

자아 중심 주제 인용분석을 활용한 딥러닝 연구동향 분석*

Deep Learning Research Trends Analysis with Ego Centered Topic Citation Analysis

이재윤 (Jae Yun Lee)**

초 록

최근 들어 다양한 분야에서 딥러닝이 혁신적인 기계학습 기법으로 급속하게 확산되고 있다. 이 연구에서는 딥러닝 연구동향을 분석하기 위해서 자아 중심 주제 인용분석 기법을 변형하여 응용해보았다. 이를 위해 Web of Science에서 'deep learning'으로 탐색하여 검색된 문헌 중 소수의 씨앗 문헌으로부터 인용 관계를 통해 분석 대상 문헌을 확보하는 방법을 시도하였다. 씨앗 문헌을 인용하는 최근 논문들을 딥러닝 분야의 현행 연구를 반영하는 자아 문헌집합으로 설정하였다. 자아 문헌으로부터 빈번히 인용된 선행 연구들은 딥러닝 분야의 연구 주제를 나타내는 인용 정체성 문헌집합으로 설정하였다. 자아 문헌집합에 대해서는 공저 네트워크 분석을 비롯한 정량적 분석을 실시하여 주요 국가와 연구 기관을 파악하였다. 인용 정체성 문헌들에 대해서는 동시인용 분석을 실시하고, 도출된 문헌 군집을 인용하는 주요 키워드인 인용 이미지 키워드를 파악하여 주요 문헌과 주요 연구 주제를 밝혀내었다. 마지막으로 특정 주제에 대한 인용 영향력이 성장하는 추세를 반영하는 인용 성장지수 CGI를 제안하고 측정하여 딥러닝 분야의 선도 연구 주제가 변화하는 동향을 밝혔다.

ABSTRACT

Recently, deep learning has been rapidly spreading as an innovative machine learning technique in various domains. This study explored the research trends of deep learning via modified ego centered topic citation analysis. To do that, a few seed documents were selected from among the retrieved documents with the keyword 'deep learning' from Web of Science, and the related documents were obtained through citation relations. Those papers citing seed documents were set as ego documents reflecting current research in the field of deep learning. Preliminary studies cited frequently in the ego documents were set as the citation identity documents that represents the specific themes in the field of deep learning. For ego documents which are the result of current research activities, some quantitative analysis methods including co-authorship network analysis were performed to identify major countries and research institutes. For the citation identity documents, co-citation analysis was conducted, and key literatures and key research themes were identified by investigating the citation image keywords, which are major keywords those citing the citation identity document clusters. Finally, we proposed and measured the citation growth index which reflects the growth trend of the citation influence on a specific topic, and showed the changes in the leading research themes in the field of deep learning.

키워드: 딥러닝, 기계학습, 연구동향 분석, 자아중심 주제인용분석, 공저 네트워크, 동시인용분석, 인용 이미지 키워드, 인용 성장지수

deep learning, machine learning, research trends analysis, ego centered topic citation analysis, coauthorship networks, co-citation analysis, citation image keywords, citation growth index

* 이 논문의 일부 내용은 제24회 한국정보관리학회 학술대회(2017년 8월 22일)에서 발표된 바 있음.

** 명지대학교 문헌정보학과 부교수(memexlee@mju.ac.kr)

■ 논문접수일자: 2017년 9월 28일 ■ 최초심사일자: 2017년 10월 11일 ■ 게재확정일자: 2017년 10월 11일

■ 정보관리학회지, 34(4), 7-32, 2017. [http://dx.doi.org/10.3743/KOSIM.2017.34.4.007]

1. 서론

최근 각광을 받고 있는 기계학습 기법인 딥러닝(deep learning)은 인공 신경망에 기반하여 발전하였으며 음성 인식, 영상 객체 인식, 물체 탐지, 신약 발견 및 유전체학과 같은 많은 영역의 최첨단 기술을 획기적으로 개선하고 있다(LeCun, Bengio, & Hinton, 2015). 딥러닝이 급속도로 주목을 받으면서 국내 연구도 활발히 이루어지고 있다. 한국학술지인용색인 KCI에서 “딥러닝” OR “딥 러닝”으로 검색하면 122건의 논문이 파악되는데(2017년 9월 25일 현재), 이중에서 95%인 116건이 2016년 이후에 발표되었으며 논문이 게재된 저널도 48종에 이를 정도로 국내에서도 연구가 급속하게 확산되고 있다. 게재 저널의 소속 분야도 공학만 아니라 복합학, 사회과학, 인문학, 자연과학, 예술체육에 이르기까지 광범위하게 나타나고 있다.

이처럼 급속하게 성장하면서 다양한 분야로 폭넓게 확산되고 있는 딥러닝 연구 동향에 대한 계량적인 분석은 관련 분야의 연구 및 정보서비스 활성화에 필요할 뿐만 아니라, 계량서지학의 측면에서도 도전적인 과제이다. 전통적인 계량서지적 분석은 특정 학문분야 문헌이나 특정 저널에 게재된 문헌에 대한 분석을 주로 다루고 있는 반면에, 딥러닝은 최근 수 년동안 급속하게 성장하면서 한 두 분야에 머무르지 않고 광범위하게 확산되고 있어서 데이터 수집 방법과 분석 방법 측면에서 새로운 시도가 필요하다.

이 연구에서는 자아 중심 주제 인용분석(이재운, 2012)의 개념을 활용하여 딥러닝 관련 최

근 국제 연구 문헌에 대한 계량서지적 분석을 시도해보았다. 자아 중심 주제 인용분석은 연구자를 대상으로 하는 White(2000)의 자아 중심 인용분석 기법을 특정 주제 분야에 적용하도록 응용한 기법이다. 특정한 주제와 관련된 연구문헌들을 자아 문헌집합(ego documents)으로 설정하고 이들이 인용한 주요 문헌들로 주제 인용 정체성(topic citation identity)을 구성한다(이재운, 2012). 자아 중심 인용 분석을 주제 인용에 적용한 국내 사례는 독서치료 분야를 대상으로 한 장윤미(2013)의 연구가 있고, 인용이 아닌 키워드 네트워크에 적용한 유소영(2015)의 연구도 있다.

딥러닝과 같이 폭넓은 영역으로 급속하게 연구가 확산되고 있는 주제에 대한 자아 문헌집합을 설정하는 새로운 접근으로 소수의 씨앗 문헌(seed documents)으로부터 출발하는 방법을 시도해보았다. 1차적으로 관련 분야의 핵심 문헌으로서 빈번히 인용되고 있는 소수의 문헌을 씨앗 문헌으로 확보한 후, 이로부터 인용 관계의 단계적 확장을 실시하여 분석 대상 문헌집합을 확보하는 방법을 제시하였다. 이 방법에 따라 확보된 딥러닝 분야의 최근 연구를 포함하는 자아 문헌집합에 대한 양적인 분석과, 이들의 주요 선행 연구에 해당하는 인용 정체성 문헌 집합에 대한 동시인용 분석을 각각 실시하고 그 결과를 상세히 분석하였다. 분석 소프트웨어로는 WNet(이재운, 2013)과 CitNetExplorer(Van Eck & Waltman, 2014)를 활용하였으며, 데이터 수집 및 분석 방법은 2장에서 소개하고 3장과 4장에서 상세한 분석 결과를 제시하였다.

2. 데이터 수집 및 분석 방법

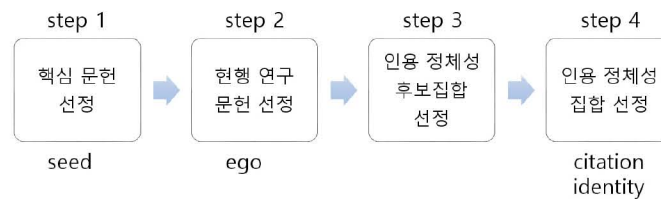
2.1 분석 데이터 수집

이 연구에서 딥러닝 분야의 현행 연구를 반영한 자아 문헌집단과 이들이 주로 참고한 인용 정체성 문헌집합을 선정하는 절차는 〈그림 1〉과 같다.

우선 1단계로 Web of Science에서 ‘core collection’ 데이터베이스를 대상으로 ‘deep learning’으로 ‘Topic’ 검색(제목, 초록, 키워드 필드 대상 검색)을 2017년 6월 14일 오전에 실시하였다. 그 결과 1,877건이 검색되었으나 이 중에는

전혀 다른 주제인 교육학 분야의 ‘심층 학습’에 해당하는 논문이 상당수 포함되어 있었다. 〈표 1〉과 같이 ‘EDUCATION EDUCATIONAL RESEARCH’ 범주 소속 논문이 217건(11.6%), ‘EDUCATION SCIENTIFIC DISCIPLINES’ 범주 소속 논문이 114건(6.1%)이나 되었다. 이런 범주의 논문을 일괄 제거하더라도 여전히 인간의 심층 학습을 의미하는 논문이 남아 있었다. 예를 들어 〈그림 2〉의 논문은 인간의 심층 학습을 다루지만 인공지능 분야 저널인 *Applied Artificial Intelligence*에 게재되었다.

