머신러닝과 양자 알고리즘

DOI: 10.3938/PhiT.26.048

방 정 호

Machine Learning and Quantum Algorithm

Jeongho BANG

Quantum machine learning (QML), a hybridization of two fields of science, *i.e.*, quantum theory and machine learning, has recently attracted sharp interest. One of the current important issues of QML is to answer the question: can we achieve a speed-up in quantum learning? Several theoretical studies have already been done on the general measures of learning performance, say the sample's complexity, to find answers to that question. However, on the forefront of recent QML research, rapid developments have been made by taking on specific learning tasks, for example, data classification. In particular, the latest developments of QML are being boosted by the advent of the quantum support vector machine (QSVM). We here describe the history of QML, and then briefly offer future prospects for QML research.

양자머신러닝

머신러닝(Machine Learning)은 인공지능(AI)의 부속분야로 “데이터의 분류/가공” 등에서부터 “고차원적 지식체계의 구축” 까지 많은 응용이 가능하다. 특히, 최근 알파고의 등장으로 “딥러닝”, “강화학습” 등과 같은 전문 용어들이 이미 대중화되었고, 머신러닝은 과학기술 영역 전반에 큰 파장을 불러일으키고 있다. 이에, 머신러닝과 양자물리학이론을 융합하고자 하는, 이른바 “양자머신러닝(Quantum Machine Learning)” 연구가 최근 매우 활발히 진행되고 있다. 특히, 양자머신러닝은 양자 정보/컴퓨팅 이론 및 구현 전반에 새로운 키워드를 제공하는

등 최근 뜨거운 감자로 급부상하고 있다.

양자머신러닝에의 큰 맥락에서의 중요한 연구주제는, 머신러닝의 기반이론을 양자물리학 영역으로 확대함으로써 기존의 고전학습대비^{a)} 의미있는 속도 향상(즉, 양자 속도 향상)을 얻을 수 있을지, 또 그것이 가능하다면 어떤 물리기작으로 이를 설명할 수 있는지 등이다. 이같은 논의가 일반적인 학습성능 평가 지표 맥락에서 이미 십수년 전 시도된 바가 있기는 하지만, 해당 연구의 필요성과 효용성 등은 아주 최근에서야 깊이 논의되고 있다. 특히, 최근 MIT의 Seth Lloyd 교수팀에 의해 “양자성을 이용한 기계학습에의 속도 향상”이 구체적으로 증명되면서 양자머신러닝 연구는 새로운 전기를 맞게 되었다.^[1] 그럼에도 불구하고, 양자머신러닝 연구는 아직 걸음마 단계로서 견고하게 정립된 용어/개념조차 찾아보기 힘든 실정이다. 또한, Seth Lloyd 교수 및 관련 후속 연구들에서의 증명은 선형 시스템을 다루는 양자컴퓨팅 알고리즘의 속도 향상에 기반하고 있으며, 현 시점에서 속도 향상을 가능케 하는 양자성(양자중첩 혹은 양자얽힘 등)의 물리적 기작 및 효율적 활용 방법 등에 대해서는 깊이 연구된 바가 없다. 게다가, 이같은 양자머신러닝에의 속도 향상은 범용 양자컴퓨터 및 단기양자메모리 등의 선행 개발을 전제로 하기 때문에, 양자머신러닝의 실제 구현은 매우 요원해 보인다.

양자 샘플복잡도

양자 속도 향상에 대한 직관이 막 형성되던, 양자컴퓨팅/알고리즘 연구 초창기에 머신러닝에의 양자성능향상에 대한 가능성이 이미 조사된 바가 있다. 당시 Deutsch-Jozsa 알고

REFERENCES

- [1] P. Rebentrost, M. Mohseni and S. Lloyd, Phys. Rev. Lett. **113**, 130503 (2014).

저자약력

방정호 박사는 한양대 양자정보 연구실에서 양자머신러닝을 주제로 학위를 받았고 현재 고등과학원의 연구원으로 재직 중이다.(jbang@kias.re.kr)

a) 이후부터 “고전(classical)”이라는 단어는 “양자(quantum)”라는 단어와 대비시키기 위해, 즉 양자물리학의 등장 이전의 원리/이론 등의 구분을 위한 목적으로만 사용한다.

