

統合機械学習分子動力学システムの構築

課題代表者: 奥村雅彦*(日本原子力研究開発機構)

副代表: 永井佑紀(日本原子力研究開発機構)、華井雅俊(東京大学)

共同研究者: 鈴村豊太郎、渡邊聰、沖田泰良、清水康司、芝隼人(東京大学)、横井達矢(名古屋大学)、加藤幸一郎(九州大学)、小林亮(名古屋工業大学)、島村孝平(熊本大学)、富谷昭夫(大阪国際工科専門職大学)、森英喜(産業技術短期大学)、安藤康伸(産業総合研究所)、河野秀俊、石田恒(量子科学技術研究開発機構)、今村穰、浦田新吾、吉田拓未(AGC株式会社)、小林恵太、山口瑛子、中村博樹、板倉充洋、町田昌彦(日本原子力研究開発機構)

* okumura.masahiko@jaea.go.jp

分子動力学法

- 原子や分子の動きをシミュレートする手法

- 本来は量子力学の基礎方程式(シュレーディンガーアルゴリズム)を解く必要があるが、解くための計算コストが膨大なため近似を導入

よく用いられる手法

- 古典分子動力学法

原子	古典物理学の質点に近似
原子間相互作用*	簡単な関数(力場)で近似*

* 物理法則(第一原理)では決められない「経験的パラメーター」を含む

- 第一原理分子動力学法

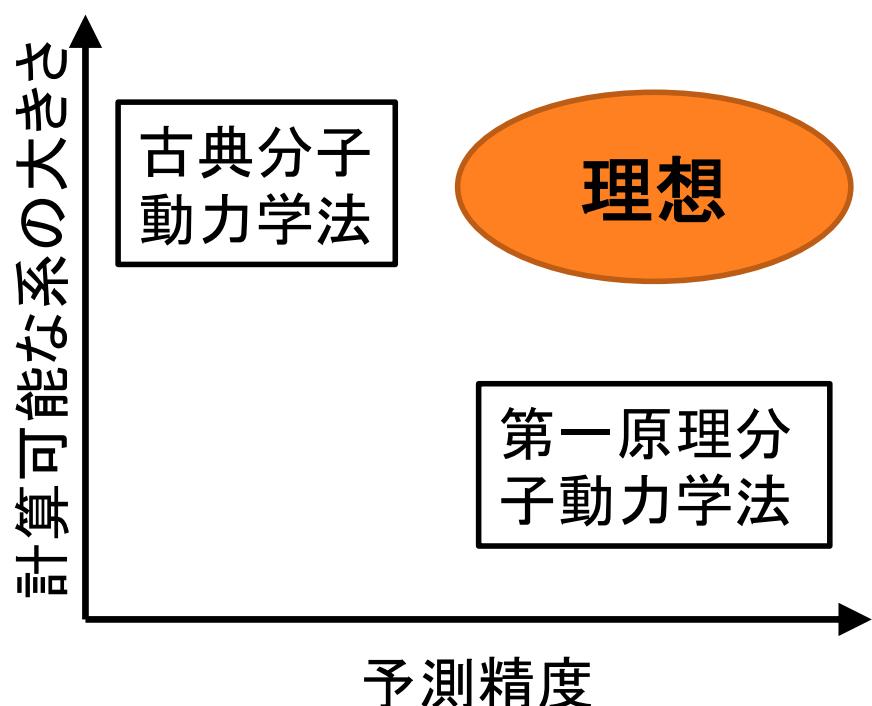
原子	原子核	古典物理学の質点に近似
	電子	量子力学
原子間相互作用**		量子力学を近似して解く**

