

특별호: 심리학과 4차 산업혁명 1
- 제 15분과 심리측정평가

빅데이터를 이용한 심리학 연구 방법

김 청 택[†]

서울대학교 심리학과, 인지과학협동과정

빅데이터, 기계학습, AI 등의 새로운 기술의 발달은 사람들의 사고와 행동을 변화시키고 이전에는 접근하기 힘들었던 인간에 대한 다양한 활동을 관찰하는 것을 가능하게 한다. 사람들이 인터넷을 광범위하게 사용함에 따라서, 개인의 행동도 인터넷에 저장되고 있다. 자료들은 매우 광범위하며 다양하기 때문에 이를 적절하게 분석하면 인간 심리를 이해하는 범위를 확대할 수 있을 것이다. 이 논문에서는 새롭게 발달된 이러한 기술들을 심리학 연구에 활용하는 방법에 대하여 모색하고자 하였다. 특히 기술의 발달로 가능해진 새로운 자료, 빅데이터의 특성과 심리학에서의 활용방안에 대하여 논의하였다. 이 논문에서는 첫째, 빅데이터의 특성과 빅데이터가 심리학에서 어떠한 역할을 할 수 있는지 살펴보았다. 심리학의 모형주도적 분석법과 다른 빅데이터의 자료주도적 분석법의 문제점들과 이러한 분석을 심리학연구에 어떻게 적용될 수 있는지에 대하여 논의하였다. 둘째, 자료의 분석 방법론에 대하여 살펴보았다. 기존 심리학 연구에서는 정교한 연구설계에 의해 자료가 수집되기 때문에 분석이 상대적으로 덜 중요하지만, 빅데이터 분석에서는 자료분석의 역할이 아주 중요해진다. 방대하고 구조화되지 않은 자료를 처리할 수 있어야 하고, 언어 자료와 같은 숫자 이외의 자료도 분석할 수 있어야 한다. 특히 주제 모형화, 능선 회귀분석과 라소 회귀분석, 지지벡터 기계, 신경망, 딥러닝 등에 대한 원리를 소개하고 심리학 연구에 적용되는 방법들에 대하여 논의하였다. 셋째, 심리학에서 빅데이터 분석 적용의 한계점을 살펴보고, 마지막으로 빅데이터의 심리학 연구의 적용에 대한 방법을 제안하였다.

주요어 : 빅데이터, 인공지능, 기계학습, 주제모형, 딥러닝, 자료주도적 분석, 모형주도적 분석

[†] 교신저자: 김청택, 서울대학교 심리학과, (08827) 서울시 관악구 관악로 1
Tel: 02-880-6076, E-mail: ctkim@snu.ac.kr

새로운 기술 시대의 심리학 연구

최근에 인공지능 혹은 4차 산업혁명이 시대의 화두로 등장하고 있다. 이러한 개념들은 학술적인 맥락에서 정의된 것이라기보다는 사회적 담론의 형태로 등장한 것이기 때문에 이를 심리학에서 사용하는 데에는 무리가 있다. 그럼에도 불구하고, 이러한 단어로 대표되는 과학 기술의 변화는 인간의 사고와 행동을 변화시키고, 심리학, 사회과학이 인간을 보는 관점도 변화시키고 있다. 인간의 심리와 행동을 더욱 정확히 설명하기 위해서는 심리학에서 이러한 변화를 반영해야 할 것이다. 심리학의 주제와 연구 방법에서 다양한 변화가 있을 것으로 예상되지만, 이 논문에서는 인간의 행동과 심리를 설명하는 데 도움을 줄 수 있는 새로운 자료의 등장과 이를 분석하는 방법들에 대하여 개관하고 이들 자료와 분석방법의 심리학 연구에의 적용을 논의하고자 한다.

심리학에서 인간을 보는 관점은 과학 기술의 발전에 따라 변화되어 왔다. 현 심리학의 이론적 틀을 형성하고 있는 정보처리론적 접근법은 디지털 컴퓨터의 영향을 받아서 발전한 것으로 인간을 정보처리 기계로 본다. 인지 과정을 입력과 출력 사이에 다양한 정보의 변환이 일어나는 것으로 보고 이 과정을 명세화하여 심리과정에 대한 모형을 형성한다. 이 모형의 타당성은 각 과정의 특성을 변화시킬 수 있는 실험조작을 고안하여 검증한다. 여기에서 생성되는 자료는 주로 반응시간이나 반응의 종류이다. 실험설계에서 모형이 참일 때, 각 실험조건에서 생성되는 반응을 예측하고, 이렇게 예측되는 반응을 사람들이 실제로 산출하는지를 관찰하여 모형의 타당성을 검증한다. 이러한 연구방법의 틀에서는 설계된 실험

조건에 대한 반응만 관찰하면 되므로 실험에서 관찰되는 자료는 그리 많을 필요가 없다.

실험법이 심리학 연구의 주류를 이루지만, 성격, 임상 등의 개인차 심리학에서는 실험과는 다소 다른 방법으로 자료를 수집한다. 설문지 등의 연구 방법을 통하여 변수들 간의 관계를 탐구하여 인간을 이해하고자 한다. 예컨대 우울한 사람들이 더 술을 많이 마시는지, 지능이 높은 사람이 더 리더십을 발휘하는지 등에 대한 변수 간의 상관관계를 통하여 다양한 구성개념 간의 관계를 파악한다. 이러한 연구법에서는 설문지 설계를 통하여 연구자가 관찰하고자 하는 구성개념들을 측정하고 분석한다. 이 연구 방법에서도 실험법과 같이 엄격하지는 않지만, 연구자의 심리 모형에 따라 설문지를 구성하고 설문대상을 선정한다. 실험법보다는 많은 사람의 행동을 관찰해야 하지만, 수집되는 자료의 수가 그리 많지는 않다.

심리학 연구에서 사용되었던 자료는 잘 설계된 연구에서 나온 것이지만, 그 규모가 작다는 특징이 있다. 최근에 인터넷 기술, 기계 학습, 인공지능 등의 발전에 따라 인간의 행동에 대한 광대한 자료가 다양한 장소에 자동적으로 저장되고 있다. 예컨대 개인이 소비하는 형태가 아마존 등과 같은 포털 사이트에 저장되어 있기도 하고, 개인이 어떤 영화를 보는지가 넷플릭스(Netflix)에 저장되기도 한다. 더 나아가서는 개인의 생각이나 태도 등이 페이스북, 트위터나 카카오톡 등의 사회망 서비스(Social Network Service, SNS)에 기록된다. 빅데이터(big data)라 불리는 이러한 자료는 매우 방대하지만 특정한 심리학 모형을 검증하기 위하여 설계된 구조화된 자료가 아니며, 심리학자가 사용하는 기존의 통계적 방법만으로는

분석하기 힘들다. 그러나 이 자료는 실험실과 같은 인위적인 상황에서 수집된 자료가 아니고 실제 생활환경에서 생성된 것이라는 점에서 실험실 자료와는 다른 이점을 지니고 있다. 이러한 자료를 심리학 연구에서 적절히 이용하면 기존의 연구 방법으로 탐지할 수 없었던 새로운 인간의 행동 혹은 심리 특성을 찾아낼 수도 있을 것이다.

이 논문에서는 이러한 가능성과 잠재력에 대하여 논의할 것이다. 빅데이터의 적용은 심리학의 외연을 확대하고 기존의 연구들을 보충할 수 있는 좋은 기회로 보이지만, 심리학 연구방법론의 전통과는 맞지 않아서 그리 많이 사용되지 않고 있다 (Cheung & Jak, 2016). 이 논문에서는 먼저 빅데이터의 특성을 설명하고 심리학 연구 방법과의 차이를 논의하고, 이러한 논의에 근거하여 심리학에서 빅데이터의 연구 방법을 도입하는 방안들의 모색할 것이다.

빅데이터란

빅데이터는 단어 자체로만 보면 큰 자료라는 뜻이며, 학술적으로는 자료가 커짐으로써 기존의 컴퓨터를 이용하여 기존의 분석 방법으로는 처리하기 힘든 자료를 말한다(Snijders, Matzat, & Reips, 2012). 이러한 정의는 자료의 크기에 초점이 맞추어져 있다. Lancy(2001)는 “빅데이터는 향상된 통찰과 의사 결정을 위해 비용 효율적이고 혁신적인 형태의 정보처리가 필요한 고용량(volume), 고속도(velocity), 고도의 다양성(variety)을 지닌 정보 자원이다”라고 정의하고 있다. 이를 흔히 3V라 부른다. 고용량과 고속도는 컴퓨터의 용량과 속도에 관한 것

으로 기존의 컴퓨터와 소프트웨어로 다루기 힘들어서 계산과 저장을 위한 새로운 유형의 정보처리기술이 필요하게 된다. 다양성은 원 자료가 숫자의 형태가 아닌 글이나 사진 동영상 등에 대한 분석이 포함되는 것을 의미한다. 이 밖에도 진실성(veracity), 변산성(variability), 시각화(visualization), 가치(value)의 네 가지가 더 포함되기도 한다.

빅데이터에 대한 개념적 정의가 위와 같은 것이지만, 실제로 이 용어가 사용되고 있는 화용론적인 의미는 다소 다른 것으로 보인다. 이 용어가 남용되다 보니 조금 큰 자료를 사용한 일반적인 자료 분석도 빅데이터 분석이라고 부르고 있으며, 대부분의 자료 분석을 빅데이터 분석이라 부르고 있다. 예컨대 Young(2018)에서 심리학에서는 오래전부터 빅데이터가 구축되고 사용됐다고 주장하기도 했는데, 이는 빅데이터를 비교적 큰 자료로 보는 해석이다. 그러나 빅데이터는 자료의 크기 이외에도 함의하는 다른 의미가 있는 것으로 보인다.

일반적으로 대중과 심리학자를 포함한 사회과학자들이 빅데이터 분석이라 부르는 경우를 관찰해보면, 대체로 다음과 같은 특징을 지니고 있는 것으로 보인다.

- 사람, 시간, 공간상에서 기존의 자료보다 넓은 범위의 자료를 말한다. 예컨대 많은 사람을 포함한다든지, 장기간의 자료와 여러 위치의 자료를 동시에 다루는 경우가 이에 해당한다.
- 이전에는 분석되지 않고 쌓여있는 자료들을 새롭게 분석할 때 빅데이터라는 말을 사용한다. 예컨대, 특정한 운동팀에서 이전에 사용하지 않았던 운동선수들의 기록들을 새롭게 분석하는 경우에 빅데이터 분석이라 부

른다. 그렇지만 빅데이터에 해당하는 만큼 데이터가 크지 않아서 자료 분석이라 말하는 것이 더 타당할 것이다. 또한, 사진이나 텍스트에 대한 분석도 이러한 의미에서 빅데이터 분석이라 부르는 것으로 보인다.

- 모형 주도적(model-driven)이라기보다는 자료 주도적(data-driven)으로 분석하여 자료에서 정보를 추출하려고 시도한다. 이러한 특징 때문에 기존에 사용되지 않았던 기법들 특히 기계학습에 사용된 기법 등이 많이 사용된다.

빅데이터, 자료과학, 기계학습

빅데이터는 자료의 특성만으로 정의되지 않으며 분석 기법과 밀접하게 연관되어 있어서 자료과학(data science), 기계학습(machine learning)과 연계되어 이해되어야 한다. 자료과학분야에서 빅데이터는 기존의 분석 방법보다는 기계학습과 같은 인공지능의 기법을 이용하여 분석된다. 기계학습은 예측이나 분류를 하는 데 주로 사용하는 계산기법으로 이 기법을 적용하기 위해서는 매우 많은 양의 자료가 필요하다. 이러한 이유로 기계학습은 빅데이터와 밀접하게 연결되어 있다. 이들은 정보기술(IT)의 발전으로 발생한 부수적인 이점으로 발전된 것으로 볼 수 있다. 빅데이터가 본격적으로 가능했던 가장 큰 이유는 인터넷의 발전 때문이었다. 인터넷의 이용이 기하급수적으로 증가함에 따라서 인터넷 공간상에 쌓이는 자료의 양은 이전에는 상상하지 못할 정도로 커졌다. 매일 4백만 이상의 블로그가 인터넷상에서 게시되고 있으면, 매일 5억 개 이상의 트위터가 전송되고, 매일 50억 개 이상 구

글 검색을 하고 있을 정도로 인터넷의 사용과 그로 인한 자료가 늘어나고 있다(HostingFacts Team, 2019 November).

이러한 대규모의 자료는 기계학습이라는 범주로 분류되는 계산 기법에 의해 분석된다. 이 분석들의 가장 큰 특징은 많은 자료에서 규칙을 스스로 학습한다는 것이다. 기계학습의 시초라 볼 수 있는 신경망은 심리학자들이 대거 참가한 프로젝트에서 시작되었다. 이 당시에 광범위하게 사용되었던 인공지능의 기법은 소위 법칙-기반(rule-based)이었다. 심리학의 ACT(Anderson, 1990)가 적용한 생성 시스템(production system)처럼 문제를 해결하는 데 필요한 법칙을 설정하고 이 법칙에 따라 문제를 해결하였다. 이 시스템을 구성하기 위해서는 법칙에 대한 영역 전문가(예컨대, 심리학자)가 중요한 역할을 하였다. 정보 시스템 중에서 가장 발달한 인간의 정보처리 시스템을 인공지능에 적용하려는 노력이 활발하게 이루어졌다. 신경망의 등장은 이러한 법칙을 가정하지 않고 사례를 통한 스스로의 학습에 의하여 문제를 해결하는 것을 가능하게 하였다.