이처럼 검색 결과로부터 인공지능의 딥러닝을 다루지 않은 논문을 한꺼번에 제거하기는



〈그림 1〉 분석 대상 문헌집합 추출 과정

〈표 1〉 1차 검색 결과 1,877건의 상위 10개 WoS 범주

순위	Web of Science 범주	건수	%
1	ENGINEERING ELECTRICAL ELECTRONIC	436	23.2
2	COMPUTER SCIENCE ARTIFICIAL INTELLIGENCE	412	22.0
3	EDUCATION EDUCATIONAL RESEARCH	217	11.6
4	COMPUTER SCIENCE INFORMATION SYSTEMS	160	8.5
5	COMPUTER SCIENCE INTERDISCIPLINARY APPLICATIONS	148	7.9
6	COMPUTER SCIENCE SOFTWARE ENGINEERING	128	6.8
7	EDUCATION SCIENTIFIC DISCIPLINES	114	6.1
8	IMAGING SCIENCE PHOTOGRAPHIC TECHNOLOGY	112	6.0
9	COMPUTER SCIENCE THEORY METHODS	95	5.1
10	RADIOLOGY NUCLEAR MEDICINE MEDICAL IMAGING	84	4.5
(11위 이하 범주 생략)			
합계		1,877	100.0

Learning by teaching: A new agent paradigm for educational software

저자: Biswas, G (Biswas, G); Leelawong, K (Leelawong, K); Schwartz, D (Schwartz, D); Vye, N (Vye, N)

그룹 저자: Teachable Agents Grp Vanderbilt

APPLIED ARTIFICIAL INTELLIGENCE

권: 19 호: 3-4 페이지: 363-392

DOI: 10.1080/08839510590910200

출판연도: MAR 2005

[학술지 정보 보기](#)

초록

This paper discusses Betty's Brain, a teachable agent in the domain of river ecosystems that combines learning by teaching with self-regulation mentoring to promote **deep learning** and understanding. Two studies demonstrate the effectiveness of this system. The first study focused on components that define student-teacher interactions in the learning by teaching task. The second study examined the value of adding meta-cognitive strategies that governed Betty's behavior and self-regulation hints provided by a mentor agent. The study compared three versions: a system where the student was tutored by a pedagogical agent, a learning by teaching system, where students taught a baseline version of Betty, and received tutoring help from the mentor, and a learning by teaching system, where Betty was enhanced to include self-regulation strategies, and the mentor provided help on domain material on how to become better learners and better teachers. Results indicate that the addition of the self-regulated Betty and the self-regulation mentor better prepared students to learn new concepts later, even when they no longer had access to the SRL environment.

〈그림 2〉 인공지능 분야 저널에 게재된 교육학의 심층 학습 관련 논문 사례

쉽지 않다. 그 대신 이 연구에서는 소수의 씨앗 논문으로부터 단계적으로 확장하여 분석 대상 논문집합을 확장하는 방식으로 전환하였다. 1차 검색 결과 논문 1,877건 중에서 인용횟수 최상위권 논문을 핵심 문헌으로 선정하고자 하였다. 인공지능의 딥러닝을 다룬 인용횟수 최상위권 논문 중에서 61회 인용된 15위와 49회 인용된 16위 사이의 간격이 두드러지게 벌어져 있고, 17위 이하부터는 순위 사이의 인용횟수 간격이 1회 이하로 촘촘하게 몰려있었다. 결국 15위 이상의 논문들이 16위 이하의 논문들에 비해서 두드러지게 인용횟수가 큰 차별화된 집합이었으므로, 이들을 〈표 2〉와 같이 선택하여 씨앗 논문에 해당하는 딥러닝 핵심 문헌으로 선정하였다.

딥러닝 분야 자아 문헌집합과 인용 정체성 집합을 확보하는 2단계부터 4단계까지의 과정은 인용관계를 이용하여 〈그림 3〉과 같이 수행


하였다.

2단계에서는 씨앗 문헌 15건을 인용한 문헌을 수집한 결과 총 2,007건이 확보되었다. 이들은 딥러닝 관련 핵심 문헌을 인용하면서 수행된 연구 결과물로서 딥러닝 현행 연구문헌 집합이며 딥러닝 관련 자아(ego) 문헌들이라고 할 수 있다. 딥러닝 현행 연구문헌 2,007건이 속한 주요 분야는 〈표 3〉과 같으며 〈표 2〉에 나타났던 교육학 분야는 밀려나고 생명과학 분야가 주요 분야에 일부 포함된 것이 눈에 띈다. 현행 연구 문헌에 대한 분석은 3장에서 다루었다.

3단계에서는 딥러닝 연구의 자아 문헌집합에 해당하는 현행 연구문헌 2,007건이 인용한 문헌들을 확인하여 인용 정체성이 될 수 있는 후보 집합을 구성하였다. 2,007건 현행 연구 문헌들의 서지사항과 참고문헌 정보를 다운로드한 후 CitNetExplorer 프로그램(Van Eck & Waltman, 2014)으로 참고문헌을 일괄 추출

〈표 2〉 Deep learning 핵심 문헌 15건

인용	제목	저자	학술지	연도
900	Deep learning	LeCun, Yann; Bengio, Yoshua; Hinton, Geoffrey	NATURE	2015
707	Representation Learning: A Review and New Perspectives	Bengio, Yoshua; Courville, Aaron; Vincent, Pascal	IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE	2013
649	Dropout: A Simple Way to Prevent Neural Networks from Overfitting	Srivastava, Nitish; Hinton, Geoffrey; Krizhevsky, Alex; Sutskever, Ilya; Salakhutdinov, Ruslan	JOURNAL OF MACHINE LEARNING RESEARCH	2014
621	Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion	Vincent, Pascal; Larochelle, Hugo; Lajoie, Isabelle; Bengio, Yoshua; Manzagol, Pierre-Antoine	JOURNAL OF MACHINE LEARNING RESEARCH	2010
445	Deep learning in neural networks: An overview	Schmidhuber, Juergen	NEURAL NETWORKS	2015
341	Learning Hierarchical Features for Scene Labeling	Farabet, Clement; Couprie, Camille; Najman, Laurent; LeCun, Yann	IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE	2013
341	Why Does Unsupervised Pre-training Help Deep Learning?	Erhan, Dumitru; Bengio, Yoshua; Courville, Aaron; Manzagol, Pierre-Antoine; Vincent, Pascal; Bengio, Samy	JOURNAL OF MACHINE LEARNING RESEARCH	2010
310	3D Convolutional Neural Networks for Human Action Recognition	Ji, Shuiwang; Xu, Wei; Yang, Ming; Yu, Kai	IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE	2013
258	Random Search for Hyper-Parameter Optimization	Bergstra, James; Bengio, Yoshua	JOURNAL OF MACHINE LEARNING RESEARCH	2012
100	Deep Learning-Based Classification of Hyperspectral Data	Chen, Yushi; Lin, Zhouhan; Zhao, Xing; Wang, Gang; Gu, Yanfeng	IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING	2014
87	Deep Learning and Its Applications to Signal and Information Processing	Yu, Dong; Deng, Li	IEEE SIGNAL PROCESSING MAGAZINE	2011
75	Image Super-Resolution Using Deep Convolutional Networks	Dong, Chao; Loy, Chen Change; He, Kaiming; Tang, Xiaoou	IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE	2016
67	Predicting the sequence specificities of DNA- and RNA-binding proteins by deep learning	Alipanahi, Babak; DeLong, Andrew; Weirauch, Matthew T.; Frey, Brendan J.	NATURE BIOTECHNOLOGY	2015
61	Traffic Flow Prediction with Big Data: A Deep Learning Approach	Lv, Yisheng; Duan, Yanjie; Kang, Wenwen; Li, Zhengxi; Wang, Fei-Yue	IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS	2015
61	A review of unsupervised feature learning and deep learning for time-series modeling	Langkvist, Martin; Karlsson, Lars; Loutfi, Amy	PATTERN RECOGNITION LETTERS	2014



〈그림 3〉 핵심 문헌을 씨앗으로 삼아 자아 문헌집합과 인용 정체성 집합을 확보하는 과정

〈표 3〉 2차 검색 결과 확보된 딥러닝 현행 연구문헌 2,007건의 상위 10개 WoS 범주

순위	Web of Science 범주	건수	%
1	COMPUTER SCIENCE ARTIFICIAL INTELLIGENCE	621	30.94
2	ENGINEERING ELECTRICAL ELECTRONIC	594	29.60
3	COMPUTER SCIENCE INFORMATION SYSTEMS	215	10.71
4	COMPUTER SCIENCE INTERDISCIPLINARY APPLICATIONS	168	8.37
5	NEUROSCIENCES	150	7.47
6	COMPUTER SCIENCE SOFTWARE ENGINEERING	145	7.23
7	IMAGING SCIENCE PHOTOGRAPHIC TECHNOLOGY	142	7.08
8	COMPUTER SCIENCE THEORY METHODS	106	5.28
9	MULTIDISCIPLINARY SCIENCES	104	5.18
10	MATHEMATICAL COMPUTATIONAL BIOLOGY	96	4.78

하고 출현 횟수가 높은 참고문헌을 중심으로 동일 참고문헌의 이표기를 전거처리하였다. 그 결과 2,007건으로부터 인용된 79,216건을 식별할 수 있었다. 이들이 딥러닝 현행 연구문헌으로부터 인용된 인용 정체성 집합의 후보가 된다.

