도 있다. 예를 들어 위에서 언급한 격자 공간 속에서는 각 셀에서 상하좌우로 이동을 하면 다음 번 상태가 직관적으로 유도된다. 하지만 실제 문제를 해결할 때 전이 모델은 쉽게 정의되지 않는다. 예를 들어서 강화 학습 문제를 자율주행에 적용한다고 해보자. 이 경우 MDP의 상태 공간(state space)은 어떻게 정의될까? 가장 먼저 떠오르는 것은, 자동차의 현재 위치로 정의하는 것이다. 하지만 이것은 굉장히 위험한 접근이다. 만약 MDP의 상태 공간(state space)을 자동차의 위치로 설정하게 되면 어떤 문제가 생길까? MDP에서 상태는 현재 내가 고려하고자 하는 내용들이 모두 함축적으로 담겨있는 상태이기 때문에, 내가 도로 위에서 어느 위치에 있는지, 혹은 주변 자동차들은 전혀 고려하지 않는 채 운전을 하겠다는 것과 동일한 의미이다. 그렇기 때문에 자율 주행 문제를 다룰 때 상태는 단순히 내 위치뿐만 아니라, 주변 자동차들의 상대적 위치, 도로 표지판 정보 등 운전에 필요한 모든

정보를 상태로 정의한다. 그리고 이렇게 상태 속에 여러 정보가 담겨 있기 때문에, 단순히 내가 어떤 행동을 했을 때(예를 들어, 핸들을 왼쪽으로 돌렸을 때) 미래에 내 상태가 어떻게 변하게 될지를 얻는 것은 매우 어려운 일이다

### 모델 프리 강화 학습(model-free reinforcement learning)

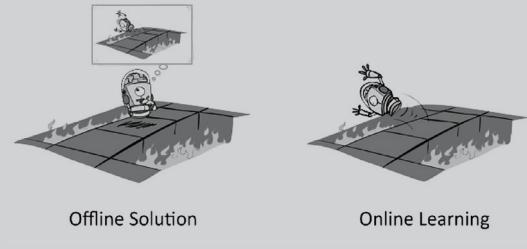
이제부터는 이렇게 MDP에서 모델이 주어지지 않았을 때 어떻게 최적의 정책 함수를 찾아내는지 알아보도록 하자. 이러한 문제를 일반적으로 모델 프리 강화 학습(model-free reinforcement learning)이라고 부른다. 사실 여기서부터가 진정한 강화 학습의 시작이라고 생각한다.



위의 [그림3]은 모델 프리 강화 학습에서 가정하는 세상을 그림으로 나타낸 것이다. 우리는 위의 그림 중 상단의 에이전트(agent)가 되어 앞과 동일한 기대되는 미래 보상의 합(expected sum of future reward)을 최대로 하는 정책 함수(policy function)를 찾고자 한다. 앞에서 설명했던 모델 기반 강화학습과의 가장 큰 차이는 더 이상 환경(environment)이 어떻게 동작되는지 알지 못한다는 점이다. 다시 말해서 우리는 주어진 상태에서 어떤 행동을 하고, '수동적으로' 환경(environment)을 알려주는 다음 번 상태와 보상(reward)을 얻게 된다. 게임을 생각하면 이해가 쉬운데, 우리의 상태는 모니터 스크린이고, 행동은 키보드 입력에 해당한다. 우리가 모니터를 보고 어떤 행동을 하게 되면, (게임 내부 코드는 모르지만) 어떤 화면이 다음 번에 나타나고, 게임 스코어 등으로 보상을 얻을 수 있다. 이러한 모델 프리 강화 학습은 모델 기반 강화 학습에 비해 몇 가지 구별되는 특징들이 있는데, 그 대표적인 것이 바로 탐사(exploration)다. 우리는 더 이상 환경이 어떻게 동작하는지 알지 못한다. 그렇기 때문에 '직접' 해보고 그 결과를 통해서 정책 함수를 점차 학습시켜야 한다. MDP 문제를 직접 푸는 모델 기반을 알지 못한다. 그렇기 때문에 '직접' 해보고 그 결과를 통해서 정책 함수를 점차 학습시켜야 한다. MDP 문제를 직접 푸는 모델 기반 강화학습은 우리에게 마치 세상에 대한 모든 설명(description)을 주고 문제를 푸는 것과 같다. 그렇기 때문에 직접 해보지 않아도,