리즘, Shor의 소인수 분해 알고리즘 등 기념비적인 양자 알고리즘들의 등장과 함께, 양자 중첩에 의한 계산에의 병렬성이 양자정보/컴퓨팅에의 가장 중요한 물리기작임이 밝혀졌다. 예를 들어, 평가대상인 입력값들을 중첩형태의 양자 상태로 준비한다. 다음으로, 준비된 중첩 상태를 “단 한번”의 연산 동작을 통해 각 입력에 대한 출력값들의 중첩 양자상태로 변환시킬 수 있다. 이를 “양자 병렬성(Quantum Parallelism)”이라고 한다.

$$\sum_x |x, \alpha\rangle \rightarrow \sum_x |x, \alpha \oplus f(x)\rangle$$

이같은 양자 병렬성을 적극 활용하여 계산과학 전반에의 새로운 활력을 불어넣는 동시에 정보 및 컴퓨팅 이론의 기반이론을 양자이론으로 확장하고자 하는 전반적인 노력이 당시 가장 활발했었다. 머신러닝에의 속도 향상에 대한 일반적인 증명 역시 이때 시도되었다. 특히, “계산 복잡도(computational complexity)” 측면에서 정의된 학습에의 성능지표를 바탕으로 일반적인 형태의 양자학습속도 향상을 증명하고자 하는 연구는 지금까지도 계속 시도되고 있다.^[2]

계산과학에서의 “복잡도(complexity)”란 흔히 어떤 알고리즘을 실행에 옮길 때 드는 총 비용을 뜻하는데, 대체로 컴퓨터가 해당 작업을 성공적으로 마치는데 드는 시간 혹은 메모리를 말한다. 머신러닝에서는 원하는 작업을 마칠 때까지 수행하는 의미있는 정보 추출 과정으로서의 “질의(query)” 연산의 총 횟수 혹은 필요한 샘플 데이터의 사이즈 등으로 정의된 학습 성능지표로서의 복잡도가 존재한다. 기본적으로 머신러닝은 주어진 훈련 데이터 샘플들($x \in \mathbf{X}$)을 원하는 목적 출력($y \in \mathbf{Y}$)과 대응시키는 어떤 목적함수($c \in \mathbf{C}$)에 대한 가설($h \in \mathbf{H}$)들을 식별하는 일련의 모든 과정이라고 정의할 수 있다. 이때, 학습의 정확도는 머신러닝 이후 최종 식별된 가설들이 얼마나 목적함수와 비슷한지 그 정도로 정의된다. 이같은 머신러닝의 일반적 정의를 염두에 두고, 어떤 학습모델의 우수성을 평가하기 위해서는 다음과 같은 만족요소들이 필요하다. 우선, 비교적으로 학습하는데 필요한 데이터 사이즈가 작을수록 좋은 학습이라고 할 수 있다. 그리고 학습한 이후 식별된 가설들의 정확도가 높을수록, 또 학습이 원리적으로 불가한 상황들이 없을수록 좋다. 이같은 요소들을 반영하여 일반적인 학습에의 평가지표를 정의하고 다양한 학습 모델에 적용하는 분야를 계산학습이론(Computational Learning Theory)이라고 한다.

예를 들어, 어떤 학습주제(내지는 학습 알고리즘) A 는 최종적으로 식별하고자 하는 목적함수와 관련된 주요 정보를 추출하기 위해 질의연산을 호출할 수 있다고 가정하자. 이 질의연

산은 알고리즘 내에서 실제 문제 정보에 접근할 수 있는 유일한 연산으로서, 흔히 “오라클(oracle)”이라고 부른다. 여기서, 어떤 주어진 학습 알고리즘 A 가 오라클을 최대한 활용하여, 최소 $1 - \delta$ 의 확률로 최종 가설 h 를 식별했을 때, 그리고 동시에 이때 식별된 가설 H 의 정확도가 $1 - \epsilon$ 이상일 때, 해당 학습 알고리즘과 목적함수의 가능공간 등을 바탕으로 “Probably-Approximately-Correct(PAC)” 학습 모델이 정의된다. 그리고 동시에, 최종 학습까지의 오라클 질의회수 관점에서 학습에의 난이도가 결정된다. 이같은 방식으로 정의된 학습에의 성능지표를 “샘플 복잡도(sample complexity)”라고 한다.