마지막 4단계에서는 79,216건의 인용 정체성 후보 문헌들 중에서 2,007건의 현행 연구문헌들 중 1%인 20건 이상으로부터 인용된 191건을 선별하여 딥러닝 연구의 인용 정체성 집합으로 선정하였다. 이 191건의 딥러닝 연구 인용 정체성 집합은 현행 딥러닝 연구 중 1% 이상에 영향을 끼치고 있는 주요 선행 연구이다. 이 191건 중에는 최초의 씨앗 문헌인 15건도 포함된다. 인용 정체성 집합에 대한 분석은 4장에서 다루었다.

2.2 분석 방법

2.2.1 현행 연구문헌 분석 방법

현행 연구문헌은 딥러닝 관련 핵심문헌을 인용하면서 최근(94.8%가 2015년 이후 발표됨)에 발표된 논문들이다. 따라서 이들에 대해서

는 인용을 통한 질적인 분석보다는 논문 수와 공저 관계 위주의 양적인 분석을 수행하였다. 공저 네트워크 분석은 연구를 수행한 연구기관과 국가를 단위로 각각 적용해보았다. 공저 네트워크 분석에서는 공저의 강도를 주로 반영하는 최근 접이웃중심성 NNC(이재운, 2006), 공저의 범위를 주로 반영하는 삼각매개중심성 TBC(이재운, 2006), 그리고 공저의 범위와 강도를 복합적으로 반영하는 SSR 지수(이재운, 2014)를 측정하여 공저 관계를 다면적으로 분석하였다.

2.2.2 인용 정체성 문헌 분석 방법

인용 정체성 문헌은 딥러닝 관련 연구를 수행하는데 주로 참고되는 선행 연구문헌들이다. 이들에 대해서는 주요 연구 주제를 밝히기 위한 동시인용 분석을 실시하였다. 2,007건의 현행 문헌들로부터 191건의 인용 정체성 문헌이 동시인용된 횟수를 코사인 계수로 정규화한 후, 크기가 191×191인 동시인용 행렬에 대해서 집단 내 평균연결 WAVE(Within-Group Average Linkage) 군집화를 실시하고 군집기반 네트워크 CBNNet-WAVE(이재운, 2007; Lee, Kim, &

Kim, 2010)를 생성하였다. 계층적 군집분석에서 적정 군집분할 수를 파악하는 기준으로는 군집 크기의 변동계수 CV(군집 크기의 표준편차를 군집 크기의 평균으로 나눈 값)를 적용하여 상대적으로 균등하게 군집이 분할된 지점을 파악하였다.

각 군집의 연구 주제를 상세히 파악하기 위해서 군집 대표 문헌과 군집 대표 키워드를 파악하였다. 군집 대표 문헌은 동시인용 네트워크에서 주변 문헌과의 동시인용 관계를 반영하는 이웃 중심성이 높은 상위 문헌을 대표 문헌으로 선정하였다. 문헌동시인용 네트워크에서 특정 문헌의 이웃중심성은 그 문헌과 동시인용된 이웃 문헌의 입장에서 산출된 관계 강도의 순위의 제곱의 역수를 누적인 값으로서, 주변으로부터 1위에 가깝게 높은 순위로 동시인용된 이웃으로 꼽힐수록 높은 값을 가지는 척도이다. 이 연구에서 적용한 문헌 d_i 의 이웃중심성 $C_N(d_i)$ 산출 공식은 다음과 같다(이재윤, 2015).

$$C_N(d_i) = \sum_{j \neq i} \frac{1}{r_{ji}^2}$$

여기서 r_{ji} 는 문헌 d_j 와 d_i 의 동시인용 강도가 문헌 d_j 가 가진 동시인용 관계 중에서 몇 번째로 높은지를 나타내는 링크 가중치 순위이다.

군집마다 소속 문헌 수가 다르므로 대표 문헌의 수가 군집 크기에 비례하도록 정하기 위해서 군집 크기의 제곱근을 취한 후 소수점 이하를 버린 정수값을 해당 군집의 대표 문헌 개수로 삼았다. 예를 들어 소속 문헌이 8개인 군집은 제곱근이 2.83이고 소속 문헌이 16개인 군집은 제곱근이 4.00이므로 각각 대표 문헌의 수

는 2개와 4개가 된다.

군집을 대표하는 키워드를 산출하는 방법은 다음 절에서 설명한다.

2.2.3 군집 인용 이미지 키워드 분석 방법

인용 정체성 문헌 군집의 연구 주제를 구체적으로 드러내는 키워드를 파악하기 위해서는 각 인용 정체성 문헌에 부여된 키워드를 수집해야 하지만, 인용 정체성 문헌에 대한 정보는 현행 연구문헌들의 참고문헌으로 표기된 CR필드의 약식 표기(예: 'Silver(2016) NATURE')뿐이므로 해당 문헌들의 주제 키워드 정보를 일괄적으로 획득하기가 어렵다. 이에 따라 본 연구에서는 특정 군집에 속한 인용 정체성 문헌을 인용하는 현행 연구문헌의 키워드가 무엇인지를 단서로 하여 인용 정체성 군집의 주제를 파악하는 방법을 시도해보았다. 즉, 주어진 인용 정체성 군집의 문헌들이 어떤 현행 딥러닝 연구를 수행할 때 인용되는지를 파악해보는 것이다. 이때 주제 키워드는 저자 키워드와 Web of Science 부여 키워드를 통합하여 활용하였다.

인용 정체성 문헌 191건을 인용하고 있는 현행 연구문헌 2,007건의 저자 키워드와 WoS 부여 키워드는 현행 연구문헌의 서지정보에 포함되어 반출된다. 인용 정체성 군집의 입장에서 해당 군집을 인용한 문헌, 즉 인용 이미지 문헌들의 키워드가 파악되는 것이므로 인용 이미지 키워드라고 할 수 있다. 이는 Braam, Moed, van Raan(1991)이 제안한 인용한 문헌의 색인어(indexing terms in citing documents) 분석과 본질적으로 같은 방법이다. 국내에서는 김도미(1993)가 경제학 분야를 대상으로 이 방법을

적용한 사례가 있다.


특정 군집의 인용 정체성 문헌과 연계된 인용 이미지 키워드를 선정하는 방법은 다음과 같이 설계하였다. 우선 키워드 k 가 출현한 n 개의 현행 연구문헌이 D_1 부터 D_n 까지이고, 군집 C 에 속한 m 개의 인용 정체성 문헌이 CID_1 부터 CID_m 까지이며 문헌 D_i 가 문헌 CID_j 를 인용한 횟수가 $Cit(D_i, CID_j)$ 일 때, 다음 공식에 따라 키워드 k 가 출현한 현행 연구문헌이 군집 c 에 속한 인용 정체성 문헌을 인용한 횟수를 합산한 것을 키워드 군집 인용점수 $CitScore(k, c)$ 로 삼았다.

$$CitScore(k, c) = \sum_{j=1}^m \sum_{i=1}^n Cit(D_i, CID_j)$$

예를 들어 <그림 4>에서와 같이 키워드 A가 D_1 부터 D_4 까지 4건의 문헌에 출현했다면, 군집 C1에 속한 인용 정체성 문헌 CID_1 , CID_2 , CID_3 는 네 문헌으로부터 각각 1회, 2회, 3회 인용되어서 합계인 6이 키워드 A의 군집 C1 인용점수가 된다.

일단 각 키워드와 소군집 15개 사이의 인용 점수를 산출한 후, 타 군집에 비해서 해당 군집에 대해서 인용점수가 높은 키워드를 해당 군집의 차별 인용 키워드로 선정하였다. 만약 단순히 인용점수가 높은 키워드가 군집을 대표하는 것으로 선정하게 되면 대부분 'DEEP LEARNING'이나 'NEURAL-NETWORKS'가 선정되므로 각 군집이 차별화가 되지 않는다. 따라서 텍스트 집합의 차별어를 선정하는 방식(김하수, 손현정, 이재윤, 강범일, 2013)을 응용하여 군집 인용점수의 KL-다이버전스(Kullback & Leibler, 1951)를 기준으로 차별 인용 키워드를 선정하였다. 원래의 KL-다이버전스 공식은 확률을 이용해서 계산하지만 여기서는 확률 대신 해당 군집에 대한 각 키워드의 인용점수 총점 대비 특정 키워드의 군집 인용점수 비율을 이용해서 다음 공식과 같이 산출해보았다.

$$D_{KL}(k, c) = \text{키워드 } k \text{의 군집 } c \text{에 대한 군집인용점수 비중} \\ \times \log\left(\frac{\text{키워드 } k \text{의 군집 } c \text{에 대한 군집인용점수 비중}}{\text{키워드 } k \text{의 모든 군집에 대한 군집인용점수 비중}}\right) \\ = \frac{CitScore(k, c)}{\sum_j CitScore(k, C_j)} \times \log\left(\frac{CitScore(k, c) \times \sum_i CitScore(K_i, C_j)}{\sum_j CitScore(k, C_j) \times \sum_i CitScore(K_i, c)}\right)$$



<그림 4> 키워드 군집 인용점수 산출 방법

2.2.4 인용 성장지수

특정 군집에 속한 문헌들이 최근 연구에 어느 정도 영향을 끼치고 있는가를 판단하기 위해서 인용 성장지수를 측정하는 방안을 고안하였다. 인용 성장지수(Citation Growth Index)는 논문 발표건수의 성장지수 GI(Growth Index) (이재윤, 김관준, 강대신, 김희정, 유소영, 이우형, 2011)를 인용빈도에 응용한 것으로서, 각 논문이 발표된 이후 현재까지의 누적 인용빈도를 해당 논문의 출판년도별로 합산한 후 다음 공식으로 산출한다.