신경망에서는 연합주의에서 자극과 반응 사이의 연합에 의하여 행동을 설명하는 것을 받아들인다. 다만 자극과 반응이 각각 다차원의 세부특징(feature)으로 정의되어서 이 둘 간의 연합관계도 또한 다차원적 특성이 있다. 또한, 자극과 반응 사이에 다른 중계자(신경망에서 은닉층)를 만들어서 이 둘 사이의 비선형적이고 복잡한 관계를 잡아낼 수 있도록 하였다. 이 중계자는 개념적으로 기술되기 힘든 수학적 행렬 시스템의 형태이기 때문에, 행동주의의 문제점으로 비판되었던 암흑 상자의 문제가 다시 등장하게 되었다. 신연합주의(neoassociationism) 혹은 신연결주의

(neoconnectionism)라고도 불리는 신경망 모형들은 이러한 이유 때문에, 1980년대 중반부터 2000년대 초반까지 심리학에서 전성기를 이루었지만, 2000년대 이후에는 그리 활발한 연구가 진행되지 않았다. 다만 인공지능의 분야에서는 신경망이 지지벡터기계(support vector machine) 등으로 대치되다가 2010년대에 이르러 다시 딥러닝(deep learning)이라는 새로운 개념으로 신경망이 다시 부흥기를 맞이하고 있다.

심리학 이론의 가장 큰 장애물로 생각되었던 은닉층에 대한 해석의 문제는 시스템에 대한 질차적 설명보다는 예측의 정확성을 더 중요시하는 기계학습에서는 크게 중요하게 다루지 않았으며, 도리어 인간의 개입 없이 스스로 세부특징을 찾아내는 (즉 법칙을 찾아내는) 것이 장점으로 받아들여졌다.

빅데이터 분석에서 사용되는 기법이 특정한 기법들에 한정되어 있는 것은 아니다. 기존의 통계학 기법과 기계학습, 데이터 마이닝(data mining)에서 사용된 기법들을 응용하고 있다. 모형주도적 분석보다는 자료주도적 분석에 의존하다 보니 통계학의 기법보다는 기계학습이나 데이터 마이닝 기법 등을 더 많이 사용하게 된다. 회귀분석이나 로지스틱 회귀분석, 군집분석 등은 통계학의 기법이고, 신경망, 지지벡터기계, 딥러닝 등은 기계학습의 기법이며, 수형도 분석(tree analysis) 등은 데이터 마이닝 기법이라 할 수 있다.

빅데이터와 기계학습이 자료와 분석 방법에 해당한다면, 이 영역들에서 새로운 학문 분야로서 자료과학이 최근에 등장하였다. 자료과학의 학문의 범위는 다소 모호하지만, 빅데이터를 분석하는 다양한 방법 등을 다루는 학문 분야라 부를 수 있다. 이 분야에서는 구글이

나 넷플릭스 등에서 특정한 서비스를 사용하는 사람들의 디지털화된 활동을 저장하여 분석하는 일을 주로 하고 있다. 따라서 거대한 자료를 저장하고 분석하여 관리하는 방법에 대한 지속적인 연구가 진행될 수 밖에 없다. Hadoop와 같이 인터넷 제공 회사에서 빅데이터를 처리하는 서비스를 제공하기도 하고, 자신들의 자료를 분석하는 다양한 기법들을 발전시키기도 한다. 이러한 이유로 자료과학은 학계보다는 몇몇 대형 업체를 중심으로 연구가 진행되는 경향이 있다.

심리학에서의 빅데이터

현재까지 빅데이터를 이용한 분석은 학술적 연구보다는 소비자 분석과 예측 같은 산업 장면에서 많이 사용되고 있다. 어떤 사람이 어떤 상품을 구매할 것인지, 어떤 영화를 좋아하는지, 혹은 어떤 사람이 신용카드 연체를 할 것인지에 대한 예측을 하는 데 사용된다. 반면, 학문적인 영역에서 빅데이터의 이용은 상대적으로 그리 활발하지 않다. 심리학 연구에서 빅데이터를 사용한 연구의 예로는 사회망 서비스(SNS)에 기록된 사람들을 활동에 이용하여 성격특성을 파악한 연구(Kosinski, Matz, Gosling, Popov, & Stillwell, 2015; Kosinski, Wang, Lakkaraju, & Leskovec, 2016)와 휴대전화에 저장된 행동 자료(앱 사용 비율, 전화, 문자 사용 등)와 인터넷 중독 간의 관계를 연구(Markowitz 등, 2014) 등을 들 수 있다. 그러나 심리학에서의 빅데이터의 이용은 다른 사회과학에 비해서도 지극히 느린 편이다(Cheung & Jak, 2016; Moustafa et al, 2018).

심리학에서 빅데이터에 의한 연구가 잘 이

루어지지 않는 가장 큰 이유는 심리학의 연구 방법론이 빅데이터의 분석과는 다르기 때문일 것이다. 빅데이터 분석은 사람의 행동을 예측하는 데 매우 유용하지만, 사람들이 그 행동을 산출하는 과정을 설명하는 데에는 그리 큰 도움을 주지 못한다. 심리학에서는 자료의 예측보다는 사람의 심리구조나 과정에 대하여 이해하는 것을 더 중요시하는데, 빅데이터 분석법에서는 이러한 과정이 대부분은 암묵 상자로 남아있다.

빅데이터 혹은 자료과학에서는 “자료가 스스로 말하게 하라(Let the Data Speak for Themselves)”라고 주장한다. 즉 이론이나 모형을 먼저 설정하고 자료에 의해 검증하는 방식으로 연구를 진행하는 것이 굳이 필요하지 않으며, 자료에 나타난 규칙적인 패턴들을 기술하기만 해도 자연현상이나 사회현상을 잘 설명할 수 있다고 주장한다. 매우 설득력 있는 말로 들리지만, 이것의 가능성에 대해서는 다음과 같은 이유에서 회의적이다. 첫째, 어떤 자료를 선택하고 그 자료에서 어떤 변수를 분석하며 어떻게 분석하는지를 결정하는 것은 연구자이다. 연구자는 이러한 과정에서 자신의 외현적 내현적 이론을 형성하고 이에 따라 분석을 진행하게 된다. 겉으로 보기에는 이론이 없는 것처럼 보이지만, 명시화되지 않고 남에게 공포하지 않는 자신의 이론이 있는 것이다. 둘째, 주어진 자료에 근거해서 어떤 현상을 설명하고자 할 것인데, 이때에도 자신의 이론이 개입되게 된다. 자료 분석에서 개인의 주관적 개입 없이 분석되는 것은 불가능한 일이다. 이론을 명세화하고 공포한 다음 검증하는 것과 자료 분석의 결과를 미리 본 다음 공포되지 않은 자신의 이론에 의하여 자료를 설명하는 것 중 어느 것이 더 타당한지는 명약

관화한 일이다. 셋째, 자료에 근거한 설명을 하면 체계적인 반복 검증을 할 수 없다. 동일한 자료가 수집되어 동일한 현상을 다시 발견할 수도 있지만, 연구자의 체계적인 설계에 따라 동일한 조건에서 반복 검증하기는 힘들다. 이는 현재의 자료에 의해 내린 결론을 반증할 수 있는 자료를 얻는 것이 불가능함을 의미한다. 반증할 수 없는 사실을 과학적 결과로 받아들일 수는 없는 일이다(Popper, 1959).

자료에 근거한 예측이 잘못된 결론을 유도하는 사례로 다음을 들 수 있다. 2014년에 프린스턴의 연구자들은 빅데이터를 분석한 결과에 근거하여 페이스북 사용자가 2017년에 현재의 20%로 줄어들 것이라는 예측을 하였다. 이들에 의하면 질병의 확산을 다루는 역학 모형을 사회망 연구에 적용하여 페이스북의 이용이 현재 정점에 도달하여 쇠퇴하는 국면으로 들어갔다고 주장하였다. 이를 반박하기 위하여 페이스북 연구자들은 동일한 기법을 사용하여 프린스턴 학생의 등록률을 예측하였다. 결과는 2018년이 되면 프린스턴 학생의 등록률이 절반으로 줄고, 2021년이 되면 한 명도 등록하지 않을 것으로 예측하였다(Griggs, 2014).

이 사례는 이론적 근거나 영역 전문가의 전문지식에 의하여 설계된 자료수집이 아닐 경우 자료 자체가 정확한 결론에 곧장 도달하게 하지 않는다는 것을 단적으로 보여준다. 흥미롭게도 프린스턴에 대한 구글의 반박도 심리학의 연구방법론의 입장에서 보면 적절하지 않은 것이다. 페이스북에 대한 프린스턴의 예측이 잘못된 것을 직접적으로 증명한 것이 아니다. 심리학자라면, 프린스턴 연구의 가정이나, 방법론, 결과의 해석에 대하여 비판하고 프린스턴의 학생들이 줄어들지 않을 것이라는

가설이나 모형을 검증해야 할 것이다. 현재의 자료 패턴은 프린스턴의 모형이 잘 설명할 수 있지만, 미래의 예측은 다르다는 것을 보여줘야 할 것이다. 페이스북 연구팀이 말할 수 있는 것은 자료에 근거한 프린스턴 연구팀의 분석이 잘못될 수 있다는 것뿐이다. 물론 위의 논쟁은 학계에서 이루어진 일은 아니지만, 소위 빅데이터 혹은 자료과학의 대표적인 행태를 보여주고 있는 것으로 보인다. 즉 자료를 분석하여 영역에 대한 전문지식 없이 상식적인 수준에서 현상을 기술하고 있다.

자료 주도적 분석과 빅데이터

심리학의 연구방법론과 빅데이터의 연구방법론은 연구 패러다임 상에서도 매우 다른 접근을 하고 있다. 심리학과 경험적 사회과학 연구는 대체로 다음과 같은 연구절차를 따른다. 먼저 연구자는 사전 연구나 자신의 경험 혹은 전문가로서의 지식에 근거하여 개인의 행동이나 사회적 현상에 대한 이론적 모형을 만든다. 그 다음으로 이 모형을 검증할 수 있는 방법들을 찾아낸다. 행동실험을 할 수도 있고, 설문지를 통하여 연구할 수도 있고, 인터뷰 등을 할 수도 있다. 경험적 연구의 경우에는 실험이나 조사를 통해 측정치들을 얻게 된다. 연구자가 설정한 모형에 따라 이 측정치 간의 관계가 정해지게 된다. 예컨대 “사회망 서비스가 사회관계를 넓게 하지만 또한 얇게 한다.”라는 연구 모형이 있다고 하자. 연구에서는 먼저 사회망 서비스를 측정할 수 있는 변수와 사회관계의 범위와 심도를 측정할 수 있는 변수를 정의하여야 한다. 이렇게 변수가 정의되면, 연구 모형에 의해 사회망 서비스 변수의 값이 증가할수록, 사회관계 범위의 변

수의 값은 증가하고 심도의 변수의 값은 감소할 것이라고 예언할 수 있다. 실제 자료에서 이 관계를 관찰하지 못하면 연구 모형은 기각되게 된다. 이때 변수를 어떻게 정할 것인지, 관계를 어떻게 검증할 것인지에 따라서 사용하는 연구방법론이 달라질 것이다.

모든 연구 모형과 측정변수, 검증 방법이 정해진 후에 자료를 관찰하고, 자료에 의하여 연구 모형을 수용/기각할 것인지를 결정하게 되는 것이다. 이러한 모형 주도적 분석(model-driven analysis) 방법은 심리학의 대표적으로 사용하는 연구법이다. 이와 반대되는 개념이 자료 주도적 분석(data-driven analysis)이다. 이 분석법은 자료를 먼저 수집하고, 자료의 패턴을 보고 가설을 설정하여 분석하는 것이다. 이는 심리학 연구 연구방법론에서 피해야 할 대표적인 접근 방법으로 알려져 있다. 빅데이터 분석은 사실 이러한 자료 주도적 분석에 의존하고 있다.

심리학 연구에 빅데이터를 사용하기 위해서는 이 자료 주도적 분석을 심리학 연구 방법에 사용하는 논리가 필요하다. 즉 심리학에서 빅데이터의 분석을 수용할 것인지에 대한 문제는 자료 주도적 분석을 심리학에서 허용할지의 문제와 직접적으로 연결되어 있다.

심리학에서 자료주도적 분석법을 받아들이기 힘든 것은 이 분석법에 따른 결과를 일반화(generalization)하기 힘들다는 한계 때문이다. 통계적 추론의 경우 표본의 자료를 이용하여 모집단의 특성을 설명한다. 즉 일부의 자료에서 얻은 결과를 전체에 적용시키는 일반화가 필요하다. 일반화는 현재의 자료를 이용한 분석 결과를 이용하여 아직 관찰되지 않은 새로운 자료를 예측하는 것과 동일하다. 대부분의 학자들은 관찰된 집단에 한정된 결과에 관심

을 가지기보다는 모집단 전체의 특성에 관심을 가지므로 일반화를 할 수 없는 결과는 매우 제한된 가치를 지닌다.