앞서 설명한 계산학습이론 내에서의 학습성능지표는 비교적 수리논리적 측면에서 정의/계산되기 때문에 그 결과가 실제 구체적 문제에 응용되는 사례는 찾아보기 힘들다. 하지만, 이론적으로 조사 대상의 학습모델이 실제 효과적으로 구현 가능한지 혹은 어떤 형태의 장점을 발휘하는지에 대해 많은 것을 시사한다. 이같은 이유로, 양자머신러닝, 특히 학습에의 양자성능향상 가능성 등의 일반적 증명을 목적으로, 양자물리학 관점에서의 학습모델을 정의하고자 하였다. 특히, 가장 기본적인 아이디어는 앞서 언급했던 양자 병렬성을 학습 과정에서의 오라클에 적용하는 것이었다. 즉, 아래 식과 같이 질의 대상의 훈련데이터들을 중첩시켜 “한번 질의”를 통하여 반환되는 목적함수값의 중첩을 만드는 양자 오라클을 활용하는 방식으로 “양자 PAC 학습모델” 프레임워크를 제작하였다.

$$\sum_x |x, \alpha\rangle \rightarrow \sum_x |x, \alpha \oplus c(x)\rangle$$

양자컴퓨팅/알고리즘 연구 분야에서 지수함수적 속도 향상의 가능성이 같은 방식으로 확인되었던 만큼, 또 해당 결과에의 물리적 기작을 있는 그대로 차용하였던 만큼, 머신러닝 영역에서 역시 긍정적인 결과가 기대되었으나, 양자 샘플 복잡도(quantum sample complexity)를 실제 계산한 결과 동일 성능 혹은 계산과학적으로 큰 의미가 없는 아주 약간의 속도 향상 정도만 확인되었다. 하지만, 특수한 목적에의 학습을 가정할 경우, 혹은 어떤 특정한 가정 하에서는 다항함수적 속도 향상을 기대할 수 있다는 결과 또한 최근 발표되었다.^[2] 이같은 결과들은 안타깝게도 양자머신러닝에 연구에 새로운 모멘텀을 부여할 만큼 어필하지 못했던 것이 사실이고, 이후 양자물리학과 머신러닝을 융합하고자 하는 시도는 얼마간 다른 맥락으로 진행되었다.

REFERENCES

- [2] I. Kerenidis and A. Prakash, arXiv:1603.08675 (2016).

양자정보처리에서의 머신러닝기술 활용

계산학습이론 맥락에서의 양자 속도 향상의 일반적 증명이 절반의 성공 혹은 절반의 실패로 여겨지는 것처럼 보이는 동안, “머신러닝 + 기반이론으로서의 양자이론”과 같은 확장/융합 시도와는 별개로 새로운 방향의 연구가 진행되었다. 특히, 알파고의 등장으로 머신러닝에 대한 학문적/대중적 관심이 폭발적으로 증가하게 됨에 따라, 머신러닝과 양자물리학의 융합 연구 역시 새로운 맥락으로 발전하였다. 머신러닝의 기반이론 자체를 양자물리학으로 광범위하게 확대하려는 일반적인 방식에서, 반대로 머신러닝의 방법론을 적극 활용하여 양자정보/컴퓨팅에의 기술적 문제점을 해결하고 또 그 안에서 새로운 형태의 물리기작을 발견하는 연구 형태로 진화되었다.