$$\text{인용 성장지수 } CGI = \frac{\sum_{i=Y_{begin}}^{Y_{end}} C_i \times Y_i}{C_{total}} - Y_{begin}$$

이 공식에서 Y_{begin} 과 Y_{end} 는 분석 기간의 첫 해와 마지막 해이고, C_i 는 i 년도에 출판된 논문이 현행 연구문헌에 의해 인용된 빈도이다. 인용 성장지수는 0과 1사이의 범위에서 0.5를 경계로 하여 그보다 작으면 예전 논문의 인용이 많고 최근 논문의 인용은 적은 하락 추세를 의미하고, 0.5보다 크면 최근 논문의 인용이 예전 논문의 인용보다 많은 상승 추세를 의미한다. 논문 발표건수의 성장지수는 0.5 정도면 성장과 쇠퇴 사이의 보통 수준으로 평가할 수 있지만, 인용 성장지수는 0.5 정도만 되어도 최근에 상당히 주목받고 있음을 의미한다. 일반적으로 오래된 논문일수록 누적 인용빈도가 높기 마련이므로 평가 기간의 최근 절반 이내에 발표된 논문이 전체 누적 인용의 과반수를 차지하는 것은 쉽지 않기 때문이다.

3. 딥러닝 현행 연구문헌 생산 국가 및 기관 분석


딥러닝 현행 연구문헌 2,007건의 연도별 논문 수는 <표 4>와 같다. 이 표에서 보듯이 수집된 논문 중 94.8%가 2015년 이후에 발표되었을 정도로 딥러닝을 다룬 연구는 최근 폭증하고 있다. 이중에서 가장 많이 인용된 논문은 2012년에 *IEEE Signal Processing Magazine*에 발표된 “Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups”으로써 1,007회 인용되었다. 이 논문은 딥러닝이 기존 기술의 성능 한계를 돌파한 선도 분야 중 하나인 음성인식을 다루고 있으며, 딥러닝 분야를 선도하는 G. Hinton 교수가 이끄는 Toronto 대학과 Microsoft Research, Google Research, IBM Watson 연구소의 연구진이 함께 저술하였다.

현행 연구문헌의 대부분은 딥러닝 기법을 실제 문제 해결에 적용하는 논문들이다. 저자의 소속 국가를 기준으로 살펴보면 중국이 766건으로 가장 많고 미국이 586건, 영국이 200건으로 그 뒤를 이었다. 10건 이상의 논문이 현행 연구문헌에 포함된 33개 국가 사이의 공저 네트워크는 <그림 5>와 같다. 논문 수 1위와 2위인 중국과 미국 사이의 공저가 113회로 가장 많았으며 중국은 미국 이외에도 싱가포르, 영국, 호주와 40회 이상 공저한 것으로 나타났다.

공저 네트워크에서 각 국가의 중심성을 측정해보면 모든 지수에서 미국이 가장 중심성이 높게 나타났다. 중국은 공저의 범위와 강도를 복합적으로 반영하는 SSR 지수(이재윤, 2014)와 공저의 강도를 주로 반영하는 최근접이웃중

〈표 4〉 현행 연구문헌의 연도별 논문 수 (2017년 6월 14일 검색 결과)

출판년도	2011	2012	2013	2014	2015	2016	2017	합계
논문 수	4	10	14	76	314	912	677	2,007
%	0.2	0.5	0.7	3.8	15.6	45.4	33.7	100.0



〈그림 5〉 딥러닝 현행 연구문헌을 10건 이상 발표한 33개 국가 간 공저 네트워크


심성 NNC(이재윤, 2006)로는 2위로 추정됐지만, 공저의 범위를 주로 반영하는 삼각매개중심성 TBC(이재윤, 2006)로는 4위에 머물렀다. 따라서 중국은 딥러닝과 관련되어 매우 많은 논문을 발표했지만 공저를 수행한 상대방 국가는 상대적으로 다양하지 못한 것을 알 수 있다.

딥러닝 현행 연구문헌에 5건 이상의 논문이 포함된 기관은 195개이며 1위인 중국과학원

(Chinese Academy of Science)을 비롯해서 6위까지 중국의 연구기관이 차지했다. 이들 195개 기관들 사이의 공저 네트워크는 〈그림 6〉과 같다. 기관 단위의 공저 네트워크 중심성을 측정해보면 모든 지수에서 1위는 논문 수가 압도적으로 많은 중국과학원으로 나타났다. 그러나 중국과학원의 공저 파트너는 대부분 중국 대학들이고 북미의 일부 대학과 1~2회의 공저만 수행하여 국제

〈표 5〉 딥러닝 현행 연구문헌 수 10위 이내 국가와 공저 네트워크 중심성 10위 이내 국가

국가	논문 수	국가	SSR	국가	TBC	국가	NNC
P.R. China	766	USA	94.1	USA	0.802	USA	18
USA	582	P.R. China	69.8	UK	0.621	P.R. China	9
UK	200	UK	66.3	Germany	0.415	UK	5
Germany	111	Germany	51.6	P.R. China	0.375	Australia	3
Canada	105	Australia	37.6	Australia	0.206	Germany	2
Australia	101	Switzerland	35.3	Switzerland	0.200	Spain	2
Singapore	84	Singapore	34.1	Italy	0.188	France	1
France	74	Italy	33.9	France	0.165	Netherlands	1
Japan	72	France	33.5	Singapore	0.159	Finland	1
Italy	68	Canada	32.9	Spain	0.149	Denmark	1



〈그림 6〉 딥러닝 현행 연구문헌을 5건 이상 발표한 연구 기관 195개의 공저 네트워크

적인 공저 영향력은 높지 않다. 각 지수별 중심성 2위는 모두 중국 연구기관이 아닌 싱가포르의 난양이공대학(Nanyang Technological University)이 차지했고 싱가포르국립대학(National University of Singapore)이 SSR과 TBC 기준 3위, NNC 기준 4위를 차지하여 공저의 범위가 중국의 여러 대학들보다 더 넓었다. 특히 난양이공대학은 중국, 미국, 영국 등 다양한 국가의 연구기관과 공저를 수행하여 폭넓게 국제적인 연구협력을 수행하고 있다. 북미의 대학 중에서는 MIT와 하버드 대학이 공저가 활발하였으며, 유럽에서는 독일의 뮌헨공대(Technical University of Munich)가 10위 이내에 포함되었다. 국가 단위에서 높은 공저 지수를 보였던 영국의 경우는 옥스퍼드 대학만이 NNC 지수 기준으로 10위

이내에 포함되었는데, 영국의 높은 국제 공저 활동 지수는 영국 런던에 소재하면서 2014년 Google에 인수된 Google DeepMind 팀 덕분으로 판단된다.

전반적으로 중국이 딥러닝 현행 연구 논문을 가장 많이 발표하고 있을 뿐만 아니라 중국 내 기관들끼리의 공동연구도 활발하지만, 국제적인 공저활동은 싱가포르의 대학이 더 폭넓게 나타났다. 중국은 정부와 대학 위주로 연구가 이루어지고 있는 반면에 미국은 공저의 범위와 강도를 복합적으로 고려하는 SSR 지수 기준으로 Google과 IBM 등의 기업도 10위 이내에 포함되어서 대학과 기업의 딥러닝 관련 공동연구가 모두 활발하게 나타났다.

〈표 6〉 딥러닝 현행 연구문헌 수 10위 이내 기관과 공저 네트워크 중심성 10위 이내 기관


기관	논문 수	기관	SSR	기관	TBC	기관	NNC
Chinese Acad Sci	106	Chinese Acad Sci	73.9	Chinese Acad Sci	0.0698	Chinese Acad Sci	23
Tsinghua Univ	46	Nanyang Technol Univ	39.4	Nanyang Technol Univ	0.0267	Nanyang Technol Univ	14
Nanyang Technol Univ	39	Natl Univ Singapore	35.2	Natl Univ Singapore	0.0229	Tech Univ Munich	13
Beihang Univ	31	MIT	30.9	MIT	0.0180	Natl Univ Singapore	10
Wuhan Univ	29	Harvard Univ	30.7	Harvard Univ	0.0156	MIT	10
Univ Chinese Acad Sci	27	Tech Univ Munich	30.0	IBM	0.0148	Tsinghua Univ	10
MIT	27	Tsinghua Univ	29.4	Tech Univ Munich	0.0146	Univ Oxford	10
Shanghai Jiao Tong Univ	26	Google	28.9	Tsinghua Univ	0.0145	Shanghai Jiao Tong Univ	9
Univ Sci & Technol China	25	IBM	27.1	Google	0.0135	Carnegie Mellon Univ	8
Xidian Univ	25	Univ Oxford	26.0	Shanghai Jiao Tong Univ	0.0116	Harvard Univ	7
Zhejiang Univ	25					Univ Calif Los Angeles	7
Northwestern Polytech Univ	25					Harbin Inst Technol	7
Stanford Univ	25						
Huazhong Univ Sci & Technol	25						