**「経験的パラメーター」は含まない

既存手法の特徴と問題点

- 予測精度 vs 計算コスト

	予測精度	計算コスト
古典分子動力学法	中	低
第一原理分子動力学法	高	高



- どちらの手法も一長一短
- 計算コストが低くて予測精度が高いのが理想
- そんな手法ある？

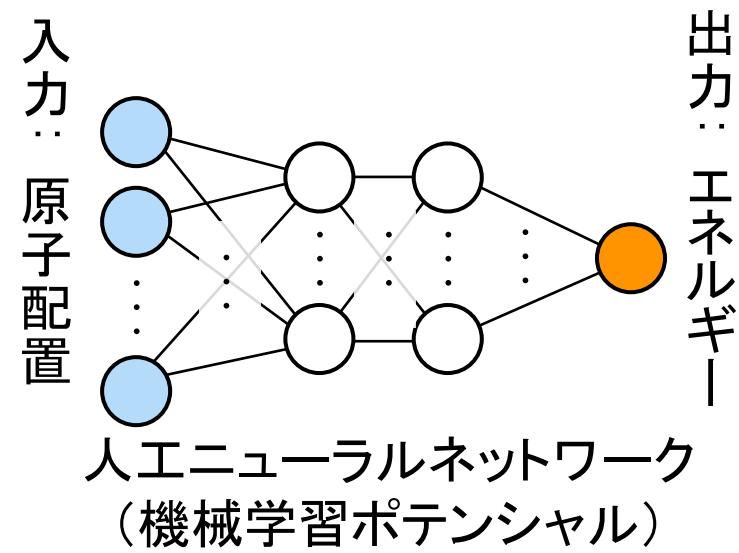
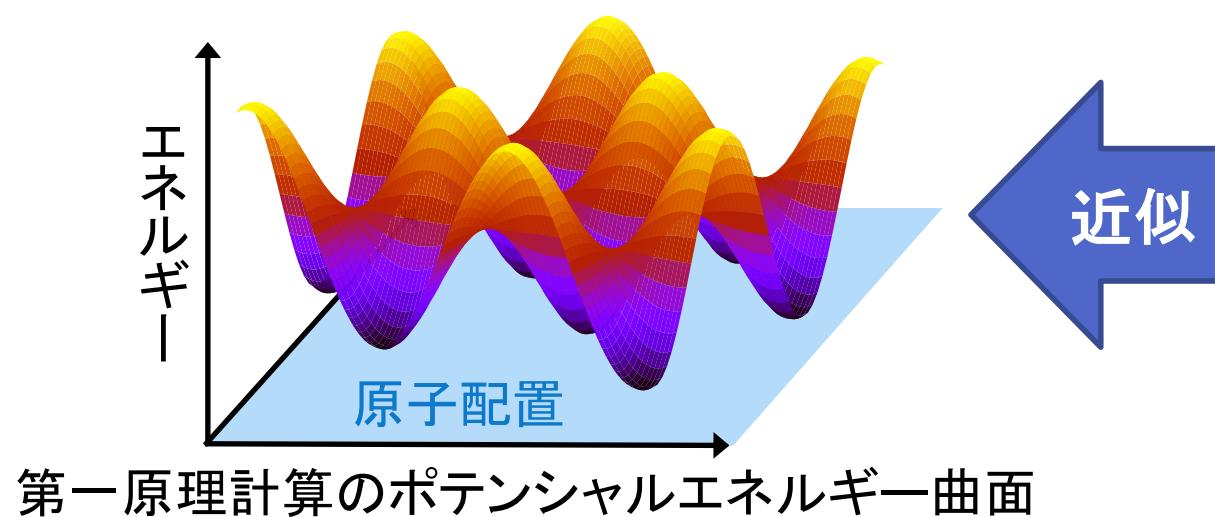


あります！
機械学習分子動力学法

Behler and Parrinello, PRL (2007)

機械学習分子動力学法

- 概略: 第一原理計算のポテンシャルエネルギー曲面を人工ニューラルネットワーク等で近似する
 - 機械学習の手法: 人工ニューラルネットワーク、ガウス過程
 - 入力: 原子配置、出力: エネルギー
 - 学習済みの人工ニューラルネットワークを「機械学習ポテンシャル」と呼ぶ
 - 教師データ: 第一原理計算の結果
 - 大量の第一原理計算を実施して教師データを作る
 - 詳細は「まとめ」の後のスライドで説明