예를 들어, 캐나다 켈거리 대학의 Barry C. Sanders 교수팀은 양자 측정에서의 정확도 증가를 위해 머신러닝의 방법론을 차용하였다. 양자물리학에 기반한 측정이론에 따르면 고전이론에 의한 측정 정확도 혹은 민감도의 한계를 극복할 수 있다. Barry C. Sanders 교수는 이같은 지식을 바탕으로 순차적응(adaptive) 방법론으로서의 머신러닝 양자측정 기법을 개발하였다. 해당 방법은 광학 간섭계 내의 (unknown) 위상변수의 측정에 적용되었다. 특히, Barry C. Sanders 교수팀은 입자군집 최적화(Particle Swarm Optimization) 방법론을 사용하였는데, 시뮬레이션 결과 기존에 가장 우수한 정확도를 보장하는 Berry-Wiseman-Breslin(BWB) 순차적응 방법론보다 훨씬 더 좋은 결과를 보여주었다.^[3] 해당 결과는 양자측정 내 머신러닝의 물리적 기작을 밝히고자 하는 이론 연구로 발전되었고 지금까지도 활발히 수행되고 있다.

한양대 이진형 교수 연구팀에서는 머신러닝 기법을 활용, 양자 알고리즘의 핵심 연산을 스스로 학습하는 양자학습 시뮬레이터를 개발하였다.^[4] 해당 연구에서 어떤 사전지식 없이 원하는 입출력 관계에 해당하는 오라클을 활용하여 Deutsch-Jozsa 알고리즘에 해당하는 연산집합들을 학습하는데 성공하였다. 또 다른 중요한 결과로서, 학습에의 비약적인 속도 향상이 관찰되었는데 이는 찾고자 하는 알고리즘의 양자 속도 향상에 직접 대응된다. 해당 결과는 알고리즘 개발이라는 실용적 측면에서의 머신러닝의 유용성, 그리고 학습 대상으로서의 양자시스템이 갖는 양자성이 학습 과정에서 충분히 활용될 수 있다는 사실을 증명한 중요한 연구로 평가받고 있다.

비교적 최근에는 D-WAVE 머신 기반의 양자어닐링(Quantum Annealing)을 활용하여 머신러닝에서의 최적화 문제를 해결

하고자 하는 시도들이 크게 관심을 받고 있다.^[5] 특히 연산 반복(iterative)을 통해 해결 가능한 최적화 문제들에 이같은 아이디어가 모두 적용 가능하다. 최근 D-WAVE의 머신러닝 최적화 방법론이 일반화되고 또 지수함수적 속도 향상 가능성에 대한 증명이 등장하였다. 이후, 기저상태 추정, 스핀글라스 등 다양한 복잡계 문제에 적용되고 있으며, 의미있는 연구 결과들이 속속 등장하고 있다.

양자 서포트벡터머신

양자머신러닝 연구는 최근 등장한 양자 버전의 서포트 벡터 머신(Support Vector Machine, SVM)에 의해 새로운 전기를 맞게 된다. SVM이란 주어진 (빅)데이터들의 분류 알고리즘 내지는 메커니즘으로서 정의된다. 이 SVM은 매우 중요한 머신러닝 방법론들 중 하나로, 학술적 맥락에서 뿐만 아니라 데이터의 분류/가공 등의 실용적 목적으로도 활용되는 매우 중요한 방법론이다. 미국 MIT의 Seth Lloyd 교수팀은 SVM의 주요 연산 커널을 양자작업으로 확장하여, 이를 기반으로 한 양자-SVM을 정의하였고, 해당 연구에서 지수함수적 양자 속도 향상이 가능함을 이론적으로 증명하였다.^[1]

이같은 양자-SVM의 속도 향상을 이해하기 위한 핵심 키워드는 “양자 병렬성” 그리고 “양자 알고리즘”으로, 우선 먼저 선형 시스템과 관련된 문제 해결을 위한 양자 알고리즘들에 대해 이해할 필요가 있다.