최적의 솔루션을 얻을 수 있다. 하지만 모델 프리 강화 학습에서는 그렇지 않다. 우리가 세상과 직접 맞닥뜨려서 행동을 해보고, 그 행동의 결과인 보상만을 받아야 한다.

[그림 4] 모델 기반 강화 학습(Model-based RL)과 모델 프리 강화 학습(Model-free RL)



위의 [그림4]와 같이 모델 기반 강화 학습은 행동을 직접 해보지 않아도, 어디가 좋고, 어디가 나쁜지 알 수 있지만, 모델 프리 강화 학습은 직접 해보고 난 후에야 결과를 알 수 있다. 이 경우에는 새로운 것을 탐사하는 것이 상당히 중요한 이슈가 된다. 내가 현재 까지 알고 있는 사실을 좀 더 파고 들어서 더 좋은 결과를 얻으려고 하는 것을 개척(exploitation), 새로운 것들을 시도하는 것을 탐사(exploration)라 하고, 이 둘 사이를 잘 조정하는 것을 개척과 탐사의 트레이드오프(exploitation and exploration tradeoff)라 한다. 실제 문제에 강화학습을 적용할 때 매우 중요한 부분이다.

이렇게 정의된 모델 프리 강화 학습을 어떻게 풀 수 있는지 생각해보자. 앞서 모델 기반 강화 학습에 사용된 벨만 이퀘이션을 적어보면 다음과 같다.

$$V(s) = \max_a \sum_{s'} T(s, a, s')[R(s, a, s') + \gamma V(s')]$$

위의 수식에서  $T(s, a, s')$ , 바로 이 부분을 우리가 모르기 때문에 벨만 이퀘이션을 직접 활용할 수는 없다. 정책 평가는 위에서  $a$ 를  $\pi(s)$ 로 치환해, 주어진  $\pi$ 를 평가하는 방법론이다. 이 수식을 다시 한번 적어보면 아래와 같다.

$$V(s) = \sum_{s'} T(s, \pi(s), s')[R(s, \pi(s), s') + \gamma V(s')]$$

이 수식을 잘 들여다보면 새로운  $V(s)$ 에 대한 업데이트(update)는  $R(s, \pi(s), s') + \gamma V(s')$ 의 가중치의 합(weighted sum)으로 볼 수 있다. 그리고 가중치에 해당하는  $T(s, \pi(s), s')$ 는 사실 우리가 모르긴 하지만, 만약 우리가 다음 상태(state)인  $s'$ 이 이  $T$ 라는 모델에서 나왔다면, 우리는 이 가중치 합을 표본 평균(sample mean)으로 대체할 수 있게 된다. 이런 식으로 벨만 이퀘이션을 표본화(sampling)로 대체하는 방법론 중 하나가 temporal

difference(TD) 학습(learning)이다

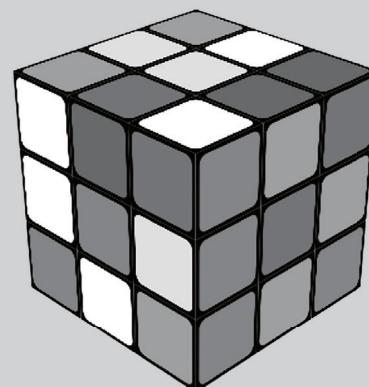
TD 학습의 제일 중요한 철학 중 하나는 모든 경험을 통해서 학습을 하자는 것이다. MDP에서 경험은 내가 어떤 상태  $s$ 에서 주어진 정책 함수를 통해서 어떤 행동을 하고( $a=\pi(s)$ ), 그리고 그 결과로 다음번 상태  $s'$ 과 보상  $r$ 을 받는 것을 의미한다. 그리고 이런  $(s, a, s', r)$ 들로 이뤄진 경험들이 누적되었을 때, 이 데이터들을 바탕으로 값 함수(value function)  $V(s)$ 와 행동 값 함수(action value function)  $Q(s, a)$ 를 학습하게 된다.