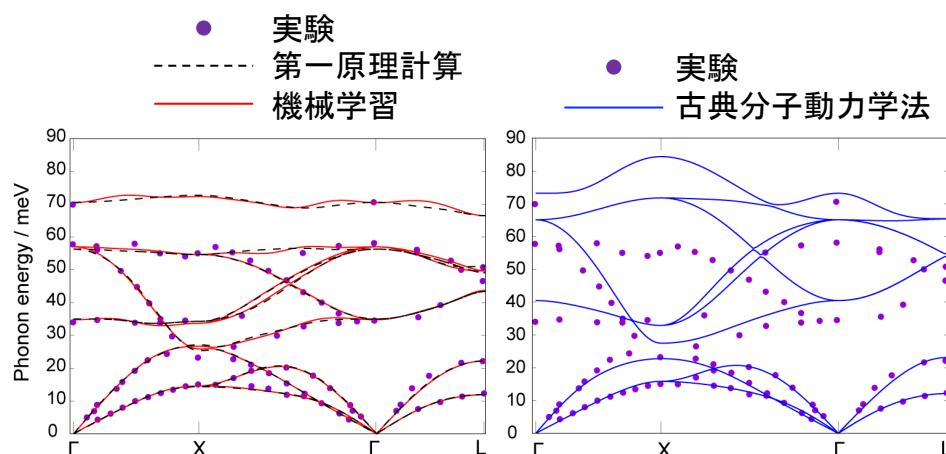
機械学習分子動力学法で何ができるか？

- 高予測精度シミュレーション

- 例: ThO₂のフォノンスペクトル

K. Kobayashi *et al.*, Sci. Rep. **12**, 9808 (2022).

- 古典分子動力学法では実験結果と合わない部分がある
- 機械学習分子動力学法は実験結果とよく合う