왜 자료주도적 분석은 일반화에 있어서 문제가 발생하는 것일까? 이에 대한 문제는 교차타당도(cross-validation), 모형오류(model error), 전체 불일치(overall discrepancy), 편향 분산 상쇄(bias variance trade-off), 모형의 복잡성(model complexity)이라는 주제로 다양한 맥락 속에서 연구되었다. 자료주도적 분석에서는 자료의 설명력을 높이기 위해 자료에 기반하여 분석 모형이나 설명모형을 수정하게 된다. 이 과정에서 모형은 점차 복잡한 형태를 띠게 되어 소위 과잉 적합(overfitting)이 발생한다. 이러한 모형은 수집된 현 자료를 가장 잘 설명하지만, 분석에 사용되지 않은 새로운 자료를 가장 잘 설명할 수 있는 모형은 아닐 가능성이 높다. 이해를 돕기 위하여 간단한 예증을 통하여 이를 살펴보자. 그림 1의 왼쪽 그래프에 10개의 자료를 설명하는 두 가지 모형이 제시되어 있다. 이 자료는 $y = a + bx + e$ 의 함수에서 생

성된 것이며 e 는 평균이 0이고 표준편차가 0.2인 정규분포를 따른다. 이 자료를 선형함수(f_1)로 예측한 것은 직선이고, 8차 다항식 함수(f_2)로 예측한 것이 얇은 곡선이다. 얼핏 보기에다 다항식 함수가 선형함수보다 자료를 더 잘 설명하는 것으로 보인다. 오차의 제곱합은 f_1 인 경우에 0.664, f_2 인 경우에 0.022로 f_2 가 10개의 자료를 더 잘 설명하고 있다. 이 분석에는 자료의 적합도만 보면 8차 다항식 모형이 1차 선형모형보다는 더 좋은 모형이라고 결론을 내릴 수 있다. 실제로 자료는 선형 모형에서 나왔다는데도 선형모형보다는 다항 모형이 이 자료를 더 잘 설명하고 있는 것이다. 그러나 8차 다항식 모형이 선형모형에서 나온 새로운 자료를 더 잘 설명할 수 있는 것은 아니다.

위와 동일한 모형($y = a + bx + e$)에서 새로운 자료를 생성해내고 앞에서 구한 두 모형으로 새로운 자료를 예측하면 어떻게 될까? 이에 대한 결과가 그림 1의 오른쪽 그래프에 제시되어 있다. 1차 선형모형은 여전히 새로운




그림 1. 한 표본의 자료를 선형모형과 다항모형으로 적합한 다음(왼쪽 그래프), 새로운 표본의 자료를 동일한 모형으로 적합한 결과(오른쪽 그래프)

자료를 잘 설명하고 있다. 그러나 다항 모형은 그 설명력이 매우 떨어지는 것을 알 수 있다. 실제로 오차제곱합에서 선형모형은 1.296이고 다항모형은 1.947이다. 즉 f_2 는 현재 관찰된 자료를 잘 예측하지만 자료의 일반적인 패턴은 잘 예측하지 못하였다. 이때에는 오히려 f_1 이 더 잘 예측하였다.

자료주도적 분석법에서 모형을 선택할 때, 전반적인 자료의 특성뿐만 아니라 현재 있는 자료에만 존재하는 독특한 속성까지도 예측할 수 있는 모형을 만든다. 그림 1이 왼쪽 그래프에 왼쪽에 있는 두 자료를 설명하기 위하여 곡선이 급격하게 변하지만, 이러한 패턴은 그림 1의 오른쪽 자료를 설명하는 데에는 도움이 되지 못한다.

빅데이터 분석법에서 이러한 문제를 해결하기 위하여 자료를 두 개로 나누어서 자료주도적으로 모형을 형성하는 단계(학습단계, training)와 이를 새로운 자료에서 검증하는 단계(testing)로 구분하여 연구하기도 한다. 모형 생성에서 사용된 자료와 다른 자료에 모형이 적용되면, 모형이 일반화 가능하다는 것을 의미한다. 그러나 이러한 방법이 근본적인 해결책이 되지 않을 수도 있다. 모형 학습 단계에서 무수히 많은 모형 중 자료에 의해 하나를 선택하는 것이기 때문에, 한 자료를 사용하면 하나의 모형만 선택되므로 다른 모형을 선택하는 것은 애당초 가능하지 않기 때문이다. 물론 다수의 자료를 선택하여 그때마다 다수의 모형을 선택하여 비교하는 것도 가능하지만 실질적으로 이러한 절차를 따르는 연구자는 없다. 이는 모형이 자료에 근거하여 만들기 때문에 발생하는 문제이다.

이러한 문제 지적에 대한 반박으로 빅데이터는 연구의 대상이 되는 모집단 전체에 대한

자료를 가지고 있으므로 표본을 이용하여 모집단을 추론하는 연구와는 다르다고 주장할 수 있다. 그러나 빅데이터가 많은 양의 자료를 갖고 있지만, 우리가 관심을 가진 모집단 전체에 대한 자료를 가지고 있는 경우는 극히 드물다. 설사 모집단의 정보를 다 가지고 있다고 하더라도, 미래에 생길 수 있는 자료까지 다 가지고 있는 것은 아니다. 따라서 현재의 패턴이나 경향을 설명할 수 있더라도 위에서 예로 든 페이스북의 운명을 정확히 예측하는 데에는 한계가 있을 수밖에 없다.

모형주도적 분석과 빅데이터

빅데이터 분석법에서도 모형주도적 분석을 사용한다는 반박이 있을 수 있다. 사실 모형을 설정하고 이를 반영하는 자료 처리 기계를 구현하여 이 결과를 보고 모형을 평가하는 연구들도 다수 존재한다. 실험심리 연구 방법론과 거의 동일한 형태를 띠고 있다. 그러나 여기에서는 모형은 입력과 출력을 연결시키는 자료처리 알고리즘을 말하며, 심리학에서 말하는 심리적 현상을 설명하는 모형과는 거리가 있다.

이 논문에서 말하는 심리 모형이란 입력과 출력을 연결 짓는 알고리즘 이상의 의미를 가지고 있다. 즉 심리 과정을 명세하는 모형이어야 된다. 시스템(알고리즘)이 특정한 입력에 대하여 산출한 출력이 사람이 동일한 입력(자극)에 대하여 산출한 출력(반응)과 동일하다고 해서 그 시스템이 인간의 심리 과정을 따르고 있다고 결론을 내릴 수는 없다. 동일한 입력-출력을 산출할 수 있는 시스템이 하나 이상 존재할 수 있기 때문이다. 시스템을 구성하는 요소들이 심리학적 의미가 있을 때 이 모형이

의미가 있다. 시스템을 심리학적으로 평가하기 위해서는 경쟁적인 모형들을 제안하고 이 모형들을 차이를 반영할 수 있는 실험 조작에 의하여 자료를 산출해내어야 한다. 이러한 관점에서 보면, 현재의 빅데이터 분석법이 심리현상에 대한 심리학적 설명을 제시하는 모형을 제공하고 있다고 보기는 힘들다.

심리학에서 빅데이터를 활용한 연구의 가능성

과학으로서의 심리학은 일반화할 수 있는 사실 내지는 지식을 축적하는 것에 목적을 두고 있으므로 당연히 자료주도적 분석법이 지양되고 있다. 그렇다면 이러한 틀 속에서 빅데이터를 심리학에 활용할 수 있는 방법은 무엇일까? 첫째, 자료주도적 방법 즉 자료에서 패턴을 찾아내어 설명하는 방식을 심리학에서 수용할 수 있는 길을 찾아내는 것이다. 이러한 가능성은 적어도 당분간은 실현되기 힘들 것으로 보인다. 이를 위해서는 심리학의 연구의 패러다임을 전환해야 하기 때문이다. 심리학은 현상에 대한 기술보다는 설명에 더 가치를 두고 있고, 사후 설명은 연구방법론에서 바람직하지 않은 것으로 보고 있다. 그러나 자료주도적 방법을 사용하여 현 심리학에서 해결하지 못하는 문제를 해결하는 창의적인 방안을 제시할 수 있다면, 연구의 새로운 패러다임도 변화될 수 있다는 가능성은 열어두어야 할 것이다. 둘째, 빅데이터에 모형 주도적 방법론을 적용하는 것이다. 즉 이론에 의해 모형을 만들고 빅데이터를 이용하여 이를 검증하는 것이다. 가능한 방법이기도 하지만 문제들이 많다. 빅데이터가 이론에 대한 가설

검증을 위한 형태로 제공되지 않기 때문에, 빅데이터에 필요한 자료가 항상 존재하는 것은 아니고, 존재하더라도 찾기가 쉽지 않기 때문이다. 그리고 빅데이터에서 자료를 확인되더라도 기존의 실험 연구 방법에 비해 그리 큰 장점이 아닐 수 있다. 결국 기존 방법에서 표본의 크기를 확대하는 것에 지나지 않기 때문이다. 비용의 측면에서 빅데이터에서 자료를 추출하는 것과 설계에 의해 자료를 확대시키는 것 중 어느 것이 더 경제적인지는 판단하기 어렵다.

셋째, 심리학 혹은 사회과학에서 빅데이터 이용의 유용성을 탐색적 분석에서 찾는 것이다. 심리학의 모든 연구가 모형 주도적으로 이루어지는 것은 아니다. 연구자가 인위적인 조작을 가하지 않고 자연스러운 상태에서 관찰하는 것도 중요한 연구 방법 중의 하나다. 인류학에서는 대표적인 연구법이 참여관찰을 통한 질적 연구이다. 이 연구 방법에서는 체계적인 조작에 의하여 특정한 변수에 초점을 맞추기보다는 관찰을 통하여 현상을 이해하고 사람의 행동이나 발생한 사건들에 대하여 의미를 부여하고 이해하는 데 더 큰 목적을 둔다. 이를 통하여 개인이나 사회에 대하여 폭넓고 심도 있는 이해를 할 수 있다. 이러한 연구법이 가능한 이유는 연구자가 충분히 관찰하고 이해할 수 있는 소수의 사람만을 연구하기 때문이다. 반면 소수의 대상을 연구하기 때문에 이 결과를 일반화하는 데에는 한계가 있다. 사실 심리학자와 사회과학자들은 소수의 심층적인 연구와 다수의 인위적으로 통제된 협소한 영역의 연구 사이에서 항상 고민하고 있다.

빅데이터의 분석이 이에 대한 해결책의 하나로 제안될 수 있다. 연구자가 자연스러운

상태에서 장시간에 걸친 관찰을 여러 사람을 대상으로 하는 것은 사실상 힘들다. 그러나 현대의 사람들은 평상시에 행한 행동, 자신들이 가지고 있는 태도, 의견, 철학 등에 대하여 인터넷에 그 흔적을 남긴다. 예컨대 저술, 게시판에 남긴 글, 페이스북이나 사회망 서비스에서 남긴 글, 사진 등이 그것에 해당한다. 이러한 자료를 분석하면 실제로 오랫동안 대면하지 않고도 대량의 질적 자료를 얻을 수 있다. 물론 이 경우에 연구자가 자료들을 면밀하게 검토하여 분석할 수 있지만, 이를 위해서는 많이 시간이 요구된다. 빅데이터의 분석 기법은 이러한 질적 자료에 대한 분석 방법을 제공할 수 있다. 예컨대 특정한 문화에 대한 다양한 사회 구성원들의 글을 빅데이터 자료 분석 기법을 사용하여 분석하고 이 결과의 도움을 받아서 인류학자, 심리학과, 사회학자 등이 세부의 글을 분석하고 의미를 부여할 수 있다. 이러한 경우에는 수치로 표현되어 있는 소위 정형 자료보다는 수치로 표현되어 있지 않은 글, 사진, 음성과 같은 비정형자료의 분석이 더 많이 사용될 것으로 보인다.

심리학에서 사용 가능한 빅데이터

빅데이터의 특징을 자료의 특성과 이 자료를 분석하는 기법들로 나누어서 살펴보고자 한다. 심리학에서 빅데이터의 활용방안을 모색하기 위해서는 이 두 측면에 대한 이해가 필요하고 이 두 측면은 서로 긴밀하게 연결되어 있다.

자료(Data)의 특성과 가용성

자료의 측면에서 보면, 심리학의 학문 분야에서는 빅데이터 형태의 자료가 그리 많이 축적된 것으로 보이지는 않는다. EEG(electroencephalogram), fMRI(functional magnetic resonance imaging)와 같은 신경 활동에 대한 자료는 크기의 측면에서 방대한 자료이지만, 빅데이터로 분류되기에는 한계가 있다. 신경의 활동 수준이라는 하나의 변수를 다수의 조건에서 관찰하고 있고 실험 설계에 의해 수집된 자료이기 때문에 자료의 양은 많아도 모형주도적 분석을 하여 필요한 정보를 추출할 수 있기 때문이다.

심리학에서도 다른 학문 분야와 같이 이미 존재하는 빅데이터 중에서 필요한 자료를 추출하여 사용할 수 있다. 예컨대, 카카오톡, 트위터나 SNS 등에서 일어나는 사람들의 대화를 분석하여 사람의 행동과 태도를 예측하고 설명하는 것이다. 심리학에서는 이러한 시도가 거의 이루어지지 않았지만, 그 한 예로 Youyou, Kosinski와 Stillwell(2015)는 페이스북의 자료를 이용하여 성격의 특성을 연구한 것을 들 수 있다.

구글, 아마존, 트위터와 같은 SNS의 자료는 일부 자료를 공개되어 있고, 애플리케이션 프로그래밍 인터페이스(Application Programming Interfaces, API)를 이용하여 제공받을 수 있다. API를 사용하여 자료의 사용자가 인터넷상에서 적절한 요청을 보내면, 자료를 인터넷으로 받을 수 있다. 명령어가 간단한 형식으로 구성되어 있고, 네트워크의 프로토콜과 같은 기술적 이해 없이도 사용자와 서비스제공자와 커뮤니케이션할 수 있다는 점에서 이점을 지니고 있다. 인터넷의 자료 중에서 웹사이트에

나와 있는 정보는 더욱더 쉽게 획득할 수 있다. 웹 크롤러(web crawler) 프로그램을 이용하여 웹사이트를 검색하고 필요한 정보를 수집할 수 있다.