4. 딥러닝 인용 정체성 분석

4.1 동시인용 분석

인용 정체성 문헌은 딥러닝 현행 연구문헌들로부터 20회 이상 인용되어서 딥러닝 관련 연구를 수행하는데 주로 참고되는 선행 연구문헌 집단이다. 이들 인용 정체성 문헌 191건을 대상으로 주요 연구 주제를 밝히기 위한 동시인용 분석을 실시하였다. 2,007건의 현행 문헌들로부터 191건의 인용 정체성 문헌이 동시인용된 횟수를 코사인 계수로 정규화한 후, 크기가 191×191인 동시인용 행렬에 대해서 집단내 평균연결 WAVE(Within-Group Average Linkage) 군집화를 실시하고 군집기반 네트워크 CBNet-WAVE를 생성하였다. 계층적 군집분석에서 적정 군집분할 수를 선정하기 위해서 <그림 7>과 같이 30개에서 2개까지 군집이 병합되는 단

계마다 군집의 크기가 고르지 여부를 변동계수 CV(군집 크기의 표준편차를 군집 크기의 평균으로 나눈 값)로 측정해보았다. 그 결과 군집 간 크기 차이가 작게 나타나고 주제 식별이 용이한 15개와 6개 분할 결과를 각각 소군집과 중군집 분할로 채택하였다. 병합을 더 진행하면 15개 소군집이 8개와 7개씩 합쳐져 2개의 대군집으로 양분되는 결과를 얻었다. 이처럼 균형 잡힌 분할이 이루어지므로 여러 계층적 군집화 기법 중에서 집단내 평균연결 군집화를 채택하였다. 이와 동일하게 집단내 평균연결 군집화에 기반한 CBNet-WAVE 네트워크를 생성하고 군집크기 변동계수 기준으로 군집분할 개수를 결정하는 방식이 건축학 분야 문헌군집화 분석(이재윤, 유종덕, 김희전, 2009), 재난 분야 키워드 네트워크 분석(이재윤, 김수정, 2016), 계량정보학 분야 키워드 네트워크 분석(Lee & Choi, 2011)에서도 활용된 바 있다. 이처럼 여




<그림 7> 집단 간 평균연결 기법에 의한 군집 병합 단계별 군집크기 변동계수(CV)

리 계층적 군집분석 기법 중에서는 집단내 평균 연결 기법이 지적구조 분석을 위해서 무난하게 적용할 수 있다고 생각된다.

CBNet-WAVE로 표현한 인용 정체성 문헌 191개의 동시인용 네트워크는 <그림 8>과 같다. 동시인용 네트워크에서 주요 문헌을 파악하기 위해서 전역 중심성인 삼각매개중심성과 지역 중심성인 이웃중심성(이재윤, 2015)을 측정해보았다. 15개 소군집별 대표 문헌을 선정하기 위해서 주변 문헌과의 동시인용 관계를 반영하는 이웃중심성이 높은 상위 문헌을 대표

문헌으로 선정하였다. 소군집마다 대표 문헌의 수가 군집 크기에 비례하도록 정하기 위해서 군집 크기의 제곱근을 취한 후 소수점 이하를 버린 정수값을 해당 군집의 대표 문헌 개수로 삼았다. 군집별로 선정된 대표 문헌은 <표 7>과 같다.

<표 7>을 보면 인용 정체성 문헌 동시인용 네트워크의 윗쪽 절반에 해당하는 대군집 A에 속한 문헌들은 대체로 회귀 트리, 랜덤 포레스트나 SVM과 같은 고성능 분류기나 전략들과 심층 신경망을 함께 다루거나 자기부호화기



<그림 8> 클러스터링 기반 네트워크 CBNet-WAVE에 표시한 2개 대군집과 15개 소군집
(노드의 크기는 인용빈도에 비례, 6개 중군집은 색상으로 구분,
15개 소군집은 노드 모양으로 구분)

〈표 7〉 인용 정체성 군집별 대표 문헌 (군집별 이웃중심성 상위 $\sqrt{c}$ 개, c 는 군집 크기)

2군집	6군집	15군집	크기	저자(연도) 출처	제목
A	1	C1	8	Hochreiter(1997) NC	Long Short-Term Memory
				Graves(2013) ICAS	Speech recognition with deep recurrent neural networks
		C2	28	Hinton(2006) NC	A Fast Learning Algorithm for Deep Belief Nets
				Hinton(2006) SCIENCE	Reducing the Dimensionality of Data with Neural Networks
				Hinton(2002) NC	Training Products of Experts by Minimizing Contrastive Divergence
				Vincent(2008) P2ICML	Extracting and composing robust features with denoising autoencoders
				Bengio(2009) FaTiML	Learning Deep Architectures for AI
		C8	8	Tibshirani(1996) JRSSBM	Regression shrinkage and selection via the lasso: a retrospective
				Tenenbaum(2000) SCIENCE	A Global Geometric Framework for Nonlinear Dimensionality Reduction
	5	C9	8	Breiman(1984) CR	Classification and Regression Trees
				Breiman(2001) ML	Random Forests
		C15	10	Huang(2012) ITSMCB	Extreme Learning Machine for Regression and Multiclass Classification
				Cybenko(1989) MoC	Approximation by superpositions of a sigmoidal function
		C3	15	Cortes(1995) ML	Support-Vector Networks
				Rosenblatt(1958) PR	The perceptron: A probabilistic model for information storage and organization in the brain
				Mnih(2015) NATURE	Human-level control through deep reinforcement learning
				Jaeger(2004) SCIENCE	Harnessing Nonlinearity: Predicting Chaotic Systems and Saving Energy in Wireless Communication
		C5	15	KhalighRazavi(2014) PCB	Deep Supervised, but Not Unsupervised, Models May Explain IT Cortical Representation
				Fukushima(1980) BC	Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position
				Gucclu(2015) JN	Deep Neural Networks Reveal a Gradient in the Complexity of Neural Representations across the Ventral Stream
		C7	11	Leung(2014) BIOINFORMATICS	Deep learning of the tissue-regulated splicing code
				Alipanahi(2015) NB	Predicting the sequence specificities of DNA- and RNA-binding proteins by deep learning
				Zhou(2015) NM	Predicting effects of noncoding variants with deep learning - based sequence model
B	3	C4	8	Felzenszwalb(2004) IJCV	Efficient Graph-Based Image Segmentation
				Achanta(2012) ITPA	SLIC Superpixels Compared to State-of-the-Art Superpixel Methods
		C11	8	Chen(2014) IJ	Deep Learning-Based Classification of Hyperspectral Data
				Chen(2015) IJ	Spectral - Spatial Classification of Hyperspectral Data Based on Deep Belief Network
	4	C6	16	Krizhevsky(2012) ANIP	ImageNet Classification with Deep Convolutional Neural Networks
				Srivastava(2014) JMLR	Dropout: a simple way to prevent neural networks from overfitting
				Lecun(1998) PI	Gradient-based learning applied to document recognition
		C10	12	LeCun(2015) NATURE	Deep learning
				Timofte(2013) IICCV	Anchored Neighborhood Regression for Fast Example-Based Super-Resolution
				Dong(2016) ITPA	Image Super-Resolution Using Deep Convolutional Networks
	6	C12	20	Yang(2010) ITIP	Image Super-Resolution Via Sparse Representation
				Wang(2010) PCI	Locality-constrained Linear Coding for image classification
				Lowe(2004) IJCV	Distinctive Image Features from Scale-Invariant Keypoints
				Dalal(2005) PCI	Histograms of oriented gradients for human detection
		C13	16	Lazebnik(2006) PIICCV	Beyond Bags of Features: Spatial Pyramid Matching for Recognizing Natural Scene Categories
				Laptev(2005) IJCV	On Space-Time Interest Points
				Wang(2013) IICCV	Action Recognition with Improved Trajectories
				Le(2011) PICCV	Learning hierarchical invariant spatio-temporal features for action recognition with independent subspace analysis
		C14	8	Ji(2013) ITPA	3D Convolutional Neural Networks for Human Action Recognition
				Cheriyadat(2014) ITGR	Unsupervised Feature Learning for Aerial Scene Classification
				Yang(2010) PISI	Bag-of-visual-words and spatial extensions for land-use classification

(autoencoder) 등을 통해 분류 성능 및 속도 향상을 모색하는 연구 문헌이 주로 소속된 것으로 나타났다. 또한 군집 C1의 LSTM이나 순환(또는 재귀)신경망을 이용한 음성인식 및 자연언어처리, 군집 C7의 바이오인포메틱스 등과 같이 확장된 응용 분야도 포함된다. 군집 C3에는 AlphaGo를 개발한 Google DeepMind 팀의 심층 강화학습을 다룬 논문이 포함된다. 대군집 A에 속한 8개 소군집 중에서 가장 가운데에 위치한 것은 C2이며 고인용 논문이 몰려있다. 이중에서 전역중심성인 삼각매개중심성이 가장 높은 것은 딥러닝 연구를 선도하고 있는 토론토 대학의 G. Hinton 교수가 2006년에 발표한 두 편의 논문 “Reducing the dimensionality of data with neural networks”(그림에서는 ‘Hinton(2006) Science’)와 “A fast learning algorithm for deep belief nets”(그림에서는 ‘Hinton(2006) NC’)로서 모두 신경망의 학습 성능을 향상시키는 주요 연구들이다. 전반적으로 대군집 A는 기계학습 기법으로서 딥러닝을 발전시키고 적용분야를 확장하는 연구 영역이라고 할 수 있다.