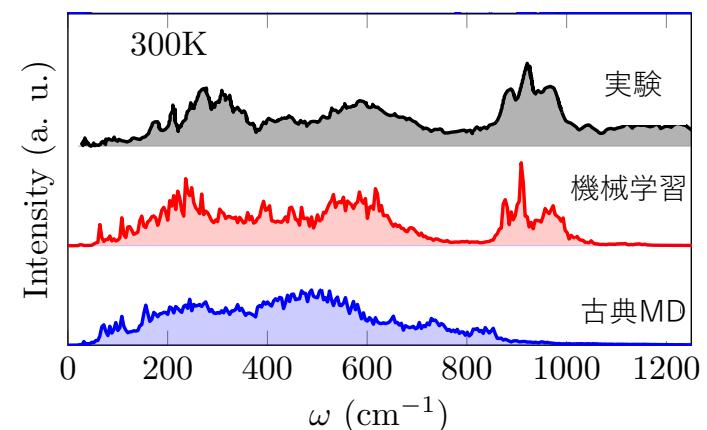


- 高予測精度・長時間シミュレーション

- 例: 粘土鉱物カオリナイトのヒドロキシ基振動スペクトル

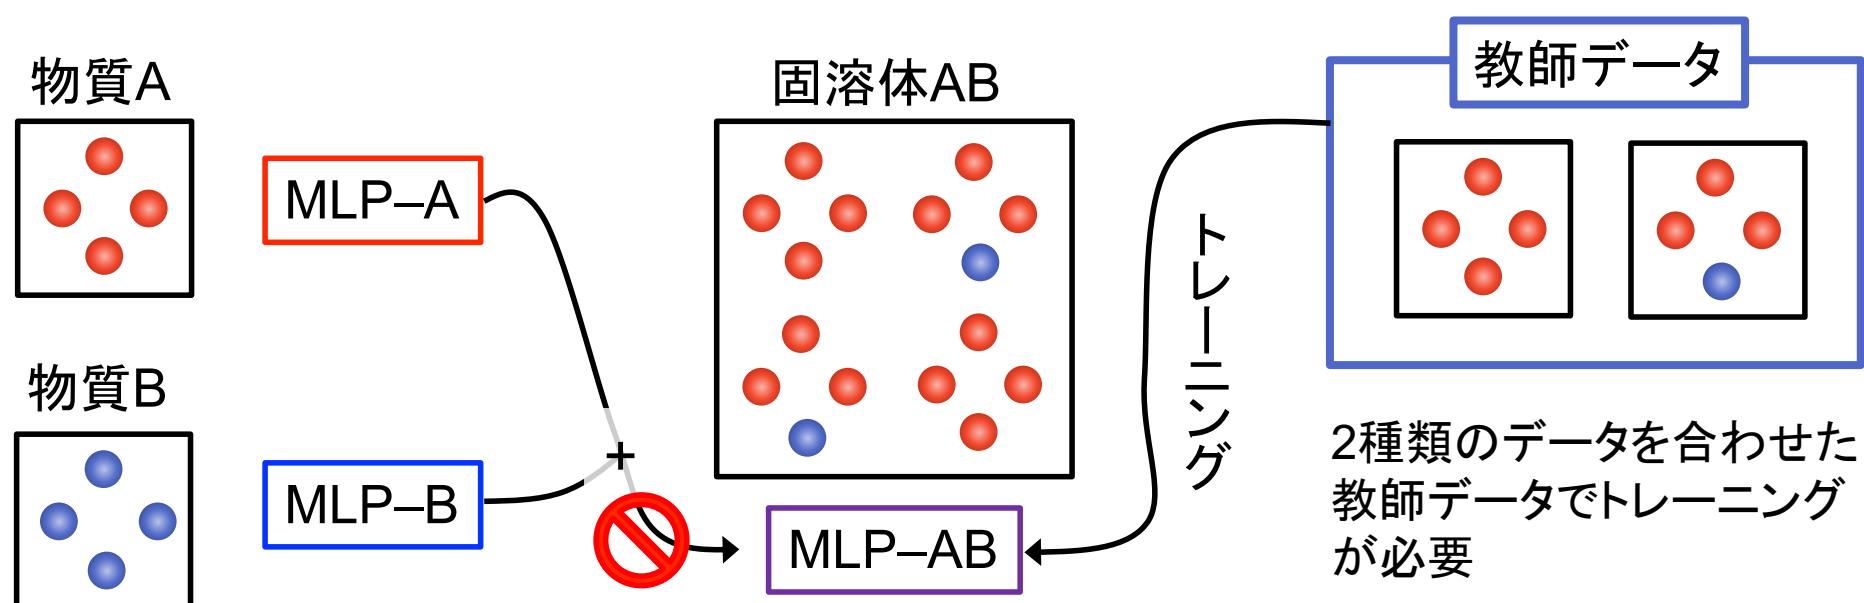
K. Kobayashi *et al.*, App. Clay Sci. **228**, 106596 (2022).