빅데이터의 자료로서의 특성

빅데이터는 기존의 자료와 다른 여러 가지 특성이 있고 이에 따라 분석의 방법이 달라진다. Adjerid와 Kelly(2018)는 빅데이터의 자료와 크기와 관련된 세 가지 중요한 특징을 Big 'n', Big 'v'와 Big 't'의 세 가지로 보았다. 각각 표본의 크기가 큰 자료, 변수의 수가 많은 자료, 다 시점에서 관찰된 종단자료를 의미한다. 이러한 특징들에 따라 각각의 경우에 가능한 분석법과 필요한 분석법이 다르게 된다.

Big 'n'은 표본의 크기가 큰 자료를 말한다. 빅데이터의 특성으로 가장 많이 받아들여지지만, Big 'n'은 기존의 분석 방법을 쉽게 적용할 수 있다. 예컨대 회귀분석을 적용한다고 하면, 회귀계수를 구하는 공식은 $\beta = (X'X)^{-1}X'y$ 인데, 계산량이 가장 많은 $(X'X)^{-1}$ 의 차원은 $p \times p$ 이다(p 는 변수의 개수). 이때 시간복잡도는 가우스-조던 제거방법으로 계산하면 $O(p^3)$ 으로 p 에만 의존한다. 따라서 n 이 증가하더라도 역행렬의 계산량은 증가하지 않아서 이러한 종류의 빅데이터는 계산량에서 크게 문제가 되지 않으며, 기존의 방법으로도 분석하는 것이 무난하다. 다만 결측치의 수가 많은 경우 이를 삭제하여 분석하면 $X'X$ 의 역행렬의 존재하지 않게 될 수 있다. 이러한 경우에 결측치를 처리하는 방법을 도입해야 하므로 계산의 문제가 다시 등장할 수 있다.

둘째 Big 'v'는 많은 변수를 가지고 있는 경우이다. 빅데이터의 경우에는 일반적으로 n 이 많은 경우보다는 v 가 많은 경우에 더 많은 정보를 얻을 수 있다. 자료가 인간의 다양한 측면을 반영하기 때문이다. 그러나 분석 방법은 훨씬 복잡해진다. Big 'v'의 경우는 회귀분석, 분산분석과 같은 전통적인 분석 방법으로 다룰 수 없는 경우가 대부분이다. 회귀분석의 맥락에서 보면, 변수가 많으면 $X'X$ 의 계수(rank)가 커지며 역행렬에 대한 계산량도 많아진다. 변수의 수가 표본의 크기보다 크면 $n < v$, 계수가 n 에 의해 결정되므로 역행렬 즉 $(X'X)^{-1}$ 가 존재하지 않아서 회귀계수를 구할 수 없다. 이러한 경우에는 능선 회귀분석, 라소 회귀분석과 같은 새로운 분석 방법이 필요하게 된다. 또한, 회귀분석이 가능한 경우라도 변수의 수가 많아 모형에 모든 변수가 포함되면 해석이 용이하지 않기 때문에, 변수를 선택하거나 변수들을 조합하여 새로운 변수를 만드는 과정이 필요하다.

또한 회귀분석, 분산분석과 같은 경우에 변수가 많아지면 결측치의 문제도 고려해야 한다. 이들 분석에서는 많은 변수 중에 하나의 변수라도 결측치가 있는 개인은 분석에서 탈락된다. 빅데이터의 특성상, 모든 변수의 관찰치가 모든 개인에게 존재하는 것이 아니기 때문에, 많은 결측치가 있는 매우 성긴(sparse) 자료일 가능성이 많다. 따라서 대부분의 자료가 탈락되어 빅데이터의 장점을 살릴 수 없을 가능성도 있다.

세 번째 Big 't'는 동일한 개인에 대한 정보가 다수의 시점에서 관찰된다는 것이다. 동일한 변수를 동일한 사람에게 여러 시간에 걸쳐서 관찰할 수 있다면, 개인의 특성에 따라서 변수들의 관계들이 어떻게 변하는지 혹은 한

개인의 특성이 안정된 것인지 시간에 따라 변하는 역동적인 것인지에 대한 정보를 얻을 수 있다. 이러한 자료는 종단분석(longitudinal analysis)과 관련된 다양한 분석법을 통하여 분석될 수 있다. 하지만 빅데이터의 특성을 반영하는 분석 방법론을 제안한 연구는 쉽게 발견되지 않는다. 이러한 유형의 빅데이터에서도 상당한 결측치가 관찰될 수 있으므로, 결측치를 처리할 수 있는 빅데이터 분석법이 새롭게 개발될 필요가 있다.

물론 이 세 가지는 서로 배타적인 것이 아니다. Big 'v'와 Small 'n'도 가능하지만 Big 'v'와 Big 'n' 혹은 Big 'n', Big 'v', Big 't'도 가능하다. 자료의 차원들이 추가되면 더 안정되고 많은 정보를 추출할 수 있지만, 자료의 차원이 증가함에 따라 드는 비용과 노력은 기하급수적으로 증가한다. 예컨대 $n=100, v=100$ 인 경우에는 10,000개의 자료가 관찰되면 되지만, $n=100, v=100, t=100$ 인 경우는 1,000,000개의 자료가 관찰되어야 한다.

빅데이터를 이용하면 비교적 손쉽게 자료를 얻을 수는 있으나, 연구자가 원하는 자료가 포함된 경우가 많지는 않을 것이며 포함되어 있더라도 많은 결측치를 가지고 있을 것이다. 빅데이터에서 연구자가 원하는 자료가 존재하는지를 확인하는 것이 빅데이터의 연구에서 가장 중요한 것으로 보인다.

빅데이터의 또 다른 특성은 자료의 다양성이다. 즉 숫자 이외의 자료 소위 비정형 자료(unstructured data)에 대한 분석이 가능하다는 것이다. 비정형 자료로 사진이나 영상자료 음성자료 등을 들 수 있는데, 심리학 연구에서 사용되고 있고 가용성이 가장 높은 것이 텍스트(text) 자료이다. 텍스트는 다른 비정형 자료에 비해서 다양한 이점을 지닌다. 사진이나

음성자료와는 달리 직접 의미와 연결될 수 있다. 개인이 생성한 글에서 의미분석을 하면 개인의 생각이나 성격, 태도 등을 추론할 수 있다. 또한, 텍스트의 언어 자극과 의미의 관계는 잘 연결되어 있기 때문에, 보다 과학적이고 객관적인 분석이 될 수 있다. 텍스트는 다른 자료에 비해 인터넷상에서 비교적 쉽게 접근할 수 있다. 여러 종류의 SNS에서 사람들이 텍스트로 의사 소통을 하고 이러한 내용이 잘 저장되어 있기 때문이다.

물론 비정형 자료는 회귀분석과 분산분석과 같은 기존의 방법으로 분석하는 것이 용이하지 않다. 예컨대 텍스트 분석을 위해서는 텍스트로부터 의미를 추출해야 하는데 이러한 방법들로는 의미추출을 할 수 없다. 텍스트에 대한 새로운 통계적인 의미 추출 방식이 등장하여 활발하게 이용되고 있어서 이에 대한 분석이 가능하게 되었다.

심리학 연구에 적용될 수 있는 기계학습기법들

인공지능이나 기계학습의 분야에서 매우 다양한 형태의 기계학습기법들이 개발되어 있다. 그 중, 심리학에서 널리 사용되고 있는 통계 분석과는 다른, 심리학의 빅데이터 분석에서 적용될 수 있는 기법들에 대하여 살펴보고자 한다. 기술적인 측면의 자세한 설명보다는 심리학자가 기법을 이해하는데 필요한 원리를 중심으로 기술할 것이다. 또한, 이 기법들이 심리학 연구에서 어떻게 사용될 수 있는지에 대해서도 논의할 것이다.

텍스트의 분석: 주제모형화(topic modeling)

텍스트의 분석은 비정형 빅데이터 자료 중에서 분석이 비교적 용이하고 의미를 직접 접근할 수 있는 장점이 있어 많이 사용되고 있으며, 특히 심리학 연구에 적용하기 쉬운 방법이다. 사람들은 글을 통하여 자신의 생각을 표현하기 때문에 이를 분석하면 사람들이 어떤 생각을 하고 있는지를 파악할 수 있다. 글의 분석을 통해 어떤 사안에 대한 사람들의 의견, 태도, 믿음 등에 대한 파악도 가능하다. 텍스트 분석의 또 다른 장점은 설문지 등의 정해진 틀 속에서는 나타나지 않은 자연스럽게 다양한 방식으로 표현된 자료를 이용할 수 있어서, 설문지 등에서는 발견할 수 없었던 풍부한 사실들을 찾아낼 수 있다는 것이다.

글은 풍부한 정보를 가지고 있지만 사진 동영상 등과 달리 숫자의 형태로 표현하는 것이 상대적으로 용이하다. 글은 문장으로 구성되어 있고 문장은 다시 단어로 구성되어 있어서 단어가 분석의 기초 요소가 될 것이다. 단어를 숫자로 표현하면 글을 숫자로 표현할 수 있다. 단어를 숫자로 표현하는 가장 간단한 방식이 단어의 빈도로 나타내는 것이다. 단어의 출현 빈도를 계산하여 해석하는 것은 현재 가장 많이 사용되는 분석법 중에 하나로 보인다. 신문에 많이 등장하는 단어나 SNS에서 자주 등장하는 단어들에 대한 분석이 그러한 예들이다. 빈도 분석에서 의미는 연구자가 부여한다. 그러나 빈도가 높은 몇 개의 단어로 텍스트의 의미를 파악하는 데에는 한계가 있다. 단어들은 서로 의미적으로 연결되어 있어서 한 단어는 다른 단어의 상위 개념일 수도 있고, 유사어 반의어일 수도 있고, 연상어일 수도 있다. 또한 단어들이 어떤 문장에서 어떤

단어와 같이 사용되었는지에 따라 다른 의미를 가진다. 이러한 단어들 간의 관계를 고려하지 않고 단순한 빈도의 분석은 원래 글이 가지고 있는 충분한 의미를 파악하지 못하게 한다.

심리학, 언어학, 인공지능 영역에서 단어들 간의 의미 관계를 고려하여 글의 의미를 표상하려는 시도들이 이미 오래전부터 있었다. 기계 언어 처리가 상당한 성공을 거두고 있으나, 계산부하량이 매우 높고 언어처리를 위한 통사, 의미, 화용론과 세상사 지식을 모두 이용해야만 한다는 단점이 있다. 모든 문장에 대한 정확한 해석이 요구되지 않고 큰 자료에서 중요한 의미를 요약적으로 찾아내는 문서처리에서는 이러한 방법들이 가장 최적의 방법은 아닐 수 있다.

빅데이터 분석에서는 통계학습(statistical learning) 방법을 사용하여 텍스트의 의미를 추출하는 방법이 가장 많이 사용된다. 단어가 얼마나 많이 등장하였는지에 대한 분석을 확장하여 단어가 어떤 문장에서 혹은 어떤 맥락 속에서 등장하였는지에 대한 정보를 적극적으로 활용한다. 특정한 시간이나 특정 공간과 같이 특정 맥락 속에서 동시에 등장하는 단어들은 의미적 유사성이 높을 것이다. 이러한 의미의 맥락 혹은 의미적 유사성을 이용하면 단어가 가지고 있는 더 풍부한 의미를 추출할 수 있다. 단어의 경우에는 이 맥락을 문장으로 볼 수도 있고, 문서로 볼 수도 있다. 단어의 빈도만 분석하지 않고, 어가 출현한 맥락을 함께 고려하는 분석이 주제 모형화(topic modeling)이다.

이 분석법에서는 단어들이 어떤 맥락 속에서 등장하였는지를 맥락-단어 행렬(context-word matrix) 혹은 문서-단어 행렬(document-term

표 1. 문서-단어 행렬(document-term matrix)의 예 (W_i 는 단어, C_j 는 문서, f_{ij} 는 발생빈도)

| | C1 | C2 | C3 | ... | Cn |
|-------|----------|----------|----------|-----|----------|
| W_1 | f_{11} | f_{12} | f_{13} | | f_{1n} |
| W_2 | f_{21} | f_{22} | f_{23} | | f_{2n} |
| | | | | | |
| W_m | f_{m1} | f_{m2} | f_{m3} | | f_{mn} |

matrix)를 통하여 표상된다. 표 1이 그 예인데, 단어 W_i 는 그 단어가 각 맥락 속에는 나타나 빈도로 정의되며, 맥락 C_j 는 그 맥락에서 등장한 단어의 빈도로 정의된다.

이 맥락-단어 행렬을 분석하여 의미를 추출하는 방법으로 가장 널리 사용되는 분석법이 잠재 의미 분석(Latent Semantic Analysis, LSA)과 잠재 디리크레 할당(Latent Dirichlet Allocation)이다.