구체적으로 TD 학습을 하면 값을 구할 때, 지수이동평균(exponential moving average, EMA)을 활용한다. 즉 나에게 새로운 값에 대한 추정값이 들어오면 이를 직접 사용하는 것이 아니라 기존 값과  $\alpha$ 의 비율로 섞은 후에 업데이트하는 식이다. 정리해보자면 모델프리 강화학습에서 정책 평가는 다음과 같다.

$$V^\pi(s) \leftarrow (1 - \alpha)V^\pi(s) + \alpha [R(s, \pi(s), s') + \gamma V^\pi(s')]$$

더 이상 모델  $T(s, a, s')$ 이 필요 없기 때문에 모델 없이도 주어진 정책 함수를 샘플링을 통해서 구할 수 있다. 하지만 이 방식엔 치명적인 단점이 하나 존재한다. 그것은 우리가 현재 가지고 있는  $\pi$ 에 대한 값 함수(value function)  $V^\pi(s)$ 를 구했다치더라도 이를 가지고 더 나은 정책  $\pi'$ 를 구할 수 없다는 것이다. 이는 내가 어느 상태가 좋은지는 분명 알고 있는데, 그 상태로 ‘어떻게’ 가야 하는지를 모르는 것과 같다. 대표적인 예가 루빅스 큐브일 것이다.

[그림 5] 루빅스 큐브



분명 모든 면이 같은 색을 갖는 상태가 가장 좋은 상태임을 알고 있지만, 우리가 가지고 있는 값 함수  $V(s)$ 는 어떤 행동을 해야지 특정 상태로 가는지를 알 수 없기 때문에 좋은 상태로 ‘어떻게’ 가야 하는지는 알 수가 없다. 하지만 행동 값 함수  $Q(s, a)$ 를 구할 수 있다면 얘기가 달라진다. 이 경우는 각 상태에서 어떤 행동을 했을 때, 얻을 수 있는 기대되는 미래 보상의 합(expected sum of future

reward)을 구하기 때문에, 모델 없이도 최적의 행동을 구할 수 있다. 벨만 이퀘이션을  $Q(s,a)$ 에 대해서 구한 식은 다음과 같다.

$$Q(s, a) \leftarrow \sum_{s'} T(s, a, s') \left[ R(s, a, s') + \gamma \max_{a'} Q(s', a') \right]$$

바로 위의 수식을 이용해서 행동 값 함수  $Q(s,a)$ 를 업데이트 할 수 있다. 물론 위의 수식에 있는  $T$ 를 표본 추정(sample estimate)으로 교체할 수 있고, 이렇게 하면 다음과 같은 수식을 얻을 수 있게 된다.

$$Q(s, a) \leftarrow (1 - \alpha)Q(s, a) + \alpha \left[ R(s, a, s') + \gamma \max_{a'} Q(s', a') \right]$$

위의 수식을 이용해서 강화 학습 문제를 푸는 것을 off-policy learning 혹은 Q러닝(Q-learning)이라고 한다. 위의 수식을 이용해서 Q함수를 업데이트하기 위해서 우리에게 필요한 것은  $(s, a, s', r)$ 들의 경험이다. 즉 어떤 상태에서 어떤 행동을 하고, 다음 번 상태를 관측하고, 이때 얻어지는 보상까지만 있으면 위의 수식을 이용해서 Q함수를 구할 수 있다. Q러닝이 가지는 장점은 모델을 모르는 상태에서도 최적 정책 함수(optimal policy function)를 구할 수 있다는 점이다. 그리고 Q함수의 정의에 따라서 최적 정책(optimal policy)은 다음과 같이 구해진다.