1. Harrow-Hassidim-Lloyd (HHL) 알고리즘: 대부분의 선형 시스템의 문제들은 수학적으로 다음과 같은 선형 방정식의 풀이로 형식화할 수 있다. $Ax=b$ ($A \in \mathbb{R}^{N \times N}$, $x, b \in \mathbb{R}^N$). 여기서 A 는 풀고자 하는 시스템과 관련된 $N \times N$ 행렬로서, 목적은 벡터 x 를 구하는 것이다. 이와 같은 선형 방정식의 풀이는 결국 A 의 역행렬을 구하는 문제로 귀결된다. 이때, 잘 알려진 고전 알고리즘(예를 들어, QR factorization)을 사용하면 주어진 시스템의 차원 N 에 대하여 $O(N^3)$ 정도의 복잡도^{b)}에 해당하는 계산 노력 정도로 문제를 해결할 수 있다. 대상 선형 시스템에 특별히 유리한 조건을 부여하지 않을 경우 이보다 효율적으로 문제를 풀 수 있는 고전 알고리즘은 아직 알려지지 않았다. 하지만, 양자물리학에 기반하여 문제를 재구

REFERENCES

- [3] A. Hentschel and B. C. Sanders, Phys. Rev. Lett. **104**, 063603 (2009).
- [4] J. Bang, J. Ryu, S. Yoo, M. Pawłowski and J. Lee, New J. Phys. **16**, 073017 (2014).
- [5] M. Benedetti, J. Realpe-Gomez, R. Biswas and A. Perdomo-Ortiz, Phys. Rev. X **7**, 041052 (2017).

b) 여기서 “O(·)”은 점근표기법의 하나로 Big-O 혹은 란다우 표기법이라고 한다. 계산이론에서 시간복잡도를 나타낼 때 흔히 사용한다.

- A method to find an optimal hyper-plane to classify the given data

Decision Rule:

$$\mathbf{w} \cdot \mathbf{x}_+ + b \geq +1 \quad (y = +1 \text{ for } \mathbf{x}_+)$$

$$\mathbf{w} \cdot \mathbf{x}_- + b \leq -1 \quad (y = -1 \text{ for } \mathbf{x}_-)$$

$$\Rightarrow y_k (\mathbf{w} \cdot \mathbf{x}_k + b) - 1 \geq 0$$

Margin: $\frac{2}{|\mathbf{w}|}$

Constraint

Target function

Optimization Problem:

$$\max(|\mathbf{w}|^{-1}) \text{ or } \min(|\mathbf{w}|)$$

$$\text{For the constraints : } y_k (\mathbf{w} \cdot \mathbf{x}_k + b) - 1 = 0$$

$$\Rightarrow \mathcal{L} = \frac{1}{2} |\mathbf{w}|^2 - \sum_k \lambda_k y_k (\mathbf{w} \cdot \mathbf{x}_k + b) - 1 \quad \text{Solving Eq. } \partial \mathcal{L} = 0$$

Fig. 1. An schematic picture of support vector machine (SVM). The maximum margin hyper-plane and margins for SVM are given. The sampled classification data are represented as the points on the 2-dimensional space. The most outside samples on the margin are called support vectors.

성할 경우, 단지 $O(\log(N))$ 정도의 계산 노력으로 해결할 수 있다는 사실이 증명되었다; 즉, 지수함수적 속도 향상이 가능하다. 이같은 양자 알고리즘을, 최초 연구자들의 이름(Harrow, Hassidim, Lloyd)을 차용하여, HHL 알고리즘이라고 부른다. HHL 알고리즘의 핵심은 앞서 설명한 양자 병렬성의 적극 활용에 있다.^[6]

2. Singular Value Estimation(SVE) 알고리즘: 선형 시스템과 관련된 또 다른 문제들 중 하나로 Singular-value 추정이 있다. 즉, 어떤 임의의 $M \times N$ 행렬 A 가 있고, 이 행렬의 랭크가 r 이라고 할 때, 해당 행렬 A 를 다음과 같이 분해할 수 있다: $A = U \Sigma V^\dagger$. 여기서 U 그리고 V 는 각각 $M \times M$ 그리고 $N \times N$ 행렬이다. 그리고 Σ 는 A 의 대각화된 행렬이다. 이때, 행렬 Σ 의 대각화 (양수)원소들을 singular value라고 한다. 이때 문제는 행렬 A 의 singular value들을 추정하는 것이다. 현재까지 알려진 가장 뛰어난 고전 알고리즘에 의한 풀이는 $O(\min\{MN^2, NM^2\})$ 정도의 복잡도를 제공한다. 하지만, 양자 알고리즘의 경우 $O(\log(MN))$ 정도의 계산 노력으로 문제를 해결할 수 있다; 즉, 역시 지수함수적 속도 향상이 가능하다. 해당 양자 알고리즘의 속도 향상 역시 양자 병렬성의 활용에 기인한다.^[7]