인용 정체성 문헌 동시인용 네트워크의 아랫쪽 절반에 해당하는 대군집 B에 속한 문헌들은 주로 신경망의 전통적인 적용 분야인 영상 및 동영상 분류와 개체 인식에 관련된 문헌들이 포함되며, 합성곱신경망(convolutional neural network)이나 드롭아웃(Dropout)과 같이 최근 널리 활용되고 있는 기법을 다룬 문헌이 포함되어 있다. 대군집 B에 속한 7개 소군집 중에서 다른 소군집들을 이어주는 중심 역할을 하는 것은 C6이며 전역 중심성인 삼각매개중심성이 가장 높은 것은 심층 합성곱신경망을 이용해서

영상 분류 성능의 혁신을 이룩한 “ImageNet classification with deep convolutional neural networks”(그림에서는 ‘Krizhevsky2014 ANIP’)으로써 이 논문 역시 Hinton 교수팀이 발표하였다. 또한 C6에는 딥러닝의 과학습(overfitting) 문제를 극복하는데 크게 기여한 드롭아웃 기법을 제안한 “Dropout: A simple way to prevent neural networks from overfitting”(그림에서는 ‘Srivastava(2014) JMLR’)도 포함되며 이 역시 Hinton 교수팀의 연구이다. 이처럼 토론토 대학의 G. Hinton 교수의 연구팀이 딥러닝 현행 연구에서 주로 참고하는 인용 정체성 문헌들 중 핵심을 다수 발표하여 딥러닝 연구를 선도하고 있음이 뚜렷하게 나타났다.

리뷰 논문을 제외하고 인용 정체성 집합에 포함된 가장 최신 문헌은 2016년에 발표된 것으로서 대군집 A의 경우 소군집 C3에 속하면서 심층 강화학습을 다룬 Google DeepMind 팀의 논문(그림에서는 ‘Silver(2016) NATURE’)이고, 대군집 B의 경우 소군집 C10에 속하면서 초고해상도 이미지 복원을 다룬 논문(그림에서는 ‘Dong(2016) ITPA’)이다. 발표된 지 1년 남짓하지만 벌써 딥러닝 현행 연구에서 참고하는 주요 선행연구 중 하나로 자리잡은 이 논문들이 딥러닝 분야의 최신 경향을 대표한다고 할 수 있다.

4.2 군집 인용 이미지 키워드 분석


각 군집의 연구 주제를 상세히 파악하기 위해서 군집 인용 이미지 키워드 분석을 실시하였다. 이는 주어진 인용 정체성 군집의 문헌들이 어떤 현행 딥러닝 연구를 수행할 때 인용되는 문헌들

인지를 파악해보는 것이다. 앞의 2장에서 소개한 군집 인용 이미지 키워드 선정 방법에 따라서 각 군집별로 군집 인용점수의 KL-다이버전스 상위 5위 이내의 키워드를 군집 차별 인용 키워드로 선정하여 <표 8>에 제시하였다.

차별 인용 키워드를 참고하여 각 군집의 주제를 확정하고 <그림 9>에 제시하였다. <그림 9>는 191개 문헌의 동시인용 패스파인더 네트워크를 소군집 15개 단위로 축소하여 표시한 것이다. 군집별 연구 주제는 군집별 대표 논문

<표 8> 군집 차별 인용 키워드

대군집 A			대군집 B		
6 군집	15 군집	차별 인용 키워드	6 군집	15 군집	대군집 A차별 인용 키워드
1	C1	RECURRENT NEURAL NETWORKS NEURAL-NETWORKS TIME SPEECH RECOGNITION SHORT-TERM-MEMORY	3	C4	IMAGE SEGMENTATION SEGMENTATION FEATURES SEMANTIC SEGMENTATION TEXTURE
	C2	NEURAL-NETWORKS DEEP BELIEF NETWORKS RESTRICTED BOLTZMANN MACHINE DEEP NEURAL NETWORKS ALGORITHM		C11	FEATURE EXTRACTION HYPERSPPECTRAL IMAGES SPECTRAL-SPATIAL CLASSIFICATION HYPERSPPECTRAL IMAGE CLASSIFICATION DEEP LEARNING
	C8	NONLINEAR DIMENSIONALITY REDUCTION DIMENSIONALITY REDUCTION FRAMEWORK NONNEGATIVE MATRIX FACTORIZATION DISCRIMINANT-ANALYSIS	4	C6	CONVOLUTIONAL NEURAL NETWORKS DEEP LEARNING NEURAL-NETWORKS MACHINE LEARNING SEGMENTATION
5	C9	MACHINE LEARNING OPTIMIZATION SUPPORT VECTOR MACHINES RANDOM FORESTS PARAMETER OPTIMIZATION		C10	SUPER-RESOLUTION INTERPOLATION SPARSE REPRESENTATION RECONSTRUCTION QUALITY ASSESSMENT
	C15	EXTREME LEARNING MACHINE APPROXIMATION FEEDFORWARD NETWORKS NEURAL-NETWORKS REGRESSION	6	C12	FEATURES SCALE IMAGE CLASSIFICATION CLASSIFICATION OBJECT DETECTION
2	C3	NEURAL-NETWORKS TIMING-DEPENDENT PLASTICITY SYSTEM REINFORCEMENT LEARNING ARTIFICIAL NEURAL NETWORKS		C13	ACTION RECOGNITION TRAJECTORIES VIDEO FACE RECOGNITION MOTION
	C5	INFERIOR TEMPORAL CORTEX RECEPTIVE-FIELDS OBJECT RECOGNITION HIERARCHICAL-MODELS VISUAL-CORTEX		C14	SCENE CLASSIFICATION UNSUPERVISED FEATURE LEARNING SCALE REMOTE-SENSING IMAGES FEATURES
	C7	MACHINE LEARNING GENE-EXPRESSION PREDICTION SEQUENCE PROTEINS			



〈그림 10〉 인용정체성 군집 소속 논문의 출판년도별 인용빈도
(원의 크기는 해당 연도에 출판된 논문이 딥러닝 현행 연구문헌들로부터 인용된 빈도)

〈그림 10〉에서 신경망의 고전 연구가 가장 많이 포함된 군집은 C3이다. 여기에는 1943년에 인공신경망(Artificial Neural Networks)이란 개념을 처음으로 제안한 “A logical calculus of the ideas immanent in nervous activity” (〈그림 7〉에서는 ‘McCulloch(1943) BMB’)와 1958년에 선형분류가 가능한 퍼셉트론을 처음 제안하여 각광을 받은 “The perceptron: A probabilistic model for information storage and organization in the brain” (〈그림 7〉에서는 ‘ROSENBLATT(1958) PR’)이 포함되어 있다. 초기 시각신경생리에 대한 연구를 개척하여 영상처리에 대한 인공신경망 연구를 가능케 한 D. H. Hubel과 T. N. Wiesel의 연구들은 1959년의 “Receptive fields of single neurones in the cat’s striate cortex” (〈그림 7〉에서는 ‘HUBEL(1959) JP’)를 비롯하여 1962년, 1968년의 논문이 모두 군집 C5에 포함되어 있다. 이를 시각패턴 인식에 최초로 성공적으로 적용한 Neocognitron 신경회로망 모형을 1980년에 제안한 Osaka 대학 Fukushima 박사팀의 “Neocognitron:

A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position” (〈그림 7〉에서는 ‘FUKUSHIMA (1980) BC’)도 군집 C5에 포함되어 있다.

〈그림 10〉을 보면 2010년을 전후하여 2006년부터 2014년 사이의 논문이 현행 딥러닝 연구문헌으로부터 가장 많이 인용되고 있는 군집은 C2(심층신경망, 제약 볼츠만 머신)임이 드러난다. 앞의 동시인용 네트워크에서도 군집 C6과 함께 중심에 위치한 이 군집이 딥러닝이 각광을 받기 시작한 시기 전후를 대표하는 메인 영역임이 다시 한 번 확인된다. 전체 시기 중에 2015년에 발표된 논문이 가장 많이 인용되어서 오른쪽 끝부분의 동그라미가 두드러지게 크게 표현된 군집은 C3(타이밍 의존 가소성, 강화학습)과 C6(합성곱신경망, 드롭아웃)이다. 특히 C6의 문헌들 중 1998년에 큰 원으로 표시된 것은 합성곱신경망을 제안한 “Gradient-based learning applied to document recognition” (〈그림 7〉에서는 ‘Lecun(1998) PT’)이다. 이 논문은 345회 인용되어서 2005년 이전 인용 정제

성 문헌 중에서 가장 많이 인용되었다. 전체적으로 딥러닝 기술이 본격적으로 탐구되어 인정 받은 시기인 2006년 이후 2013년까지는 군집 C2에서 개발된 연구가 주도하는 시기였고, 딥러닝이 본격적으로 확산된 2014년부터는 군집 C6의 연구가 주도하는 시기임을 알 수 있다. 인용 데이터 수집 시점으로부터 1년 정도만 지난 가장 최근인 2016년은 단서가 적어서 판단하기는 이르지만, 2015년부터 인용 성장이 두드러지기 시작한 군집 C3이 이후 시기를 주도할 후보라고 추정된다. 군집 C3에는 Google DeepMind 팀의 강화학습 관련 연구와 AlphaGo 연구도 포함되어 있다.