$$\pi(s) = \arg \max_a Q(s, a)$$

여기서 증명을 하지는 않겠지만,  $(s, a, s', r)$ 에 있어서 우리가 각 상태에서 임의의 행동을 하면서 데이터를 수집해도, 이러한 경험들로 얻어지는  $Q(s, a)$ 는 항상 최적의  $Q(s, a)$ 로 수렴하게 된다.<sup>6</sup> 내가 항상 임의의 행동을 하면서 경험을 수집해도 이런 엉망인 데이터로 얻어지는  $Q(s, a)$ 는 항상 최적의 값으로 수렴하고, 우리는 항상 최적의 정책 함수를 찾을 수 있게 된다. 그리 직관적이지는 않지만 이것은 증명된 사실이다. Q러닝이 절대 만능은 아니다. 모델 프리 강화 학습의 가장 큰 단점은 탐사(exploration)이다. 강화 학습 특징상 보상을 마지막에 한번, 혹은 띠엄띄엄 주는 경우가 있다. 이러한 경우에 우리의 경험이 유의미한 보상이 있는 지역을 가보지 못했다면 절대로 올바른 정책을 얻을 수가 없다. 이러한 탐사가 갖는 어려움은 상태 공간(state space)이 커짐에 따라서 더 부각된다.

이제부터 이러한 Q러닝을 딥러닝 기법과 결합한 방법론들을 살펴볼 것인데, 딥러닝과 강화 학습을 결합한 딥강화 학습(deep reinforcement learning, DRL)에서 가장 중요한 것 중 하나가 이 탐사(exploration)을 얼마나 잘 하는가라고 해도 전혀 부족함이 없을 것이다. DRL은 크게 두 가지 관점에서 바라볼 수 있다. 하나는 DeepMind사에서 발표해 유명해진 DQN이란 방법론이고, 다른

하나는 정책 경도(policy gradient) 방법론이다. 물론 각 방법마다 장점과 단점이 명확히 있다. 이제부터 하나씩 알아보도록 하자.

먼저 DQN에 대해서 살펴보자.<sup>7</sup> DQN은 현재의 DeepMind사를 최고의 AI회사로 만들어준 알고리듬이라 할 수 있다. 딥마인드의 알파고는 작년 이세돌과의 대국에 이어 커제와의 대국에서도 승리하였다. 만약 DQN이 없었다면 현재의 딥마인드도 없었을 수 있고, 현재의 알파고가 없었을 수도 있다(그리고 미래의 스카이넷...)。

사실 강화학습의 알고리듬적 관점에서 DQN은 그다지 새로울 것은 없다. 앞서 살펴본 Q러닝의 수식을 다시 한번 살펴보자.

$$Q(s, a) \leftarrow \sum_{s'} T(s, a, s') \left[ R(s, a, s') + \gamma \max_{a'} Q(s', a') \right]$$

위 수식이 가지는 가장 큰 장점이라면 우리가 환경(environment)에 대한 그 어떤 정보 없이도, 어떤 시뮬레이터나 프로그램을 통해서 구할 수 있다면, Q함수에 대한 업데이트를 할 수 있다는 점이다. 사실 이것은 생각보다 엄청난 의의를 가지고 있다. 왜냐하면 RL이 기존의 SL(지도학습)에 비해서 가지는 어려움이 기대되는 미래 보상의 합을 고려한다는 점인데, 위의 수식을 통해 단순히 하나의 경험만으로도 Q함수를 업데이트시킬 수 있다는 것이다. 게다가  $(s, a, s', r)$ 에서  $(s, a)$ 를 고를 때 임의의 행동  $a$ 를 매번 고른다 하여도 무한한 시간이 흐른 뒤에  $Q(s, a)$ 는 항상 최적의 행동 값 함수(action value function)로 수렴한다는 점 역시 아주 좋다.