잠재 의미 분석은 단어들이 어떠한 맥락 속에서 동시에 등장하는지에 대한 정보, 즉 맥락에서 단어들간의 공기성(co-occurrence)을 통하여 의미를 파악하는 방법이다(Landauer & Dumais, 1997; Landauer, Foltz & Laham, 1998). 잠재 의미 분석에서 가장 중요한 과정은 단어-맥락 행렬을 선형대수학의 특잇값 분해(Singular Value Decomposition, SVD)를 이용한 축소하여 단어들을 다차원 상에 다시 표상하는 것이다. 차원의 축소는 의미 공간을 요약하는 역할을 한다. 단어들 간의 유사성은 두 단어가 동일한 맥락(문서) 속에서 얼마나 자주 등장하였는지를 나타내는 두 단어 벡터의 코사인 값으로 정의된다. 예컨대 두 단어가 같은 문서 속에서 등장하였다면 높은 유사성 값을, 등장하지 않았다면 낮은 유사성 값을 가지게 되는 것이다. 차원을 축소하면 두 단어

가 같은 문서 속에서는 등장하지 않더라도 A 단어가 C 단어와 유사하고 B 단어가 C 단어와 유사하면 A와 B를 유사성을 높게 하는 고차적인 상관을 표상할 수 있다. 이러한 이유에서 차원을 축소하지 않는 것보다 축소하는 것이 의미 파악을 더 잘할 수 있다. 다시 말하면 축소 전에는 나타나지 않았던 2차, 3차, 고차의 상관이 탐지될 수 있는 것이다. LSA를 사용하여 의미를 파악하는 과정에서 하나의 단점은 각 축이 의미하는 바가 무엇인지 파악하기 힘들다는 것이다. 그러나 각 축과 단어 벡터의 유사성을 계산하여, 축과 유사성이 높은 단어들을 추출함으로써 각 축의 의미를 파악할 수 있는 방법도 제안되었다(김청택, 이태현, 2002; 이태현, 김청택, 2004).

잠재의미분석은 문서-단어 행렬의 차원을 축소하고 문서와 단어들 간의 유사성을 정의함으로써 문서의 의미 파악이나 분류 등에 사용할 수 있는 기법이다. 통계학적으로 보면 주성분 분석의 확장으로 볼 수 있다. 이 분석에 문서와 단어가 특정한 분포에서 생성되었다는 가정을 추가하면 확률잠재의미분석(Probabilistic LSA; PLSA, Hofmann, 1999, 2001)이 된다. 이 모형은 심리측정학에서의 요인분석모형과 유사한 형태가 되며 통계학에서의 위계적 베이지안 모형의 형태를 띠게 된다. PLSA는 잠재 디리크레 할당(LDA, Latent Dirichlet Allocation) 기법으로 확장되는데, LDA에서는 문서가 토픽들의 혼합 분포(mixed distribution)에 의하여 결정된다는 가정 하에 위계적 베이지안 기법을 적용하여 텍스트를 분석한다(Blei, Ng & Jordan, 2003; Steyvers & Griffiths, 2006).

LDA는 흔히 생성모형(generative model)이라 불린다. 이 방법은 특정한 맥락 속에서 특정

한 단어가 나타나는 확률 모형을 설정한 다음, 이 모형에 가장 잘 맞는 파라미터를 찾아내는 방식으로 분석하게 된다. 문서 속의 단어의 출현 확률은 다음과 같은 여러 단계를 거쳐 예측되게 된다. (1) 먼저 텍스트는 텍스트의 분포에서 생성된다. (2) 텍스트가 정해지면 주제를 산출하는 분포에 의하여 주제가 생성된다. (3) 주제가 정해지면, 단어를 산출하는 분포에 의해 단어가 생성된다. 이는 모든 조건부 분포(conditional distribution)에 의하여 정의될 수 있다. LDA를 통하여 텍스트의 주제들과 각 주제에서 산출되는 단어들을 추정할 수 있다. 그러나 단어들간의 유사성과 텍스트들 간의 유사성을 계산하는 데에는 한계가 있다.

LSA와 LDA등의 기법을 이용하여 페이스북, 트위터, 신문 기사 등의 텍스트들에 등장한 주제들과 이슈들을 계산하고 이들이 어떤 주제를 다루고 있는지를 파악할 수 있다. 빅데이터를 이용한 심리학 연구의 다수가 텍스트 분석을 하고 있고 주제 모형화 기법을 사용하고 있다.

능선 회귀분석, 라소 회귀분석

빅데이터의 분석에서 많은 독립변수가 포함된 경우에 설명의 편의성을 위해서 실제로 종속변수를 설명하는데 공헌하는 변수들만 독립변수로 선택하는 소위 변수 선택(variable selection) 단계가 필요하다. 경우에 따라서는 변수의 수가 사례수보다 더 커서 기존의 회귀 분석 기법을 사용할 수 없는 경우도 발생할 수 있다. 변수의 선택과 자료의 적합을 동시에 하는 기법들이 능선회귀분석(ridge regression)과 라소 회귀분석(lasso regression)이다. 이 기법에서는 회귀분석의 최소제곱법(Ordinary Least

Square) 손실함수에 정규화(regularization)와 항목을 포함하여 회귀계수의 크기를 작게 하는 모형을 선택한다. 회귀계수의 크기가 0이거나 매우 작으면 그 독립변수를 회귀식에서 제외할 수 있어서 변수의 일부를 제거하여 단순한 모형으로 만들 수 있다.

두 회귀분석은 정규화에 대한 기준에서 다르다. 능선 회귀분석은 회귀계수들을 제곱합을 작게하는 방식으로 라소 회귀분석에서는 회귀계수들 절댓값의 합을 작게하는 방식으로 정규화를 한다(Tibshirani, 1996).

능선 회귀분석의 손실함수:

$$\sum_{i=1}^N \left(y_i - \sum_j \beta_j x_{ij} \right)^2 + \lambda \sum_j \beta_j^2$$

라소 회귀분석의 손실함수:

$$\sum_{i=1}^N \left(y_i - \sum_j \beta_j x_{ij} \right)^2 + \lambda \sum_j |\beta_j|$$

그림 2에서 평면은 회귀계수의 공간을 나타낸다. 예컨대 x축이 β_0 , y축이 β_1 을 나타낸다고 하면 (β_0, β_1) 는 단순 회귀분석을 취할 수 있는 모든 회귀계수의 값을 나타낸다. 그 중 $\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1)$ 는 일반적인 회귀분석의 손실 함수 (OLS) 즉 모형이 예측과 관찰된 자료의 차이의 제곱합을 최소화로 만드는 해를 나타낸다. 타원들은 동일한 최소제곱합을 산출하는 회귀계수들의 값들을 선으로 연결한 것인데, $\hat{\beta}$ 에 가까워질수록 그 값은 작게 된다.

능선 회귀분석에서는 회귀계수의 제곱합이 특정한 값보다 작다는 제약(즉 $\sum_j \beta_j^2 < t$)하에서 해를 구한다. 최소제곱합에 의한 해인 $\hat{\beta}$ 는 이 조건을 만족하지 못하기 때문에 해가 될

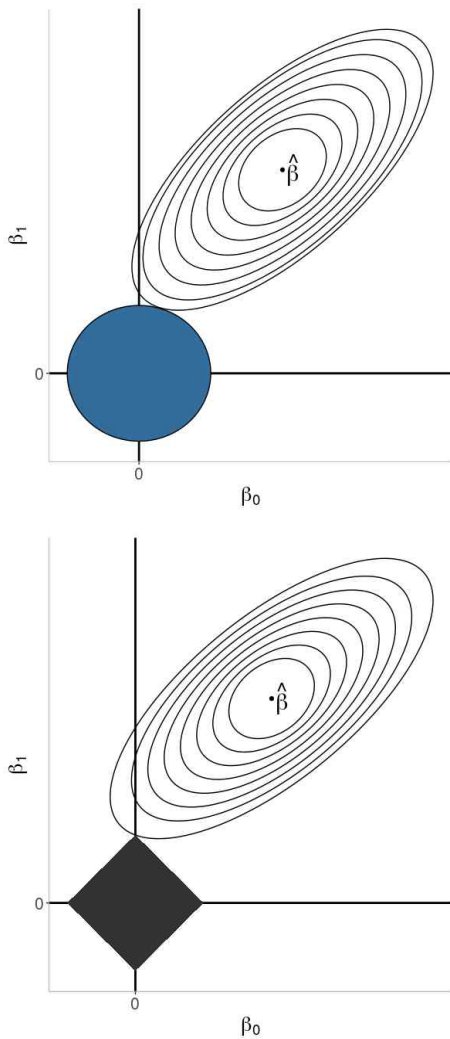


그림 2. 능선 회귀분석(위쪽)과 라소 회귀분석(아래쪽)과 회귀계수 공간

수 없다. 해가 될 수 있는 부분은 그림에서 채워진 원의 형태로 표현된다. 따라서 원 내에 포함되면서 제곱값을 최소로 하는 지점을 구해야 한다. 그림에서 보면 $\hat{\beta}$ 가 해가 되는 것이 아니고 타원과 원이 접하는 지점이 해가 된다. 동일한 논리로 라소회귀분석에서는 타원과 마름모가 접하는 지점이 해가 된다. 이

해들은 오차의 제곱합을 최소화시키지는 않지만, 회귀계수의 크기를 작게 하는 기준과 오차의 제곱합을 작게하는 기준을 모두 고려하여 구해진다. 두 정규식의 특징으로 인해, 능선 회귀분석은 회귀계수가 전반적으로 작은 해를, 라소회귀분석은 다수의 회귀계수들이 0이 되는 해를 구하게 된다.

정규화를 포함하는 것은 변수 선택의 기능 이외에 분석결과에 대한 일반화에도 밀접히 관련되어 있다. 앞서서도 살펴본 바와 같이 다수의 독립변수를 포함하는 회귀분석은 복잡한 모형으로 과잉적합의 문제를 일으킨다. 정규화를 통해서 모형을 단순화하면 적합도(fitting)는 낮아질 수 있지만, 일반화의 가능성은 더 높아진다. 이 기법은 또한 표본의 크기(n)가 변수의 수보다 작은 경우에도 작동한다는 장점도 있다.

이는 심리학에서 변수가 많은 자료를 다룰 때 유용하게 사용될 수 있으며, 회귀분석과 동일한 논리로 결과를 해석할 수 있다.

지지벡터기계(support vector machine)

기계학습 분야에서 딥러닝(deep learning)이 제안되기 전에는 지지벡터기계가 예측 분류에 가장 높은 수행을 보여주었던 기법이었다. 이 기법은 Boser, Guyon와 Vapnik(1992)에 의해 제안되었는데, 1960년대부터 계속발전되어온 통계학습이론(statistical learning theory)에 기반을 둔 것으로 알고리즘 자체는 복잡하지만 개념은 명확하다.

이 방법은 기본적으로 결과변수의 값에 따라 예측변수들로 구성된 공간을 분리하는 기법이다. 선형적으로 분리될 수 있는 단순한 경우를 예로 들어보자. 입력이 2차원이라면(예

측변수가 두 개라면) 예측변수는 2차원으로 표현될 수 있다. 그림 3에서 각 점은 개별 자료를 나타내며, 결과변수에 따라서 점은 +와 o로 표시되어 있다. 이 두 가지 종류의 자료(점)를 분리하는 방법은 다음과 같다. 직선을 그어서 직선 위에 입력이 위치하면 +로 아래에 입력하면 o로 분류하면 된다. 이를 수식으로 표시하면 다음과 같다. 아래의 식에서 y 가 분류된 값을 나타내는데 +는 +1, o는 -1로 표현된다고 하자.

$$y = \begin{cases} +1 & \text{if } ax + b \geq 0 \\ -1 & \text{if } ax + b < 0 \end{cases}$$

이 분류방식을 확장하여 하나의 분류 직선을 사용하는 것이 아니라 두 개의 직선을 사용하여 위쪽 직선보다 위에 있으면 +로 아래쪽 직선보다 아래에 있으면 o로 분류할 수 있다. 이를 수식으로 나타내면 다음과 같다. u 와 v 에 따라서 직선이 y 축상에서 평행이동하게 된다.

$$y = \begin{cases} +1 & \text{if } ax + b \geq u \\ -1 & \text{if } ax + b \leq v \end{cases} \quad \text{단 } u > v$$

두 직선 사이의 간격이 크면 클수록(즉 $u - v$ 의 값이 크면 클수록), o와 +가 더 확연히 분류되는 것임을 알 수 있다. 분류 시스템에서는 그 사이에 입력이 전혀 없는 두 직선을 찾아내어야 한다. 이렇게 직선 사이의 간격을 늘려나가면 결국에는 일부 자료들과 만나게 된다. 그림 3에서 두 개의 직선상에 4개의 자료가 놓여있다. 이를 지지벡터(support vector)라 한다. 지지벡터기계에서는 a 와 b , 그리고 u 와 v 를 구하게 된다.