- 遅い振動モードの計算のためには長時間のシミュレーションが必要
- 古典分子動力学法では実験結果と合わない部分がある
- 機械学習分子動力学法は実験結果とよく合う



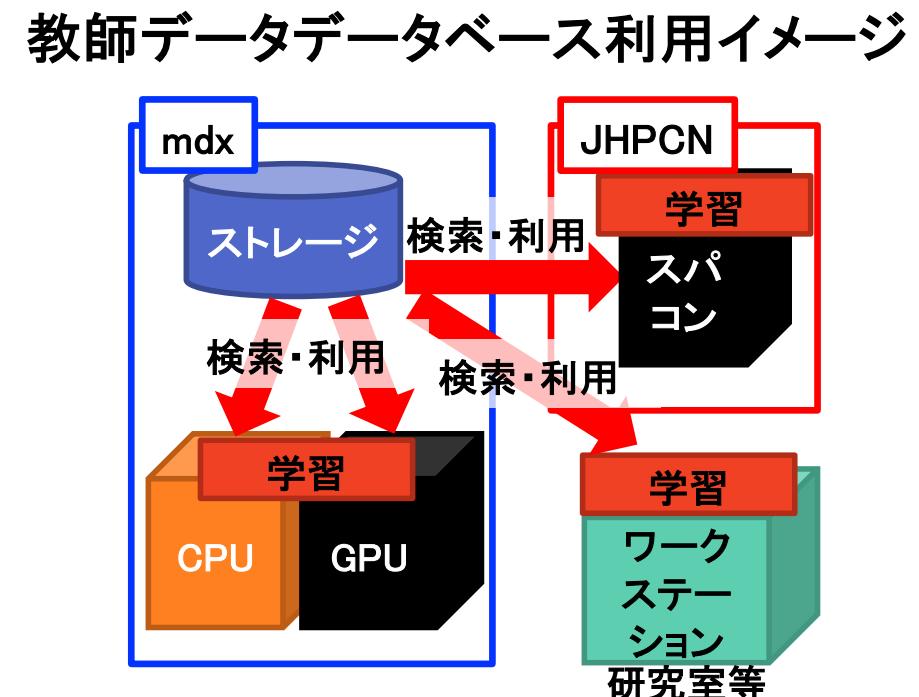
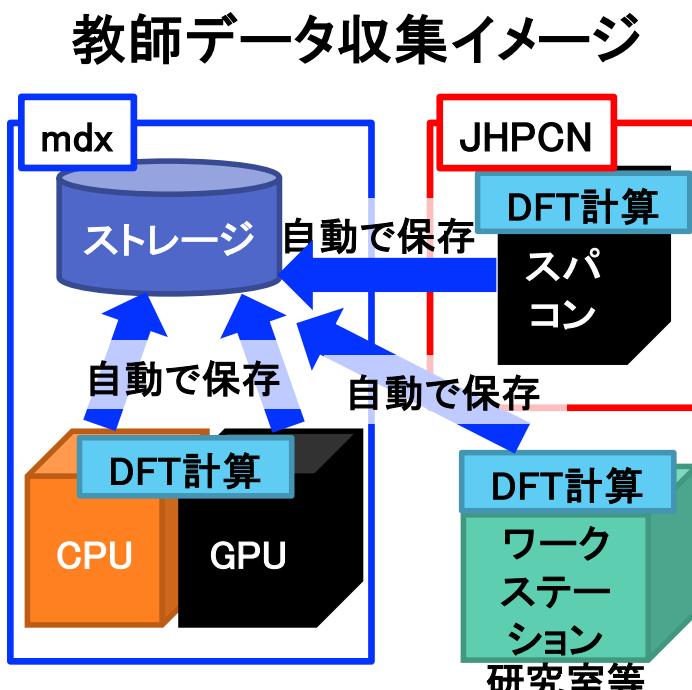
機械学習分子動力学法の不便な点