선형 시스템에서의 양자컴퓨팅/알고리즘의 위와 같은 큰 성공을 염두에 두고, 다시 SVM 논의로 돌아가 보자. 앞서 언급

했듯이, SVM은 주어진 많은 양의 데이터들을 분류하는 방법론으로서 임의의 차원의 공간에 분포하고 있는 포인트들로서의 분류 데이터들을 “최적으로” 분류하는 초평면(hyperplane)을 구하는 메커니즘으로 이해할 수 있다. 이 과정에서 문제는 분류 범주의 최외각 데이터에 접하는 초평면들과 그들 사이의 거리 (margin)를 극대화하는 초평면을 찾는 것이다(그림 1 참조). 해당 문제는 결국 분류 범주의 결정률에 대응하는 제약식과 라그랑지안 승수를 곱한 항의 최적화 문제(라그랑지안 최적화 문제)로 환원된다. 이 문제를 풀기 위해서 필요한 가장 큰 계산량이 바로, 데이터의 개수 N 에 대한 선형 방정식, 즉 $N \times N$ 행렬의 역행렬을 구하는데 집중되어 있다. 따라서 매우 많은 양의 (빅)데이터 샘플에 대해 해당 작업을 수행하기 위해서는 엄청나게 큰 계산노력이 필요하다.

Seth Lloyd 교수 연구팀은 바로 이 부분에 HHL 알고리즘을 적용하였다. 즉 첫째로, 분류에 필요한 데이터 샘플을 모두 양자 상태로 “변환”하고 이들의 “중첩” 상태를 최종 준비한다. 다음으로, 풀고자 하는 행렬 A 와 관련된 유니타리를 구성한 후 “단일동작”으로서의 양자상태 변환식을 정의한다. 여기에, HHL 알고리즘을 적용함으로써 양자 병렬성을 극대화한 양자 속도 향상을 얻는다. Seth Lloyd 교수 연구팀은 이같은 아이디어에 기초하여 “양자-SVM”을 정의하였다.

이런 아이디어는 HHL 알고리즘 혹은 양자-SVE 알고리즘을 커널로 사용할 수 있는 대부분의 머신러닝 작업에의 속도 향상 증명에 적용될 수 있는 기본적인 방법론으로 일반화되었다(그림 2 참조). 이같은 연구들은 양자머신러닝 연구에 하나의 가치 비전을 제시하였다는데 매우 큰 평가를 받고 있다. 특히, 양자머신러닝의 지수함수적 속도 향상의 구체적인 증명과 동시에, 범용 양자컴퓨터 및 새로운 양자 알고리즘 개발의 매우 중요한 동기를 새로 부여했다는 점에서 양자정보 연구 전반에 활력을 불어넣고 있다.

REFERENCES

- [6] A. W. Harrow, A. Hassidim and S. Lloyd, Phys. Rev. Lett. **103**, 150502 (2009).
- [7] S. Lloyd, M. Mohseni and P. Rebentrost, Nature Physics **10**, 631 (2014).

Problem	Scaling	QML applications
Algorithm for Linear System	Classical: $O(s\kappa N \log(1/\epsilon))$	Quantum SVM
	Quantum: $O(s^2\kappa^2 \log(N)/\epsilon)$	Quantum Regression
		Kernel Least Squares
SVE	Classical: $O(k^2 N \log(1/\delta)/\epsilon)$	Recommendation System
	Quantum: $O(\log(N)/\epsilon^3)$	Quantum Linear Regression
		Principal Component Analysis

Fig. 2. Quantum machine learning (QML) applications using the two different quantum algorithm kernel: Quantum linear system algorithm (often called "HHL") and quantum singular value estimation (QSVE) algorithm.