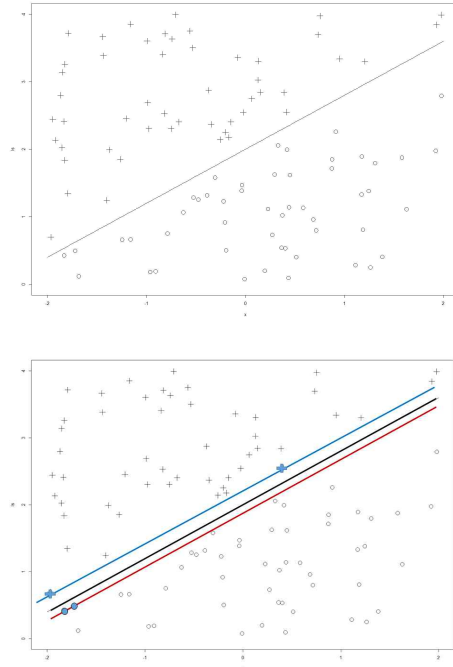


그림 3. 선형공간의 분리와 지지벡터

실제 문제에서는 이렇게 직선에 의해 선형적으로 분류할 수 있는 경우는 거의 없다. 지지벡터기계에서는 저차원에서는 선형으로 분리할 수 없는 자료를 차원을 확장하여 고차원 공간상에서 선형적 방식으로 분리한다. 그림 4의 왼쪽 그래프에서 x , y 의 두 개의 입력이 있고, $y = 5x^3 + x + 20$ 의 직선 위에 있으면 +로 분류하고 아래에 있으면 o으로 분류하는 경우이다. 그림에서 가로축은 x 세로축은 y 를 나타내는데, 이 경우에는 두 공간이 직선으로 분리되지 않는다. 오른쪽 그래프는 x 와 y 의 2차원으로 된 공간을 확장하여 x, x^3, y 를 축으로 하는 삼차원상에 표상한 것이다. 이 그래프에서 두 개의 범주는 굵은 직선으로 표현된 2차원 평면에 의하여 분리된다. 즉 x 의 자료만 주어졌지만 x^3 의 자료도 생성하여,




그림 4. 비선형 함수에 의한 공간분리와 커널로 확장된 차원에서의 선형 분리

(x, x^3, y) 를 이용하여 분류하는 모형에서는 선형 분리가 된다.

지지벡터기계는 다양한 방식으로 입력의 차원을 무한 차원까지 확장시키고 커널 트릭(kernel trick)에 의해 실제로는 무한 차원으로 확장시키지 않고도 계산하는 방법을 찾아내었다(Shawe-Taylor & Cristianini, 2004). 자료의 원 차원을 확장하여 구성된 공간을 세부특징 공간(feature space)라 한다. 위의 예에서 (x, x^3, y) 로 이루어진 공간이다. 지지벡터기계는 선형적으로 분리할 수 없는 자료를 세부 특징 공간으로 투사하는 함수인 세부 특징 함수를 사용하여 차원을 확장하여 선형적으로 분리할 수 있는 공간을 형성하고, 이 공간상에서 지지벡터를 사용하여 자료들을 분류하는 것이다.

지지벡터기계는 매우 강력한 기법이라서 차원을 늘리면 대부분의 자료를 선형 분리할 수 있다. 그러나 이렇게 구성된 모형이 새로운 자료를 예측하는데 반드시 도움을 주는 것은 아니다. 즉 일반화의 문제가 있다. 이를 위해서 이 기법은 모형의 복잡성과 자료의 설명력 사이에서 균형을 잡는 절차가 포함되어 있다.

심리학 연구의 관점에서 보면, 세부 특징 공간을 확인하는 것은 매우 중요한 의미를 지닌다. 세부 특징 공간 상에서 한 세부 특징은

여러 자극(변수)들을 조합하여 종속변수를 잘 설명할 수 있는 복합변수의 의미가 있다. 심리학 연구에서는 이러한 복합변수를 찾아서 입력과 출력을 매개하는 설명 개념으로 사용할 수 있다. 심리학의 관점에서 지지벡터기계의 문제점은 세부 특징 공간을 명시적으로 명세화할 수 없다는 것이다. 이 기법의 특성상 종속변수를 예측하는 데 사용되기는 하지만, 실제로 계산되지 않기 때문이다. 세부 특징 공간을 표현할 수 있는 기법이 개발된다면, 심리학에서 이 방법의 유용성은 매우 크게 될 것이다.

신경망(Neural Network)과 딥러닝(Deep Learning)

딥러닝은 신경망이 발전된 형태로 나타난 것이다. 여기에서는 신경망이 심리학자들에게 매우 익숙한 모형이므로 신경망을 통하여 딥러닝에 접근하고자 한다.

신경망 모형

신경망은 신경원(neuron)들 간의 정보처리과정을 모사하여 복잡한 계산을 가능하게 한 모

형이다. McCulloch & Pitts(1943)에 의해 처음으로 제안되었으나, 한동안 별로 관심을 받지 못하다, 1980년대 연결주의(connectionism)라는 이름으로 다시 주목을 받았다. 특히 Rumelhart와 McClelland라는 두 심리학자의 주도로 저술된 두 권의 기념비적 책(Rumelhart, McClelland, & the PDP Research Group, 1986; McClelland, Rumelhart, & the PDP Research Group; 1986)에서 연결주의의 원리와 구현에 대한 종합적인 이론과 기법을 제시한 후 심리학, 인공지능 분야에서 매우 방대한 연구가 진행되었다.

신경망은 인간의 인지 과정에 대한 정보처리론적 접근법과는 다른 가정에서 시작하였다. 정보처리론적 접근에서는 한 심성 상태가 다른 상태로 전환되는 과정을 심리 과정으로 보고, 심성 표상은 마디(node)가 연결되어 구성된 망(network)로 보았다. 이때 각 마디는 의미나 개념을 표상하고 있다. 반면 신경망 모형에서는 하나의 의미나 개념이 다수의 신경원에 분산되어 표상되어 있다고 가정한다. 또한, 신경원들은 서로 연결되어 있어서 각 신경원이 활성화되면 연결 마디(link)를 따라서 다른 신경원으로 활성화가 전달된다.

그림 5는 신경망의 대표적인 모형 중의 하나인 전방 전달 신경망(feedforward network)인데, 입력이 활성화의 형태로 입력층에 표상되

면 활성화 상태는 서로 다른 강도를 지닌 연결을 통해 다른 신경원으로 전달된다. 이 모형의 경우 입력층은 은닉층을 통하여 출력층에 전달된다. 은닉층은 입력과 출력을 담당하고 있지 않고 입력층과 정보를 받아 출력층으로 다시 전달하는 역할을 한다. 물론 은닉층에서 중재하는 과정에서 정보의 변화가 발생하게 된다. 입력층의 활성화 수준과 입력층과 은닉층의 연결 강도에 의하여 은닉층의 활성화 수준이 결정되고, 은닉층의 활성화 수준과 은닉층에서 출력층으로 가는 연결 강도에 의하여 출력층의 활성화 수준이 결정된다.

신경망에서 모든 정보는 연결 강도들에 저장되어 있는데, 이 연결 강도들은 미리 연구자에 의해 정해지는 것이 아니라 사례를 통하여 학습된다. 입력을 제시하고 출력을 산출한 다음, 출력이 목표 결과(target)와 다르면 출력과 목표 결과의 차이 즉 오차를 교정할 수 있게 연결 강도를 수정하는 것이다. 이러한 학습 방법을 역전파(back propagation; Rumelhart, Hinton, & Williams, 1986) 방식이라 한다. 즉 출력층에서 발생하는 오차에서부터 입력이 전달되는 방향과 반대 방향으로 가면서, 연결 강도를 수정하는 것이다. 이 신경망 모형은 다양한 영역에서 입력과 출력을 연결하는 데 매우 높은 성공률을 보여주었다.

학습방법에는 사례에 목표 결과를 포함시켜 학습하는 지도학습(supervised learning)과는 달리 목표결과를 포함시키지 않고 자극들간의 연합구조를 반영할 수 있도록 연결 강도를 수정하는 학습 방법인 비지도학습(unsupervised learning)도 있다. 비지도학습 방법을 사용하는 신경망은 완전하지 않은 자극에 대한 입력을 이용하여 완전한 자극을 회복해 낸다든지, 혹은 자극들에 대한 군집분석 등에 사용된다.




그림 5. 전방전달 신경망

신경망은 심리학의 다양한 분야에서 매우 활발하게 연구되었으나, 최근에는 연구가 그다지 활발하지 않다. 가장 큰 이유는 입력과 출력 사이의 과정에 대하여 심리학적 용어로 설명하기 쉽지 않았기 때문이다. 행동주의에서 비판되었던 암흑상자(black box)의 문제가 다시 등장한 것이다.

물론 기존의 이론 틀에서 설명하기 힘들었던 심리 현상을 신경망을 이용하여 설명하는 모형들도 존재한다. 가장 대표적인 예가 McClelland & Rumelhart(1981)의 상호활성화 모형(interactive activation model)을 이용한 단어우월효과(word superiority effect)에 대한 설명이다. 이 효과는 영어 철자가 단독으로 제시될 때보다 단어 속에서 제시될 때 더 빨리 지각할 수 있다는 것이다. 예컨대 자극에 D 혹은 K가 있는지 판단할 때, D와 K를 단독으로 제시할 때보다 WORD, WORK와 같이 단어로 제시할 때 판단 시간이 빠르다. 시각 자극에서 세부 특징을 추출하고 이를 결합하여 철자를 지각하며, 이 철자들을 조합하여 단어를 만든다고 가정하는 지각 모형에서는 이 현상을 설명하

기 힘들다.

상호활성화 모형에서는 세부특징에서 철자, 단어로 가는 모형을 그림 6과 같이 설정하였다. 이 모형에서는 세부특징, 철자, 단어로 가는 연결 뿐만 아니라, 단어에서 철자, 철자에서 세부특징으로 가는 연결도 가정하였다. 또한 동일한 층에서는 서로 억제적인 연결을 설정하였다. 이 모형에서는 일부의 철자만 활성화되어도 관련된 단어가 활성화되고 이는 다시 아래 층의 철자에 영향을 주는 방식으로 작동하므로 단어우월효과를 설명할 수 있게 된다. 이 모형에서는 단어 우월효과를 신경망의 구조로 설명한다.

초기의 이러한 창의적인 연구가 계속하여 등장하지 않아서 심리학에서는 신경망의 모형이 현재 활발하지는 않지만, 다양한 공학 분야와 인공지능의 분야에서는 꾸준히 발전되어 왔다.

딥러닝 모형

심리학에서 신경망에 관심을 기울이지 않는 사이에 인공지능의 분야에서는 신경망에서 지지벡터기계와 같은 새로운 기법으로 발전되어 갔다. 이들 기법은 정보처리과정에 대한 관심보다는 입력과 출력 사이의 관계를 예측하는데 목표를 두었기 때문에, 심리학의 관심에서는 멀어져 갔다. 2000년대에 Hinton에 의해서 신경망은 딥러닝(deep learning)이라는 이름으로 다시 등장하여 문제해결의 수행능력이 매우 높은 기계학습 기법으로 인정되고 있다(Hinton & Salakhutdinov, 2006; LeCun, Bengio, & Hinton, 2015).

딥러닝은 입력층과 출력층 사이에 은닉층이 다수로 존재하는 모형을 말한다. 기존의 신경

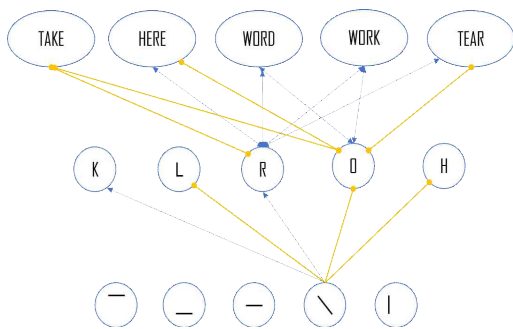


그림 6. 단어지각에 대한 상호활성화모형
(정적인 연결을 화살표로 부적인 연결을 원으로 끝나는 화살표로 표시하였다. 일부의 연결만을 표현하였고, 동일한 층에서 모든 마디는 부적으로 연결되어 있다.)

망에서는 은닉층을 다수 포함하는 경우에 학습이 효율적이기 않기 때문에 한두 개의 은닉층만 포함하는 것이 일반적이었다. 역전파 학습의 경우 출력층에서만 오류가 계산되는데, 이 오류를 이용하여 출력층과 연결된 은닉층과의 연결 강도를 수정한다. 그 오류는 다시 은닉층으로 전달되어 은닉층과 그다음 은닉층 혹은 입력층과의 연결 강도를 수정하게 된다. 그런데 이러한 오류의 전달은 출력층에서 멀어져 은닉층과 그다음 은닉층으로 전달됨에 따라 출력층에서 발생한 오류를 충분히 반영되지 않는 경향이 생긴다. 실제로 은닉층을 많이 포함하면 신경망의 수행은 도리어 떨어지기도 한다.

딥러닝의 초기모형으로 볼 수 있는 deep belief network에는 최종 출력층의 역전파 사용하지 않고 먼저 Restricted Boltzman Machine을 사용하여 인접한 두 층간의 연결을 비지도 학습방법으로 초기 학습한 다음, 그 후에 지도 학습방법인 역전파를 적용시키는 방법이다. (예, Hinton & Salakhutdinov, 2006). 이 모형은 다층의 은닉층이 학습을 어렵게 하는 문제를 해결하여 다층의 은닉층을 설정하는 것을 가능하게 하였다. 이 모형 이후에 많은 딥러닝 모형들이 제안되고 사용되어 딥러닝이 범위가 매우 넓어졌으며, 지지벡터기계와 같은 방식보다 높은 수행을 보여주면서 인공지능에서 광범위하게 사용되고 있다. 사실 deep belief network은 몇몇 분야에서 뛰어난 수행을 보여주었지만, 그 후에 우수한 수행을 내는 다양한 딥러닝 모형들이 등장함에 따라 현재는 그리 널리 사용되지는 않지만, 딥러닝을 가능하게 한 모형으로 평가받을 수 있다.

생물학적 혹은 심리학적 타당성의 관점에서도 입력층과 출력층 사이에 많은 층이 존재하

는 것이 더 자연스럽다. 입력된 정보에서 일차적인 세부특징이 추출되고, 그 세부특징들이 입력이 되어, 다시 이 세부특징들의 세부특징들이 추출되는 방식으로 정보가 처리되는 것이 시각이나 인지 과정에서 흔히 볼 수 있다.