위 수식의 우변은 만약 우리가 현재  $Q(s, a)$  함수를 안다면 손쉽게 구할 수 있다( $\max_{a'} Q(s', a')$ 을 구하기 위해서는 가능한 행동  $a$ 의 수가 유한해야 한다. 다시 말해 모든 가능한 행동을 다 집어 넣고, 제일 큰 Q값이 나오는 행동을 고르면 된다) 그리고 좌변의  $Q(s, a)$ 를 어떤 입력  $(s, a)$ 에 대한 Q 함수의 출력값이라 하고, 우변을 해당 입력에 대한 목적(target)이라고 본다면 위의 Q함수에 대한 벨만 이퀘이션은 우리가 SL에서 많이 사용하는 회귀 함수(regression function)에 대한 입출력쌍을 만들어주는 것으로 해석할 수 있다(다음 호에서 계속됩니다).

\*1 참고 : Andrew Ng, "Shaping and policy search in Reinforcement learning", PhD Thesis, 2003 \*2 논문 : Shai Shalev-Shwartz, Shaked Shammah, Amnon Shashua, "Safe, Multi-Agent, Reinforcement Learning for Autonomous Driving", ArXiv, 2016 \*3 자료 : UC Berkeley CS188 Intro to AI 수업 자료, [http://ai.berkeley.edu/lecture\\_videos.html](http://ai.berkeley.edu/lecture_videos.html) \*4 논문 : Sutton, Richard S., and Andrew G. Barto, "Reinforcement learning: An introduction", Cambridge: MIT press, 1998. \*5 책 : Richard Bellman, "Dynamic Programming". Princeton University Press, 1957 \*6 논문 : Steven Bradtke and Michael Duff "Reinforcement learning methods for continuous-time Markov decision problems," NIPS, 1995 \*7 논문 : Mnih, Volodymyr, et al. "Human-level control through deep reinforcement learning." Nature, 2015

# AI 그리고 미래사회를 위한 책들

## 카카오 ‘임팩트 북클럽’이 추천하는 AI 관련 도서

카카오에는 ‘임팩트 북클럽’이라는 독서 모임이 있습니다. 매달 2권을 정해 점심 시간에 도시락을 먹으며 독서 토론회를 진행한 지가 벌써 1년이 훌쩍 넘었고, 함께 읽으며 열띤 토론을 나눈 책의 숫자는 어느새 32권이 되었습니다. 처음에는 기업이 미래 사회를 대비하며 해야 할 역할에 대한 고민에서 출발했는데, 시간이 지나면서 점차 ‘인간과 기계’, ‘AI가 가져올 미래’에 집중되고 있더군요. 이것이 우연일까요, 아니면 필연일까요. 북클럽 멤버들은 각자 자리에서 자신이 만드는 카카오 서비스들을 대할 때, 함께 나눴던 독서토론이 통찰력을 키우는데 많은 보탬이 되었다고 입을 모아 말합니다. 이런 인사이트를 더 많은 분들과 함께 나누면 좋겠다는 마음에, 카카오 북클럽 멤버들이 읽은 책들 중, AI가 화두가 된 이 시대를 사는 누구에게나 권해도 좋을 책 몇 권을 소개드립니다.



글 | 김연지 : may.kim@kakao.com

2000년 다음커뮤니케이션에 입사, 국내에서 ‘인터넷=한메일’로 통하던 시기에 한메일 개발자로 사회생활을 시작, 유저와 맞닿은 서비스부터 백엔드 시스템까지 다양한 IT 프로젝트의 개발과 PM을 맡아왔다. 개발자의 시선으로 이슈를 바라보고 근본적인 해결 방법을 찾아내는 것을 즐기며, 함께 일하는 사람들을 신나게 하는데 관심이 많은, 개발자 스테레오타입 하면 떠오르는 모습과는 조금 다른 캐릭터. 관심사는 미래와 인간공동체. 카카오 임팩트 북클럽을 리딩하고 있다.