양자머신러닝의 연구전망 및 맺는말

양자정보/컴퓨팅 분야의 연구 초기, 다소 격양되었던 분위기 속에서 시작되었던 양자머신러닝 연구가 광범위하고 일반적인 형태에서 조금 더 국소적이고 목적 중심의 연구로 진화되고, 특히 그 안에서 의미있는 결과를 창출하고 있다는 사실은 주목할 만하다. 이같은 연구 양상은 범용 양자컴퓨터 개발이라는 거시적이고 다소 추상적인 연구 목표의 한계를 이해하고, 특정 목적에 적용 가능한 양자 시뮬레이터 혹은 주요 양자 모듈 등의 개발이라는 조금 더 정밀하고 특화된 형태의 현실적 접근을 택한 최근 양자정보 연구 트렌드의 변화와도 깊이 연관되어 있다. 이에, 당분간의 양자머신러닝 연구는 현실적으로 접근 가능한 구체적이고 분명한 형태의 머신러닝 예제들 속에서 긍정적인 양자성능변화의 가능성에 대한 이론증명 및 검증실험 등의 형태로 진행될 것으로 보인다. 따라서 무리하게 확장된 개념, 이를테면 "양자 인공지능" 혹은 "양자 심층 인공 신경망" 등과 같은 다소 추상적인 키워드의 개발보다는 구체적인 양자 학습속도 향상 및 그 기작을 증명하는 형태의 연구가 당분간

은 보다 주목받을 것으로 예상된다.

그럼에도 불구하고, 짧은 미래에 활용 가능한 형태의 양자머신러닝 프레임워크를 개발하는 것은 매우 중요하다. 이런 측면에서, 최근 양자머신러닝 연구를 견인하고 있는 양자-SVM 관련 연구들은 구현 및 현실화 측면에서 심각한 문제들을 포함하고 있다. 예를 들어, 양자-SVM의 성공적인 학습 수행을 위해서는 모든 (빅)데이터 샘플들이 양자화되어야 하고 심지어는 이 양자상태들이 중첩형태로 준비되어야 한다. 보다 심각한 상황은 이같이 거대한 (빅)사이즈의 양자 중첩 상태의 준비 과정에 필요한 계산 노력은 양자-SVM의 속도 향상에 전혀 고려되지 않았다는 점이다. 이는 고전 정보가 양자 정보로 매우 쉽게, 즉 시간 및 메모리의 계산 소모 없이, 부호

화될 수 있다는 것을 의미한다. 이와 같은 역할을 하는 (가상의) 양자장치를 "양자-RAM"이라고 한다. 하지만, 현재까지 양자-RAM의 현실적 구현 방법은 제시되어 있지 않다. 이런 측면에서 양자-SVM의 학습속도의 속도 향상, 더 나아가서 HHL 내지는 양자-SVE 알고리즘을 커널로 하는 모든 양자머신러닝 작업 예제들의 속도 향상이 현실적으로 실현 가능한 것인지에 대한 회의적인 시각도 존재한다. 하지만 해당 분야의 전문가들 역시 이 문제에 대해 집중적으로 논의하고 있고, 여전히 양자머신러닝은 새로운 형태의 발전 가능성을 모색하고 있다.¹⁾

심층신경망 연구의 새 역사를 열었던 Geoffrey E. Hinton 교수는 최근 인터뷰 첫마디에서 "여기까지 오는데 매우 긴 시간이 걸렸다"라며 본인의 인공신경망 연구를 회고했다. 양자머신러닝도 다르지 않을 것이다. 그만큼의 "긴 시간" 동안 진중하고 꾸준한 연구를 통해 양자 머신러닝에 대한 이해의 선명도를 우선 제고해야 한다. 그렇게 흡수되어온 경지의 지식들이 종국에는 양자 머신러닝의 새 역사를 열게 될 것을 믿는다.

REFERENCES

- [8] S. Yoo, J. Bang, C. Lee and J. Lee, New J. Phys. **16**, 103014 (2014); J. S. Lee, J. Bang, S. Hong, C. Lee, K. H. Seol, J. Lee and K.-G. Lee, arXiv:1706.01561 (2017).

c) 이를테면, 고전 데이터의 양자화 없이도 양자 머신러닝의 속도 향상이 가능하다는 결과도 최근 발표되었다.^[8]