- 物質ごとに機械学習ポテンシャルを作る必要がある
- 既存の機械学習ポテンシャルを組み合わせることはできない
 - 例: 物質A、Bの機械学習ポテンシャル(MLP-A, MLP-B)が公開されている状況で固溶体ABの機械学習ポテンシャル(MLP-AB)を作りたい
 - MLP-AとMLP-Bを組み合わせることはできない
 - 物質A、物質B、物質ABの第一原理計算の結果を混ぜた教師データを用いてトレーニングして作成する必要がある
 - しかし、**教師データはほとんど公開されていないため、計算を全てやり直す必要がある**



統合機械学習分子動力学システム

- 目的
 - 機械学習ポテンシャル作成のための第一原理計算結果のデータベース
 - 将来的には機械学習ポテンシャルの自動作成を目指す
- システム概略



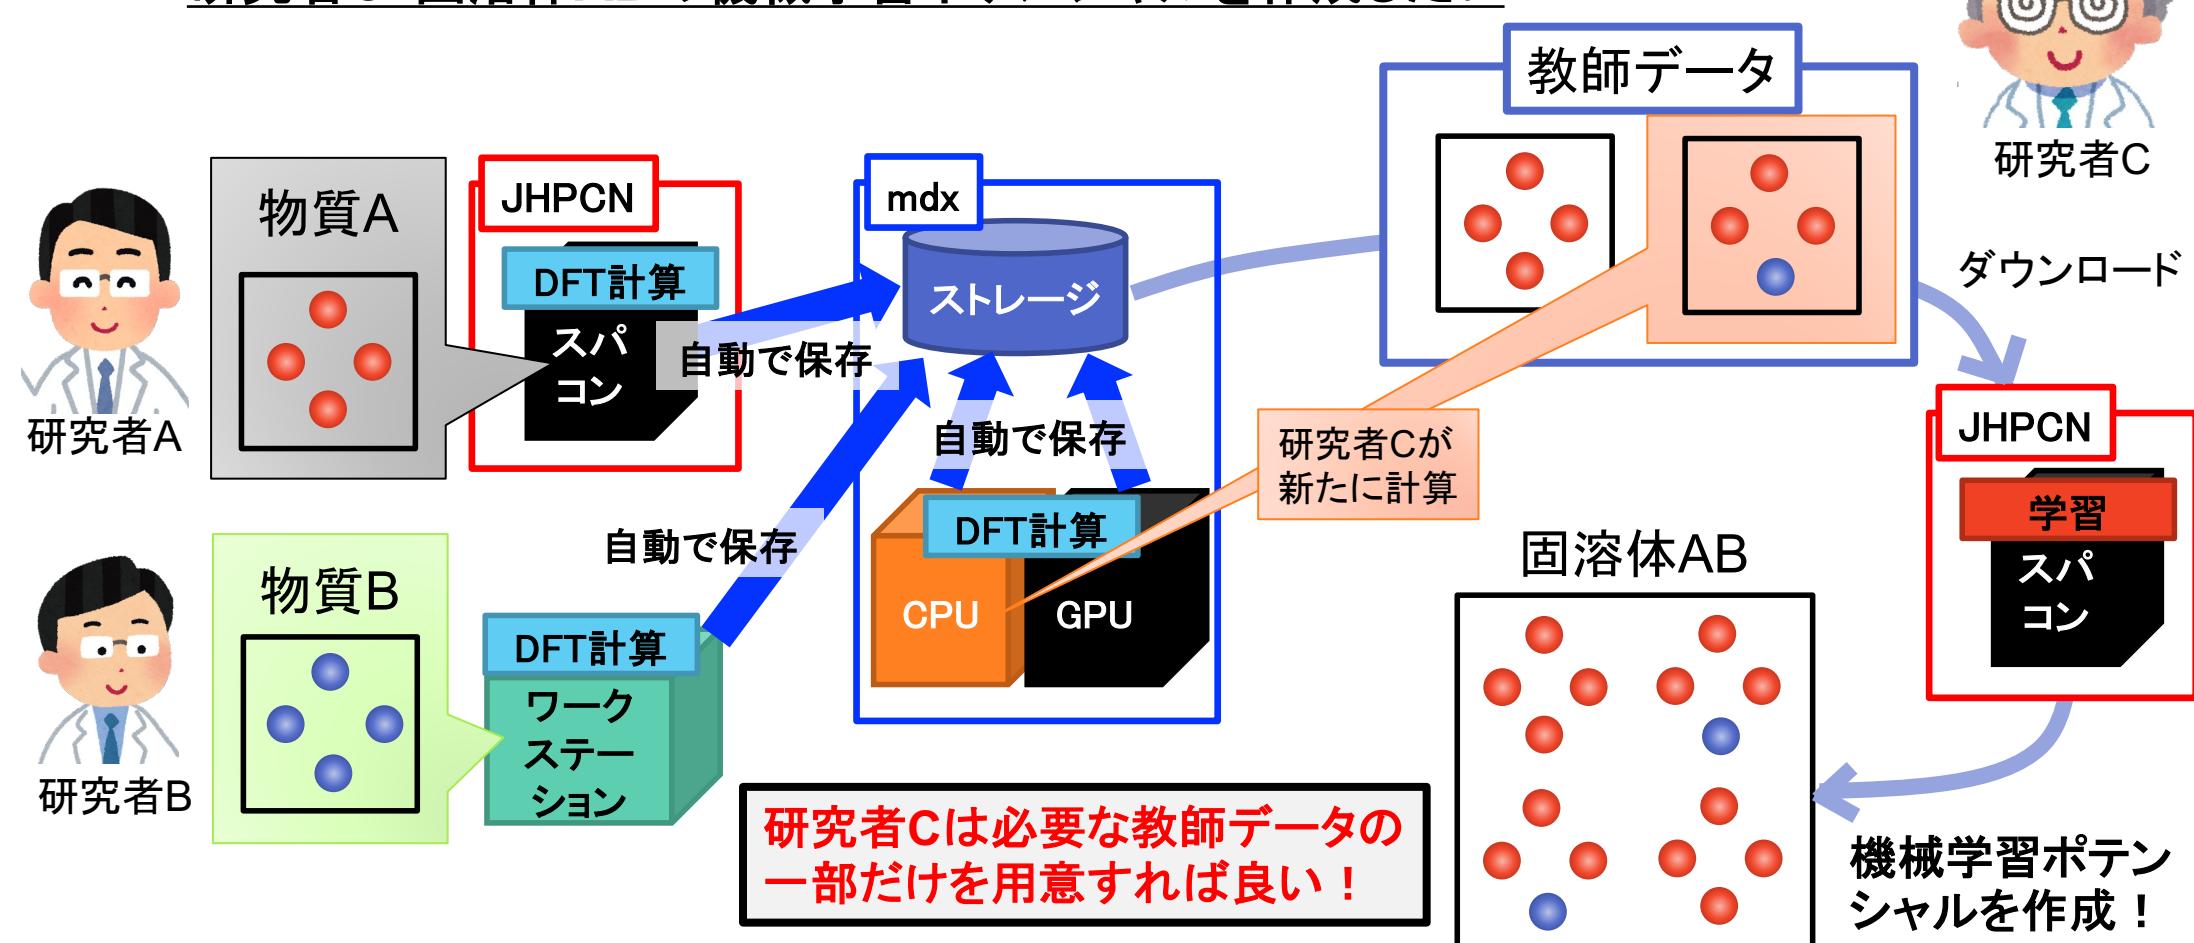
- 量子力学計算の結果を自動で保存
- データベースに自動で追加される

- 物質名や元素名で検索
- 様々な計算機環境で学習に利用

統合機械学習分子動力学システム

・利用例

- 研究者A: 物質Aの教師データ、機械学習ポテンシャルを作成済み