**인에비터블 : 미래의 정체**

와이어드(WIRED) 공동 창간자이자 뉴욕타임스가 '위대한 사상가'라고 칭한 케빈 켈리의 최신작입니다. 그는 미래 예측 방법으로, 역사의 흐름상 불가피해 보이는 경향성이 있다는 신선한 아이디어를 생각해냅니다. 그 불가피한 경향성 12가지를 바탕으로 미래를 그려 갑니다. 중간 중간 저자의 인사이트를 담은 미래 사회 상상 내레이션은 마치 눈 앞에서 영화를 보는 듯 생생합니다. 미래를 너무 아름답게만 본 것이 아닌가 싶기도 한데, 저자가 언급하지 않은 정치, 정책 부분들은 우리가 채워가야 할 부분이겠지요.

저자 | 케빈 켈리(Kevin Kelly)

**제리 카플란 인공지능의 미래**

전작 '인간은 필요 없다'에서 인공지능 시대의 도래를 예견했던 스탠퍼드대학교 법정보학센터 교수인 카플란은 이 책을 통해 AI 기술에 대한 높은 이해를 바탕으로 법과 윤리, 사회 전반에 AI가 미칠 영향을 분석하고 있습니다. 특히 인공지능 시대를 맞아 '인간은 어떻게 AI와 공존할 것인가'라는 주제 아래 사회적, 법적, 철학적, 경제적 이슈별로 다양한 시각에서 인공지능의 미래를 예측하고 있습니다. 세부적인 기술 관련 설명보다는 전반적인 변화의 트렌드를 파악하고 싶은 독자들에게 추천할만 합니다.

저자 | 제리 카플란(Jerry Kaplan)

**마스터 알고리즘**

과연 스카이넷이 등장할 수 있을 것인가. 이 이슈에 대해서는 찬반 의견이 팽팽합니다. 스카이넷, 특이점, 초인공지능 등을 말하자면 기계가 '의식'을 갖게 되는 것을 달리 표현한 말들이라고 할 수 있습니다. 저자인 페드로 도밍고스는 이를 '마스터 알고리즘'이라고 명명하면서, 어떻게 마스터 알고리즘을 만들어 낼 수 있을지에 대해 이야기합니다. 현존하는 머신러닝의 여러 개념들을 통찰력 있는 아이디어로 분류하고 설명하고 있어서 다소 난이도가 있지만 머신러닝 기술 전반에 대해 정리하기 좋은 책입니다.

저자 | 페드로 도밍고스(Pedro Domingos)

**노동 없는 미래**

AI가 바꿔갈 세상에 대한 기대와 걱정이 많이 있습니다. 가장 큰 걱정은 AI가 내 직업을 대신하지 않을까 하는 점입니다. 이 책은 일과 노동의 가치를 다양한 측면에서 고민하며, AI의 시대를 맞아 미래의 일과 노동은 과연 어떻게 될 것인지에 대해서 이야기하고 있습니다. 저자는 노동 없는 미래가 결국 인류가 생존을 위해 억압적으로 일해야 하는 상황에서 자유로워지는 것이라고 강조합니다. 나의 직업이 없어진다면, 과연 난 행복한 미래를 맞이할 수 있을까요? 그에 대한 답을 찾을 수 있기를 기대합니다.

저자 | 팀 던롭(Tim Dunlop)

**알렉로스의 미래산업보고서**

IT 혁신 전문가 알렉 로스가 자신의 경험을 바탕으로 '현재와 미래 사회와 산업'에 대한 통찰을 담아낸 책입니다. 로봇공학, 생명공학, 신뢰의 코드화(블록체인), 데이터, 농업, 글로벌 시장구조까지 광범위하게 다루며, 다양한 사례와 데이터를 바탕으로, 먼 미래가 아닌, 바로 닥쳐올 미래의 모습에 대해 구체적으로 설명하고 있습니다. 알렉 로스는, 결국 적응하는 사람이 살아남는 시대이니, 다음 세대 아이들은 평생 동안 새로운 지식을 배우는데 능한 사람으로 길러져야 한다고 조언합니다.