최근 인용 추세를 더 정확하게 판단하기 위해서 인용 정체성 문헌의 출판년도별 인용빈도의 성장 추세를 2장에서 소개한 인용 성장지수

를 이용하여 <표 9>와 같이 분석하였다.

2000년부터 2016년 사이의 총 인용빈도를 가로축으로 하고 인용 성장지수를 세로축으로 하여 각 군집을 <그림 11>과 같이 표시했다. 가로축으로 오른쪽에 위치할수록 해당 군집의 논문이 많이 참고되었음을 의미하고, 세로축으로 위쪽에 위치할수록 예전보다 최근 발표된 논문이 주로 인용되고 있음을 의미한다. 인용되는 양이 가장 많은 것은 군집 C2(심층 신경망; 제약 볼츠만 머신)이지만 2000년~2016년 인용 성장지수는 0.558로서 중간을 겨우 넘겼으며 최근 기간인 2010년~2016년 인용 성장지수는 0.265에 불과하다. 이는 딥러닝의 확산을 이끈 제약 볼츠만 머신을 비롯한 주류 심층신경망 연구의 인용 성장세가 주춤하고 있음을 보여준다. 이와 달리 합성곱신경망과 드롭아웃 등 영상 처

<표 9> 군집 소속 논문의 출판년도별 인용빈도 추세

군집			최다 인용			누적 인용빈도			인용 성장지수			핵심 주제
대	중	소	연도	인용 빈도	비중 (%)	'00~'16	'05~'16	'10~'16	'00~'16	'05~'16	'10~'16	
A	1	C1	1997	80	27.7	156	136	113	0.633	0.562	0.305	순환신경망; 음성인식
		C2	2006	879	27.9	3,087	2,968	1,407	0.558	0.382	0.265	심층 신경망; 제약 볼츠만 머신
		C8	2000	80	29.3	212	69	0	0.201	0.194	0.000	차원 축소
	5	C9	2012	141	28.4	370	263	141	0.442	0.412	0.333	최적화, 고성능 기계학습(SVM 등)
		C15	1995	99	31.5	120	120	54	0.544	0.336	0.333	극한 기계학습: 군사
	2	C3	2015	316	42.4	512	467	410	0.813	0.816	0.808	타이밍 의존 가소성, 강화 학습
		C5	1980	71	13.8	251	251	229	0.758	0.649	0.438	하측두피질, 시각피질 등 뇌신경세포; 물체 인식
		C7	2015	126	36.6	344	324	324	0.787	0.749	0.540	바이오인포메틱스 응용
B	3	C4	2013	176	47.6	370	293	293	0.677	0.741	0.524	영상 분할
		C11	2014	91	36.5	249	228	202	0.730	0.671	0.470	초분광영상
	4	C6	2015	780	35.3	1,863	1,863	1,863	0.863	0.801	0.635	합성곱 신경망; 드롭아웃
		C10	2009	129	23.2	480	430	257	0.621	0.511	0.372	초고해상도 복원
	6	C12	2014	163	17.9	860	611	336	0.484	0.421	0.356	영상 분류
		C13	2013	173	27.2	585	559	455	0.708	0.607	0.434	동작 인식; 얼굴 인식
		C14	2010/2015	23	13.6	148	128	108	0.650	0.597	0.401	장면 분류



〈그림 11〉 소군집별 2000년 이후 출판 논문이 딥러닝 현행 문헌으로부터 인용된 인용빈도와 인용 성장지수 비교

리 분야에서 대세로 활용되고 있는 딥러닝 기법이 포함된 군집 C6은 2000년 이후 논문의 총 인용빈도가 2위이고 인용 성장지수 1위로서 가장 뚜렷하게 성장한 영역으로 확인된다. 군집 C6의 인용 성장지수는 2000년 이후 0.863, 2005년 이후 0.801, 2010년 이후 0.635로 최근으로 올수록 조금씩 낮아지긴 하지만 여전히 두 번째로 높은 추세이다.

최근 인용 성장지수가 가장 높은 주제는 AlphaGo 연구를 비롯한 강화 학습 주제가 포함된 군집 C3이다. 2000년 이후 0.813, 2005년 이후 0.816, 2010년 이후 0.808로 기간을 최근으로 좁히더라도 상승 추세가 감소하지 않고 유일하게 0.8대를 계속 유지하고 있다. 인용 성장지수가 0.8 이상이라는 것은 이 군집에 속한 2010년 이후의 논문 중에서 최근 1/5 이내 시기의

논문들이 주로 인용되고 있음을 의미한다. 결국 딥러닝 연구 중에서 가장 최근 논문이 활발하게 인용되고 있는 주제는 AlphaGo로 인해 급속하게 주목받고 있는 강화 학습 등임이 확인된다.

5. 결 론

본 연구는 딥러닝 분야의 연구 동향을 구체적으로 파악하기 위해서 1차 검색한 논문으로부터 핵심 문헌 15건을 씨앗 집합으로 선정한 후, 씨앗 집합을 인용한 딥러닝 현행 연구문헌 2,007건을 자아 문헌집합으로, 현행 연구문헌으로부터 인용된 상위 191건을 인용 정체성 문헌으로 선정하고 각각 분석하였다.

현행 연구문헌은 딥러닝 기법을 실제 문제 해결에 적용하는 논문들로서 이에 대한 분석 결과는 다음과 같다.

첫째, 핵심 선행 연구를 인용한 딥러닝 현행 연구문헌 중 약 95%가 2015년 이후에 발표되었을 정도로 딥러닝 관련 연구가 최근 폭증하고 있다.

둘째, 딥러닝 현행 연구문헌의 수는 중국이 가장 많고 미국과 영국이 그 뒤를 이었다.

셋째, 국가들 사이의 공저 네트워크에서는 미국이 가장 중심적인 역할을 차지하고 있었다. 중국은 발표 논문 수 및 공저 횟수에 비하면 공저를 수행한 상대방 국가는 다양하지 못해서 영국이나 독일에도 미치지 못했다.

넷째, 연구기관 수준의 공저 네트워크에서는 중국과학원이 가장 중심적인 입지를 차지하고 있었으나 주로 중국 내 기관들끼리의 공동연구에 치중하고 있었다. 오히려 국제적인 공저활동은 중국보다 난양이공대학을 비롯한 싱가포르의 대학이 더 폭넓게 나타났다. 중국은 정부와 대학 위주로 연구가 이루어지고 있는 반면에 미국은 대학과 기업의 딥러닝 관련 공동연구가 모두 활발하게 나타났다.

인용 정체성 문헌은 딥러닝 관련 연구를 수행하는데 주로 참고되는 선행 연구문헌들로서 이에 대한 분석 결과는 다음과 같다.

첫째, 인용 정체성 문헌은 기계학습 기법으로서 딥러닝을 발전시키고 적용분야를 확장하는 연구 영역인 대군집 A와, 신경망의 전통적인 적용 대상인 영상을 분할, 분류, 복원하는 등의 영상 처리 영역들이 포진하고 있는 대군집 B로 구분된다.

둘째, 대군집 A는 제약볼츠만머신과 자기부

호화기를 다룬 소군집 C2를 중심으로 딥러닝을 확장/발전시키는 강화 학습이나 생물정보학 응용 영역, LSTM이나 순환신경망을 이용한 음성인식 및 자연언어처리 영역, 그리고 딥러닝의 비교/결합 대상인 타 기계학습 기법을 다루는 영역으로 구성되어 있다. 대군집 A에 속한 인용 정체성 논문 중 가장 최신 연구는 심층 강화학습을 다룬 Google DeepMind 팀의 논문이다.

셋째, 영상 처리에 관한 대군집 B는 딥러닝으로 영상을 다루는 연구에서 최근 널리 활용되고 있는 합성곱신경망이나 드롭아웃 기법에 관한 소군집 C6을 중심으로 영상 처리의 심화 주제인 초고해상도 복원, 초분광 영상, 동작 인식 등이 포함되어 있다. 대군집 B에 속한 인용 정체성 논문 중 가장 최신 연구는 초고해상도 영상 복원을 다룬 논문이다.

넷째, 대군집 A의 핵심인 소군집 C2 소속 문헌 그리고 대군집 B의 핵심인 소군집 C6에 속한 문헌 중 토론토 대학의 G. Hinton 교수팀이 발표한 논문이 다수 속하여, 이들이 딥러닝 연구를 선도해왔음이 뚜렷하게 나타났다.

다섯째, 인용 시기를 분석해본 결과 전체적으로 딥러닝 기술이 본격적으로 탐구되어 인정받은 시기인 2006년 이후 2013년까지는 제약볼츠만머신을 비롯한 심층신경망 핵심 연구들이 포함된 소군집 C2가 주도하였으나 최근에는 인용이 주춤하였다. 대신 딥러닝이 본격적으로 확산되기 시작한 2012년 이후 발표된 합성곱 신경망과 드롭아웃이 포함된 소군집 C6의 연구가 주로 인용된 것으로 나타났다. 한편 AlphaGo와 관련된 Google DeepMind팀의 강화학습 관련 연구가 2015년과 2016년에 발표된 이후 2017년

중반까지 인용이 급격히 성장하고 있어 향후 딥러닝 연구의 핵심 주제로 자리잡을 것으로 기대된다.