- 研究者B: 物質Bの教師データ、機械学習ポテンシャルを作成済み
- 研究者C: 固溶体ABの機械学習ポテンシャルを作成したい



まとめ

- 機械学習分子動力学法の紹介
 - 人工ニューラルネットワーク等で第一原理計算の結果を学習
 - 高予測精度と低計算コストを両立
 - 物質ごとに教師データを用意し、人工ニューラルネットワークのトレーニングが必要
 - 教師データはほとんど公開されていない
- 統合機械学習分子動力学システムの概略紹介
 - 教師データの収集・検索・利用のためのデータベース作成
 - 最も計算資源を必要とするのが教師データ作成であるため、教師データを共有することにより、機械学習ポテンシャルの構築が容易になる
 - 将来的には、機械学習ポテンシャルの自動生成を実現したい

機械学習分子動力学法詳細 1/3

- 特徴
 - 機械学習を用いて、高予測精度かつ低計算コストを実現
 - 小さい系で学習して大きな系を計算可能
- 仮定、その他
 - 全エネルギーは各原子に付随する「原子エネルギー」に分割
 - 原子エネルギーはカットオフ半径内に存在する周辺原子の配置で決まる
 - 長距離力は十分にスクリーンされている
 - 周辺原子配置は並進・回転変換普遍な「記述子」と呼ばれる特徴量の関数