1980년대의 신경망 연구와는 달리 딥러닝은 심리학에서 현재까지는 널리 적용되고 있는 것으로 보이지는 않는다. 여러 가지 이유가 있겠지만, 가장 큰 이유는 은닉층에서 특정한 패턴으로 표상되어 있을 세부특징들을 찾아내고 그것을 해석하는 것이 용이하지 않기 때문일 것이다. 시지각과 관련된 분야에서 일부 적용할 수 있으나, 다른 분야의 경우는 더 많은 기법이 발전되어야 할 것으로 보인다.

딥러닝의 구조 자체가 앞에서 예로든 상호활성화 모형처럼 심리학적으로 설명할 수 있는 모형으로 구성될 수 있으면, 심리학의 중요한 모형이 될 것이다. 이러한 경우에는 딥

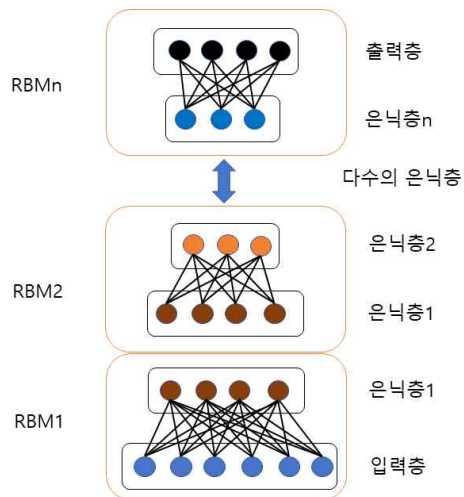


그림 7. 딥러닝 모형의 하나인 deep belief network.(각 층간의 연결강도를 Restricted Boltzman Machine (RBM)을 이용하여 학습함)

러닝의 구조 자체가 사람들이 사례를 통하여 학습하는 과정에 대한 심리학적 모형이 될 것이다.

심리학 연구에서 빅데이터 이용의 장애 요소들

심리학 연구자들이 빅데이터를 당장 이용하는 것은 두 가지 측면에서 쉬운 일이 아니다. 첫 번째가 빅데이터에 접근하기 쉽지 않다는 것이고, 두 번째가 접근하였을 때 그 자료를 분석할 수 있는 도구와 방법을 심리학자가 가지고 있지 않다는 것이다.

자료에 대한 접근성

빅데이터에 대한 접근성에 대해서는 연구자가 설계에 의하여 수집하는 자료인지 인터넷에서 자동적으로 수집되는 자료인지에 따라 다른 양상을 띤다. 전자의 경우는 필요한 비용이 확보되면 자료를 수집하는 것은 시간과 노력의 문제일 뿐이다. 따라서 얼마든지 접근 가능한 자료를 수집할 수 있다. 특히 최근에 Mechanical Turk과 같은 인터넷을 통하여 자료를 수집해 주는 편리한 서비스가 등장함에 따라서 자료수집이 훨씬 용이하게 되었다. 이 방법으로 얻어진 자료에 대한 타당성에 대하여 몇몇 연구자들이 우려를 표명하고 있으나, 이 방법이 몇 가지 점에 유의한다면 심리학 연구에서 타당성을 확보하여 사용할 수 있다는 연구도 있다(Landers & Behrend, 2015; Thomas, & Clifford, 2017).

접근성에 대한 문제는 인터넷에 저장된 자료를 이용할 때 특히 심각하다. 흔히 이러한

자료들로 페이스북, 트위터, 링크드인(LinkedIn), 넷플릭스, 카카오톡 등을 들 수 있는데, 이는 사설 기관에서 구축된 자료이기 때문에 자료에 접근이 제한되어 있다. 물론 이들의 자료를 API를 통해 공개하기도 하나 해석하게도 모든 자료 보유자가 이 서비스를 제공하고 있는 것은 아니다. 예컨대 국내의 기업들이 이러한 서비스를 제공하는 경우가 흔하지 않으며, 제공할 때도 매우 제한된 자료만 공개하는 경우가 대부분이다. 자료가 공공재로 인식되지 않으며, 빅데이터의 이용에 대한 사회적 법적인 장애가 여전히 존재하기 때문에 학자들의 빅데이터 이용이 점차 어려워지고 있다. 이러한 경향이 계속되면, 빅데이터의 분석은 자료를 독점하고 있는 사기업을 중심으로 이루어질 것이고 학문적인 주제에 대한 연구는 활발하게 이루어지기 힘들 것이다. 이미 빅데이터의 분석은 대학과 연구소보다는 구글과 아마존과 같은 자료를 보유하고 있는 사기업에 의하여 더 활발하게 진행되고 있다.

자료의 접근성에 대한 또 다른 문제는 연구윤리의 문제이다. 연구윤리의 측면에서 빅데이터 이용에서 문제가 될 수 있는 소지는 개인정보에 대한 보호이다. 특히 인터넷 상에서 수집되는 자료는 생명윤리위원회의 규정을 따르면 사용하는 데 한계가 있다. 기본적으로 개인에게 자료가 연구와 관련된 목적으로 사용할 수 있다는 동의를 받아야 되는데, 사실상 불가능한 일이다. 현재에는 이와 관련된 문제들이 명백한 기준이나 합의 없이 다루어지고 있으나, 문제의 소지는 있다. 새로운 자료에 대한 연구윤리의 문제도 마련되어야 할 것이다.

심리학자들의 인공지능기법에 대한 활용 능력

인공지능이나 기계학습에서 사용되는 기법들은 심리학자들이 대학이나 대학원에서 학습한 내용이 아니고 단시간 내에 학습할 수 있는 내용도 아닌 경우가 대부분이다. 이러한 이유로 심리학자들이 빅데이터에 접근할 수 있더라도 분석을 하는 데 어려움을 겪는 경우가 많다. 협동 연구를 통하여 분석을 자료과학자에게 맡길 수 있으나 이 협업에도 한계가 있다. 이 기법들의 많은 부분이 소위 모형을 포함하기 있어서, 분석과정에서 내려야 할 결정이 많다. 이러한 결정은 내용에 대한 전문자인 심리학자가 내려야 되는데, 분석기법에 대한 이해가 있지 않으면 자료과학적 판단을 내리는 것이 쉽지 않다. 사실 이러한 이유 때문에 많은 심리학자들이 빅데이터의 분석을 쉽게 시도하지 못하고 이러한 방법론을 습득한 일부 심리학자들만이 빅데이터의 분석을 하고 있다.

결 론

최근에 인터넷 기술과 인공지능 기법의 발달로 자연스럽게 등장한 빅데이터의 분석은 자료 주도적 분석 방법이 주를 이루고 있다. 이러한 이유로 현 상태로 심리학 연구에 적용하는 것은 한계가 있지만, 인간들의 다양한 활동과 특성을 반영하고 있는 자료라는 것을 부인할 수는 없다. 심리학 연구에서 이러한 빅데이터에서 인간에 대한 더 풍부한 자료를 얻는 방법을 찾아내는 것은 학자들에게 주어진 임무라고도 할 수 있다.

미래의 심리학 연구자와 연구방법

빅데이터를 심리학 연구에 적용할 수 있는 몇 가지 가능성을 제시하면 다음과 같다. 첫째, 빅데이터 분석법을 통하여 인간의 인지 과정과 행동을 탐색적으로 파악하고, 이에 근거하여 연구 모형을 설정하여 심리학적 모형 주도적 분석 방법으로 검증하는 것이다. 사실 탐색적 분석과 모형주도적 방법을 함께 사용하는 연구 방법은 심리학에서 흔히 행하는 방법 중의 하나이다. 그러나 대체로 탐색적 연구는 연구 과정에서 큰 비중을 차지하지 않고, 소규모의 연구로 진행되는 경우가 많으며, 완전히 탐색적 연구이기보다는 연구자의 모형에 관한 예비 연구의 특성을 지니는 경우가 대부분이다.

빅데이터의 분석은 순수한 탐색적 연구로서 연구자가 생각하지 못했던 인간의 행동 패턴을 발견하는 데 도움을 주기 때문에 연구자의 연구 영역을 확장할 수 있는 좋은 도구가 될 수 있다. 사고의 과정에 비유하자면, 현재의 연구는 소수의 가능성 중에서 하나를 선택하는 연구 과정의 수렴적 사고에 비중을 두었다면, 빅데이터 연구는 가능성의 수를 확장시키는 연구 과정의 확산적 사고에 더 비중을 두고 있다. 이러한 관점에서 보면, 빅데이터는 모형을 검증하는 것보다는 자료에 근거하여 다양한 모형을 만들어내는 데 더 큰 역할을 할 수 있을 것이다.

둘째, 빅데이터 분석의 가장 큰 장점이 예측이기 때문에 예측이 중요한 심리학의 영역에 적용시키는 것이다. 예컨대, 임상 심리 분야에서 진단이나 소비자 심리학에서 예측은 그 자체로 중요한 역할을 한다. 즉 주어진 입력(자료)과 결과 사이의 관계가 중요하다. 이

분야에 대한 빅데이터 활용의 범위는 매우 넓다. 이미 심리학 바깥의 분야인 의학 등에서 이러한 연구는 활발하다. 심리학 연구와 관련하여 주목할 필요가 있는 연구는 입력과 결과 사이의 연결(mapping)을 넘어서서 이 과정에 대한 가설을 생성하는 방법도 모색 중이라는 것이다. 빅데이터를 통하여 진단과 처방과 관련된 변수를 찾아내기도 하고, 전문 학술지에 대한 텍스트 분석을 하여 명제로 표현되는 가설을 찾아내기도 한다¹⁾ (예, Oquendo, Baca-Garcia, Artés-Rodríguez, Perez-Cruz, Galfalvy, Blasco-Fontecilla, Madigan, & Duan, 2012; Sang, Yang, Li, & Lin, 2015; Amato & Coronato, 2017). 여기에서 다루는 가설은 단순한 명제의 형태로 구성된 것이다. 예언, 진단의 측면에서는 충분한 것이지만, 현재의 방법으로는 심리학적 모형에 적용하는 데에는 한계가 있다. 그러나 이를 확장하여 심리학 연구에 적용시킬 수 있는 충분한 가능성이 있다. 심리학자가 이러한 가능성에 대하여 관심을 가질 필요가 있는 것으로 보인다.

셋째, 빅데이터는 또한 실험 자극이나 문항을 제작하는데에도 도움을 줄 수 있다. 심리학 실험에서 자극이나 문항은 특정한 구성개념(construct)과 유관한 자극 중에서 일부를 표집하는 것으로 볼 수 있다(예, 영역 표집 이론, Kaplan & Saccuzzo, 2018). 빅데이터 기법을 이용하여 성격 문항들을 추출한다든지 실험조건에 맞는 자연스러운 상태에서 관찰되는 시나리오를 추출할 수도 있을 것이다. Farnaldi 등(2016)은 소셜미디어에서 관찰되는 행동 특성을 수집하여 성격을 파악하려는 시도를 하

고 있다. 박성준, 박희영, 김청택(2019)은 토픽 모형화 기법을 이용하여 성격 문항을 추출하고 이를 이용하여 성격검사를 제작하는 방법을 제시하기도 하였다. 이러한 방법은 다양한 영역에서 사용될 수 있고 비교적 쉽게 자료를 수집할 수 있다는 장점이 있다.

빅데이터를 심리학 연구에 적용할 때 가장 큰 문제점은 심리학자들이 어떻게 이러한 자료를 분석할 것인지이다. 심리학자들이 빅데이터 분석법에 능통하게 되는 것이 바람직하나 이러한 가능성은 그리 높지 않을 것이다. 가장 쉬운 방법은 자료과학자나 인공지능 연구자에게 위탁하는 것이다. 연구자가 연구방법론을 타인에게 의지하는 것은 연구의 내용과 방법론은 밀접하게 연결되어 있기 때문에 해결책이 되기 힘들다. 신경망 연구와 같이 이전에 심리학자와 공학자가 협업을 시도하여 상당한 성공을 거둔 적이 있다. 그러나 현재와 미래의 상황은 과거와는 다른 측면이 있다. 과거에는 심리학에서 발견한 지식을 이용하여 기계에 적용시키려는 시도를 많이 하였다. 이러한 경우에는 공학자들에게 심리학 지식은 매우 필요한 것이었다. 예컨대 지각이나 인지 과정에서 복잡한 사고를 처리하기 위하여 어떠한 세부특징들을 이용하는지에 대한 심리학 정보를 인공지능에 이용하고자 하였다. 최근의 기계학습이나 딥러닝과 같은 인공지능 기법에서는 연구자가 정해주지 않고 인공지능 모형들이 학습을 통하여 스스로 세부특징을 찾아준다. 물론 이러한 세부특징들이 인간의 것들과 동일한지에 대해서는 장담할 수 없지만, 자료를 예측하는 데에는 좋은 모형이다. 따라서 굳이 심리학자들에게 도움을 찾을 이유가 없다. 빅데이터의 초기 단계에서 공학자들에 의해 연구가 주도되었으며, 이때 영역의

1) 가설 생성 (hypothesis generation)에 대하여 조언을 해 주신 익명의 논문심사자에게 감사드린다.

지식이 없이도 빅데이터의 분석만으로 충분하다고 주장하기까지 하였다. “자료가 스스로 말하게 하라”라는 표어가 그것이다. 이러한 맥락에서 보면 심리학자들이 연구에 필요한 기계 학습이나 인공지능 기법들을 학습해야만 할 것이다.