위키백과의 '딥 러닝'¹⁾ 항목에서는 딥러닝의 주요 알고리즘으로 심층신경망, 합성곱신경망, 순환신경망, 제약볼츠만머신, 심층신뢰신경망, 심층Q-네트워크(강화학습)를 제시하고 있다. 이들은 본 연구의 분석 결과에서는 소군집 C2(심층신경망, 제약볼츠만머신, 심층신뢰신경망), C6(합성곱신경망), C1(순환신경망), C3(강화학습)에 포함된 주요 기법들이다. 이처럼 인용

정체성 분석을 통해서 딥러닝의 주요 기법이 모두 파악되었으며 최신 기법인 강화학습의 급부상과 핵심 선행연구까지 파악할 수 있었다. 결과적으로 본 연구에서 자아 중심 주제 인용분석을 변형하여 소수의 씨앗 문헌으로부터 인용 관계의 단계적 확장을 통해 현행 연구문헌 집합과 인용 정체성 문헌집합을 구성하여 분석하는 방법이 딥러닝과 같이 단기간에 급속하게 확산되고 있는 주제에 대한 분석에 효과적임이 확인되었다.

참 고 문 헌

- 김도미 (1993). 저자동시인용 분석과 인용한 문헌의 색인어 분석에 의한 지적구조의 규명: 경제학 분야를 대상으로. 정보관리연구, 24(1), 32-57.
- 김하수, 손현정, 이재윤, 강범일 (2013). 정치와 언어의 관계에 대한 양적 분석 시론. 담화와인지, 20(1), 79-111. <https://doi.org/10.15718/discog.2013.20.1.79>
- 딥러닝 (2014). Wikipedia. Retrieved from https://ko.wikipedia.org/wiki/딥_러닝
- 유소영 (2015). 자아 중심 네트워크 분석과 동적 인용 네트워크를 활용한 토픽모델링 기반 연구동향 분석에 관한 연구. 정보관리학회지, 32(1), 153-169. <http://doi.org/10.3743/KOSIM.2015.32.1.153>
- 이재윤 (2006). 계량서지적 네트워크 분석을 위한 중심성 척도에 관한 연구. 한국문헌정보학회지, 40(3), 191-214. <http://doi.org/10.4275/KSLIS.2006.40.3.191>
- 이재윤 (2007). 국내 광역 과학 지도 생성 연구. 정보관리학회지, 24(3), 363-383. <http://doi.org/10.3743/KOSIM.2007.24.3.363>
- 이재윤 (2012). 폭소노미 연구 문헌에 대한 자아 중심 주제 인용 분석. 정보관리학회지, 29(4), 295-312. <http://doi.org/10.3743/KOSIM.2012.29.4.295>
- 이재윤 (2013). tnet과 WNET의 가중 네트워크 중심성 지수 비교 연구. 정보관리학회지, 30(4), 241-264. <http://doi.org/10.3743/KOSIM.2013.30.4.241>

1) https://ko.wikipedia.org/wiki/딥_러닝

- 이재윤 (2014). 공동연구 네트워크 분석을 위한 중심성 지수에 대한 비교 연구. 정보관리학회지, 31(3), 153-179. <http://doi.org/10.3743/KOSIM.2014.31.3.153>
- 이재윤 (2015). 가중 네트워크를 위한 일반화된 지역중심성 지수. 정보관리학회지, 32(2), 7-23. <http://doi.org/10.3743/KOSIM.2015.32.2.007>
- 이재윤, 김수정 (2016). 국내 재난 관련 연구 동향에 대한 계량정보학적 분석. 정보관리학회지, 33(3), 103-124. <http://doi.org/10.3743/KOSIM.2016.33.3.103>
- 이재윤, 김관준, 강대신, 김희정, 유소영, 이우형 (2011). 계량서지적 기법을 활용한 LED 핵심 주제영역의 연구 동향 분석. 정보관리연구, 42(3), 1-26. <http://doi.org/10.1633/JIM.2011.42.3.001>
- 이재윤, 유종덕, 김희전 (2009). 텍스트마이닝을 이용한 건축학 분야의 지적 구조 분석. 경기대학교 대학원 논문집, 39, 1-21.
- 장윤미 (2013). 자아 중심 주제 인용 분석에 의한 독서치료 주제 분야 지적구조에 관한 연구. 제20회 한국정보관리학회 학술대회 논문집, 37-41.
- Braam, R. R., Moed, H. F., & van Raan, A. F. J. (1991). Mapping of science by combined co-citation and word analysis. I. Structural aspects. Journal of the American Society for Information Science, 42(4), 233-251. [http://doi.org/10.1002/\(SICI\)1097-4571\(199105\)42:4<233::AID-ASI1>3.0.CO;2-I](http://doi.org/10.1002/(SICI)1097-4571(199105)42:4<233::AID-ASI1>3.0.CO;2-I)
- Kullback, S., & Leibler, R. A. (1951). On information and sufficiency. Annals of Mathematical Statistics, 22(1), 79-86.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521, 436-444. <http://doi.org/10.1038/nature14539>
- Lee, Jae Yun, & Choi, Sanghee (2011). Intellectual structure and infrastructure of informetrics. Journal of the Korean Society for Information Management, 28(2), 11-36. <http://doi.org/10.3743/KOSIM.2011.28.2.011>
- Lee, J. Y., Kim, H., & Kim, P. J. (2010). Domain analysis with text mining: Analysis of digital library research trends using profiling methods. Journal of Information Science, 36(2), 144-161. <http://dx.doi.org/10.1177/0165551509353251>
- Van Eck, N. J., & Waltman, L. (2014). CitNetExplorer: A new software tool for analyzing and visualizing citation networks. Journal of Informetrics, 8(4), 802-823. <http://doi.org/10.1016/j.joi.2014.07.006>
- White, H. D. (2000). Toward ego-centered citation analysis. In B. Cronin & H. B. Atkins (Eds.), The web of knowledge: A festschrift in honor of Eugene Garfield (pp. 475-496). Medford, NJ: Information Today, Inc.

• 국문 참고문헌에 대한 영문 표기

(English translation of references written in Korean)

- Chang, Yun-Mee (2013). A study on the intellectual structure of bibliographic therapy by ego-centered topic citation analysis. Proceedings of the 20th Annual Conference of the Korean Society for Information Management, 37-41.
- Deep learning (2014). Wikipedia. Retrieved from https://ko.wikipedia.org/wiki/딥_러닝
- Kim, Do Mi (1993). A study on intellectual structure using author co-citation analysis and indexing term analysis of citing documents: Application to economics. Journal of Information Management, 24(1), 32-57.
- Kim, Ha-Soo, Son, Hyunjung, Lee, Jae Yun, Kang, Beomil (2013). A quantitative approach to the relation between politics and language. Discourse and Cognition, 20(1), 79-111.
<https://doi.org/10.15718/discog.2013.20.1.79>
- Lee, Jae Yun (2006). Centrality measures for bibliometric network analysis. Journal of the Korean Society for Library and Information Science, 40(3), 191-214.
<http://doi.org/10.4275/KSLIS.2006.40.3.191>
- Lee, Jae Yun (2007). Making a science map of Korea. Journal of the Korean Society for Information Management, 24(3), 363-383. <http://doi.org/10.3743/KOSIM.2007.24.3.363>
- Lee, Jae Yun (2012). Ego-centered topic citation analysis on folksonomy research documents. Journal of the Korean Society for Information Management, 29(4), 295-312.
<http://doi.org/10.3743/KOSIM.2012.29.4.295>
- Lee, Jae Yun (2013). A comparison study on the weighted network centrality measures of tnet and WNET. Journal of the Korean Society for Information Management, 30(4), 241-264.
<http://doi.org/10.3743/KOSIM.2013.30.4.241>
- Lee, Jae Yun (2014). A comparative study on the centrality measures for analyzing research collaboration networks. Journal of the Korean Society for Information Management, 31(3), 153-179. <http://doi.org/10.3743/KOSIM.2014.31.3.153>
- Lee, Jae Yun (2015). A generalized measure for local centralities in weighted networks. Journal of the Korean Society for Information Management, 32(2), 7-23.
<http://doi.org/10.3743/KOSIM.2015.32.2.007>
- Lee, Jae Yun, & Kim, Soojung (2016). A bibliometric analysis of research trends on disaster in Korea. Journal of the Korean Society for Information Management, 33(3), 103-124.
<http://doi.org/10.3743/KOSIM.2016.33.3.103>

- Lee, Jae Yun, Kim, Pan-Jun, Kang, Dae-Shin, Kim, Hee-Jung, Yu, So-Young, & Lee, Woo-Hyoung (2011). A bibliometric analysis on LED research. *Journal of Information Management*, 42(3), 1-26. <http://doi.org/10.1633/JIM.2011.42.3.001>
- Lee, Jae Yun, Ryoo, Jong-duk, & Kim, Hee-jeon (2009). A study on the intellectual structure of architectural studies with text mining. *Journal of the Graduate School of Kyonggi University*, 39, 1-21.
- Yu, So-Young (2015). Combining ego-centric network analysis and dynamic citation network analysis to topic modeling for characterizing research trends. *Journal of the Korean Society for Information Management*, 32(1), 153-169. <http://doi.org/10.3743/KOSIM.2015.32.1.153>