저자 | 알렉 로스(Alec Ross)

**사피엔스**

미래를 보려면 과거를 이해해야 하는 것은 기본. 저자 유발 하라리는 특유의 시선으로 인류의 역사를 통찰합니다. 인간이기에 우리가 놓쳤던 부분들에 대한 날선 지적들, 농업 혁명은 '인류 최대의 사기'라는 해석, 제도는 모두 미신이라는 설명, 그리고 결국 신이 되어가는 인간에 대한 이야기까지 어디 하나 빼놓을 부분 없이 흥미롭습니다. 사피엔스가 과거 인류 역사에 대한 통찰이라면, 그의 최신작 '호모 데우스'는 현재와 미래에 대한 인사이트를 가득 담았습니다. 함께 읽는 것을 추천드립니다.

저자 | 유발 하라리(Yuval Noah Harari)

**생각에 관한 생각**

기계와 사람의 다른 점은 무엇인가, 혹은 인공지능 대비 인간 지능의 특징은 무엇인가라는 질문들의 출발점인 인간의 인지 방식에 대한 궁금증을 해소해 주는 바이블 같은 책입니다. 저자는 노벨경제학상을 받은 최초의 심리학자이자 행동경제학을 개척한 학자입니다. 대니얼은 '인간'은 합리적으로 사고한다는 기준의 패러다임을 뒤집었는데, 그 이유의 일례로 우리의 사고, 인지 방식 자체에 편향이 있기 때문이라고 설명합니다. 연관 도서로 데이비드 핸드(David J. Hand)가 쓴 '신은 주사위 놀이를 하지 않는다'도 추천할만 합니다.

저자 | 대니얼 카너먼(Daniel Kahneman)

**The AI Revolution**

친근감 넘치는 그림과 글로 다양한 주제를 재미있게 설명하는 온라인 미디어 'Wait But Why'에 2회에 걸쳐 게재된 AI 관련 글입니다. AI 전반에 걸쳐 악인공지능, 인간공지능, 초인공지능, AI 혁명의 의미 등의 주제를 대중 눈높이에서 흥미진진하게 풀어갑니다. 기술 발전도 중요하지만, 많은 이들의 이해와 정책적인 준비도 발을 맞춰야 한다는 메시지를 던집니다. AI 단일 주제로는 레이 커즈와일의 '특이점이 온다'를 제외하고 가장 많이 읽힌 글로, 댓글에는 전문가들의 열띤 토론 내용들로 가득합니다.

저자 | 팀 어반(Tim Urban)

# 마치며

인공지능(AI) 기술이 향하는 최종 기착지는 결국 우리 ‘인간’ 인듯 합니다. 인간처럼 보고, 듣고, 말하고, 판단할 수 있는 기계는 역설적으로 과연 ‘인간다움’이 무엇인가를 반추하게 합니다. 우리 스스로를 정의할 수 없다면 우리의 닮은 꼴인 AI가 갖게 될 ‘인간다움’은 어떻게 정의할 수 있을까요? AI의 시대, 다양성(diversity)과 윤리, 철학의 가치가 다시 주목받는 이유입니다.

카카오 AI 리포트 4호에서는 AI 연구에 내재된 다양성 부족 문제에 주목했습니다. 편향된 AI 알고리듬은 편향된 데이터에, 편향된 데이터는 결국 우리 사회의 편견들에 뿌리를 두고 있습니다. 여성, 소외계층 등 소수자 그룹들의 적극적인 참여를 통한 다양성 강화 노력처럼, 카카오 AI 리포트 역시 AI 기술과 연관된 사회적, 기술적, 정책적 문제와 이슈들을 함께 고민할 수 있는 소통의 장이 되도록 노력하겠습니다.

카카오 AI 리포트는 모두에게 ‘열린’ 채널입니다. AI 기술에 대한 새로운 시각, 진지한 통찰과 고민을 담은 글이라면 언제나 환영합니다. AI가 ‘모두를 위한 기술’이어야 하듯, 저희 리포트 역시 AI에 관심 있는 모두를 위한 리포트가 되길 원합니다. 많은 분들의 참여와 관심을 부탁드립니다.