그다음 의문점은 심리학자들이 학습하는 것이 가능한가 가능하다면 그 기법들의 학습하기 위하여 시간과 노력을 얼마나 투자해야 해야 하는가이다. 심리학에서 빅데이터의 활용은 대학과 대학원 교육의 변화를 통하여 가능하다. 사실 이를 학습하는데 학생들이 많은 시간을 투자하지 않더라도 가능하다. 그동안 심리학에서는 통계학을 필수과목으로 하고 대학원생들이 통계처리에 필요한 프로그램들을 학습하여 자유롭게 사용할 수 있었다. 특히 SPSS와 같은 프로그램들은 메뉴 방식으로 되어 있어서 계산과정에 대한 이해 없이도 통계학에 대한 이해만 있으면 쉽게 사용할 수 있었다. 기계학습과 같은 기법들도 계산과정에 대한 자세한 이해 없이도 원리만 이해하면 R이나 Python 등의 소프트웨어를 사용하여 프로그램을 비교적 쉽게 할 수 있다. 물론 모델링을 포함하고 있기 때문에 메뉴 방식의 프로그램보다는 학습하는데 시간이 많이 걸릴 것이다. 그러나 대학원에서 통계 과목에서 R이나 Python를 교육한다면, 한 학기 정도의 교육만으로 대학원생들이 충분히 소화할 수 있는 양이 될 것이다.

요약하면, 빅데이터가 심리학의 연구를 발전시키고 새로운 사실들을 발견하는 데 중요한 역할을 할 것이며, 심리학자가 빅데이터를 활용하는 방법을 습득하여 이용하는 것이 가능하다는 것이다.

이러한 가능성에도 불구하고 빅데이터 분석

법과 심리학 연구방법론의 차이로 인해 서로 독립적인 연구 분야로 남아있을 가능성도 있다. 빅데이터의 분석법에서는 심리 현상에 대한 예측을 위주로 연구가 진행되고, 심리학에서는 엄격한 심리학 연구방법론을 사용하여 심리학의 연구 모형들을 계속하여 검증해 나갈 수 있다. 사람의 심리 현상에 대하여 서로 다른 연구 방법으로 서로 다른 측면에 대하여 연구하는 것도 가치가 있을 수 있다.

이제 막 시작한 인공지능 혹은 빅데이터의 시대가 어떤 모습으로 진행될지를 예측하기는 힘들다. 빅데이터의 분석법도 발달할 것이고 심리학도 변화할 것이다. 빅데이터 분석법이 현재까지는 심리학에 큰 영향을 미치지 않는 것으로 보이지만, 이러한 기술들이 심리학에 도움을 주지 않기 때문이기보다는 심리학자들이 충분히 이용하지 못하였기 때문일 가능성이 더 크다. 빅데이터 분석법이 기존의 분석법으로 탐지하지 못한 다양한 자료 패턴을 찾아내기 때문에 그 가치는 충분하다고 할 수 있다. 심리학에서는 빅데이터의 방법론을 성공하든 실패하든 시도는 해 보아야 할 것이다. 이러한 기술의 변화가 분명 인간을 변화시키고 있고 또한 사람들이 인터넷상에서 빅데이터를 남기고 있는 현실에서 인간을 연구하는 심리학자가 이를 무시하거나 피할 수는 없을 것이다.

참고문헌

- 김청택, 이태현 (2002). 뇌와 인지모형: 잠재의미분석을 사용한 문서분류. 한국심리학회지: 실험 및 인지, 14(4), 309-320.
- 박성준, 박희영, 김청택 (2019). 잠재의미분석

- 을 활용한 성격검사문항의 의미표상과 요
인구조의 비교. *인지과학*, 30(3), 133-156.
- 이태현, 김청택 (2004). LSA모형에서 다의어 의
미의 표상. *인지과학*, 15, 23-31.
- Adjerid, I., & Kelley, K. (2018). Big data in
psychology: A framework for research
advancement. *American Psychologist*, 73(7), 899-
917. <https://doi.org/10.1037/amp0000190>
- Amato A., & Coronato, A. (2017). Supporting
hypothesis generation by machine learning in
smart health. *Advances in Intelligent Systems
and Computing*, 612, 401-410. [https://doi.org/
10.1007/978-3-319-61542-4_38](https://doi.org/10.1007/978-3-319-61542-4_38)
- Anderson, J. (1990). *The Adaptive Character of*
Thought. Hillsdale, NJ: Erlbaum Associates.
- Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003).
Latent Dirichlet allocation, *Journal of Machine*
Learning Research, 3, 993-1022.
- Boser, B. E., Guyon, I., & Vapnik, V.N. (1992).
Training algorithm for optimal margin
classifiers. In *Proceedings of the Fifth Annual*
Workshop of Computational Learning Theory (pp
144-152), Pittsburgh: ACM. [https://doi.org/
10.1145/130385.130401](https://doi.org/10.1145/130385.130401)
- Cheung, M. W. L., & Jak, S. (2016). Analyzing
big data in psychology: A split/analyze/meta-
analyze approach. *Frontiers in Psychology*, 7,
<https://doi.org/10.3389/fpsyg.2016.00738>
- Farnadi, G., Sitaraman, G., Sushmita, S., Celli, F.,
Kosinski, M., Stillwell, D., Marvalos, S.
Moens, M-F., & De Cock, M. (2016).
Computational personality recognition in social
media. *User Modeling and User-Adapted*
Interaction, 26, 109-142. [https://doi.org/
10.1007/s11257-016-9171-0](https://doi.org/10.1007/s11257-016-9171-0)
- Griggs, B. (2014, January 27). *It's Facebook vs.*
Princeton in study smackdown. CNN. [https://
edition.cnn.com/2014/01/24/tech/social-media/fac
ebook-princeton-smackdown/index.html](https://edition.cnn.com/2014/01/24/tech/social-media/facebook-princeton-smackdown/index.html)
- Hinton, G. E., & Salakhutdinov, R. R. (2006).
Reducing the dimensionality of data with
neural networks. *Science*, 313, 504-507.
- Hofmann, T. (1999). Probabilistic latent semantic
analysis. In K. B. Laskey, & H. Prade
(Eds.), *Proceedings of the Fifteenth Conference on*
Uncertainty in Artificial Intelligence(pp. 289-296).
Stockholm Sweden: Morgan Kaufmann
Publishers Inc.
- Hofmann, T. (2001). Unsupervised learning by
probabilistic latent semantic analysis. *Machine*
Learning, 42, 177-196. [https://doi.org/
10.1023/A:1007617005950](https://doi.org/10.1023/A:1007617005950)
- HostingFacts (2019, November) *Internet Stats &*
Facts for 2019. Retrieved November 25, 2019
from [https://hostingfacts.com/
internet-facts-
stats](https://hostingfacts.com/internet-facts-stats)
- Kaplan, R. M., & Saccuzzo, D. P. (2018).
Psychological Testing: Principles, Applications, and
Issues. Boston, MA: Cengage Learning.
- Kosinski, M., Matz, S., Gosling, S., Popov, V., &
Stillwell, D. (2015). Facebook as a research
tool for the social sciences: Opportunities,
challenges, ethical considerations, and practical
guidelines, *American Psychologist*, 70(6), 543-
556. <https://doi.org/10.1037/a0039210>
- Kosinski, M., Wang, Y., Lakkaraju, H., &
Leskovec, J. (2016). Mining big data to
extract patterns and predict real-life outcomes.
Psychological Methods, 21(4), 493. [https://doi.
org/10.1037/met0000105](https://doi.org/10.1037/met0000105)

- Landauer, T. K., & Dumais, S. T. (1997). A solution to Plato's Problem: The latent semantic analysis theory of acquisition, induction, and representation of knowledge. *Psychological Review*, *104*(2), 211-240. <https://doi.org/10.1037/0033-295X.104.2.211>
- Landauer, T. K., Foltz, P. W., & Laham, D. (1998). Introduction to latent semantic analysis. *Discourse Processes*, *25*, 259-284. <https://doi.org/10.1080/01638539809545028>
- Landers, R., & Behrend, T. (2015). An inconvenient truth: arbitrary distinctions between organizational, Mechanical Turk, and other convenience samples. *Industrial and Organizational Psychology*, *8*(2), 142-164. <https://doi.org/10.1017/iop.2015.13>
- Laney, D. (2001). 3D Data management: controlling data volume, velocity and variety. *META Group Research Note*, *6*.
- Lazer, D., Kennedy, R., King, G., & Vespignani, A. (2014). The parable of google flu: Traps in big data analysis. *Science*, *343*(6176), 1203-1205. <https://doi.org/10.1126/science.1248506>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*, 436-444. <https://doi.org/10.1038/nature14539>
- Markowetz, A., Błaskiewicz, K., Montag, C., Switala, C., & Schlaepfer, T. E. (2014). Psycho-informatics: Big data shaping modern psychometrics. *Medical Hypotheses*, *82*(4), 405-411.
- McClelland, J. L., & Rumelhart, D. E. (1981). An interactive activation model of context effects in letter perception: I. An account of basic findings. *Psychological Review*, *88*(5), 375-407. <https://doi.org/10.1037/0033-295X.88.5.375>
- McClelland, J. L., Rumelhart, D. E., & the PDP Research Group (Eds.). (1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Vol. 2. Psychological and biological models*. Cambridge, MA: MIT Press.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, *5*(4), 115-133. <https://doi.org/10.1007/BF02478259>
- Moustafa, A. A., Diallo, T. M. O., Amoroso, N., Zaki, N., Hassan, M., & Alashwal, H. (2018). Applying big data methods to understanding human behavior and health. *Frontiers in Computational Neuroscience*, *12*, 1-4. <https://doi.org/10.3389/fncom.2018.00084>
- Oquendo, M. A., Baca-Garcia, E., Artés-Rodríguez, A., Perez-Cruz, F., Galfalvy, H. C., Blasco-Fontecilla, H., Madigan D., & Duan, N. (2012, October). Machine learning and data mining: Strategies for hypothesis generation. *Molecular Psychiatry*. <https://doi.org/10.1038/mp.2011.173>
- Popper, K. R. (1959). *The Logic of Scientific Discovery (translation of Logik der Forschung)*. London: Hutchinson.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, *323*(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Rumelhart, D. E., McClelland, J. L., & the PDP Research Group (Eds.). (1986). *Parallel*

- Distributed Processing: Explorations in the Microstructure of Cognition: Vol. 1.* Foundations. Cambridge, MA: MIT Press.
- Sang, S., Yang, Z., Li, Z., & Lin, H. (2015). Supervised learning based hypothesis generation from biomedical literature. *BioMed Research International*, 215, <https://doi.org/10.1155/2015/698527>.
- Shawe-Taylor, J. & Cristianini, N. (2004). *Kernel Methods for Pattern Analysis*. Cambridge: Cambridge University Press.
- Snijders, C., Matzat, U., & Reips, U.-D. (2012). 'Big Data': Big gaps of knowledge in the field of internet. *International Journal of Internet Science*, 7, 1-5.
- Steyvers, M. & Griffiths, T. (2006). Probabilistic topic models. In D. Landauer, D. McNamara, S. Dennis, & W. Kintsch (Eds.). *Latent Semantic Analysis: A Road to Meaning*. Mahwah: Erlbaum.
- Thomas, K. A., & Clifford, S. (2017). Validity and Mechanical Turk: An assessment of exclusion methods and interactive experiments. *Computers in Human Behavior*, 77, 184-197. <https://doi.org/10.1016/j.chb.2017.08.038>
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B*, 58, 267-288. <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>
- Young, J. L. (2018). The long history of big data in psychology. *The American Journal of Psychology*, 131(4), 477-482. <https://doi.org/10.5406/amerjpsyc.131.4>
- Youyou, W., Kosinski, M., & Stillwell, D. (2015). Computer-based personality judgments are more accurate than those made by humans. *Proceedings of the National Academy of Sciences of the United States of America*, 112(4), 1036-1040. <https://doi.org/10.1073/pnas.1418680112>

기 고 일 : 2019. 11. 04.

계재확정일 : 2019. 12. 24.

Special issue: Psychology and Fourth Industrial Revolution 1

Studying Psychology using Big Data

Cheongtag Kim

Department of Psychology, Interdisciplinary Program in Cognitive Science, Seoul National University

The development of new technology such as big data, machine learning, and Artificial Intelligence changes human behaviors and thought. Increased use of the internet makes it possible to observe various human activities that were not observable before. Huge amounts of data about various types of human activities are being stored on the internet. Analyzing this information will help extend the scope of understanding human behaviors and psychology. The present paper attempts to find a way of applying new technology to psychological studies. Specifically, we focused on what big data are like and how they can be used for psychological research. This paper first reviewed the characteristics of big data and their role in psychological research. In this context, it discussed the problems of data-driven analysis techniques in which big data analysis is applied and the possibility of applying such methods to psychological research. In this context, it discussed the problems of the data-driven analytic scheme that big data analysis adapting and the possibilities of applying such a method to psychological research. Second, data analytic techniques used in big data analyses are reviewed. These techniques should be able to deal with big and unorganized data and unstructured data such as pictures, video clips, texts, etc. Specifically, it reviewed basic principles of topic modeling, ridge or lasso regression, support vector machine, neural network, and deep learning, and their application to psychological data. Third, the limitations of the use of big data in psychological research are discussed. Finally, it proposed ways of applying big data technology to psychological research.

Key words : *Big Data, Artificial Intelligence, Machine Learning, Topic Modeling, Deep Learning, Data-driven Analysis, Model-driven analysis*