$$E_{\text{tot}} = \sum_{i=1}^N \epsilon \left(D_{r_c}^{(i)} \right)$$

記述子 $D_{r_c}^{(i)}$

- カットオフ半径 r_c 内に存在する周辺原子配置の特徴量
- 並進・回転変換不変

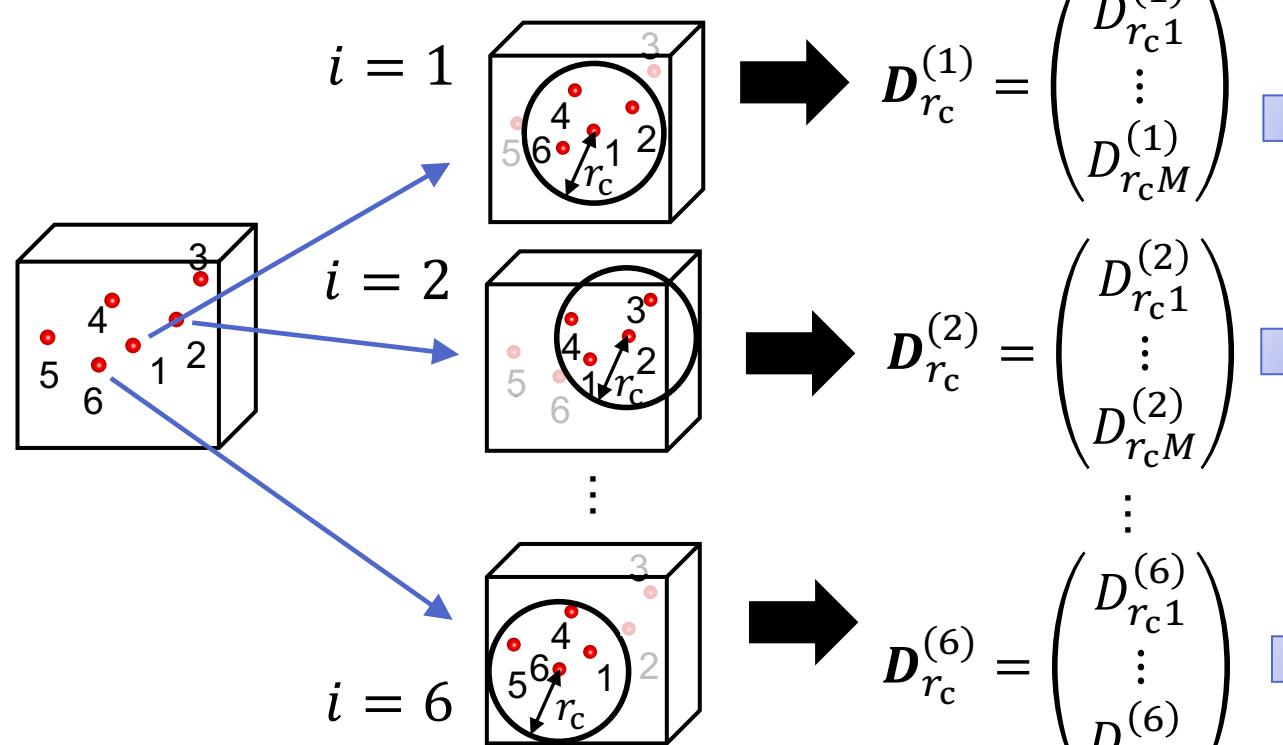
全エネルギー E_{tot}

原子エネルギー ϵ

入力 $D_{r_c}^{(i)}$ の非線形関数
人工ニューラルネットワークで近似

機械学習分子動力学法詳細 2/3

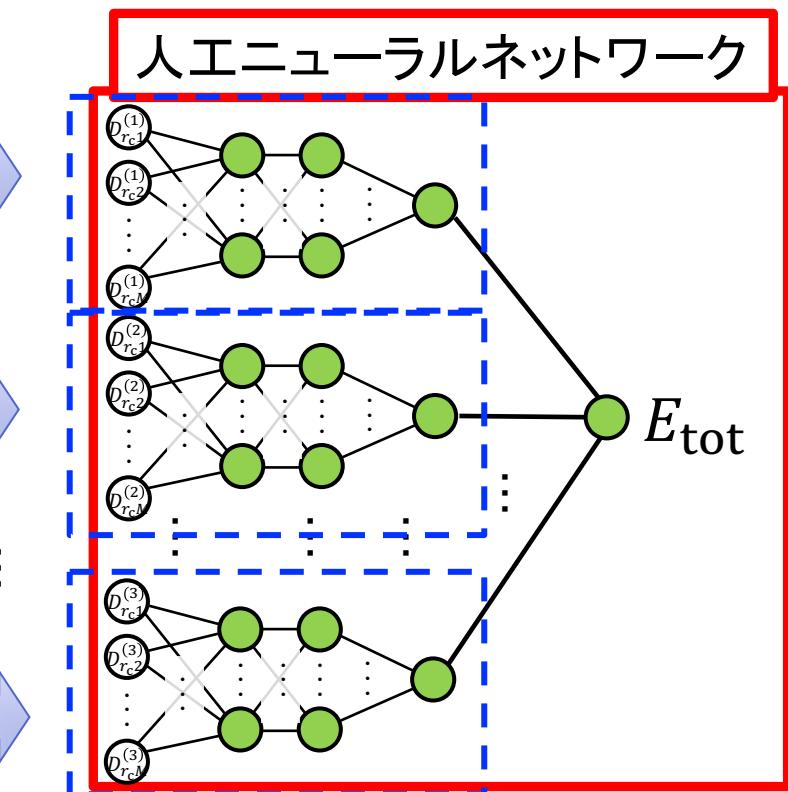
- 例: 6個の原子で構成される系



記述子 $D_{r_c}^{(i)}$ (M 次元)

- カットオフ半径 r_c 内に存在する周辺原子配置の特徴量
- 並進・回転変換不变

$$E_{\text{tot}} = \sum_{i=1}^6 \epsilon(D_{r_c}^{(i)})$$

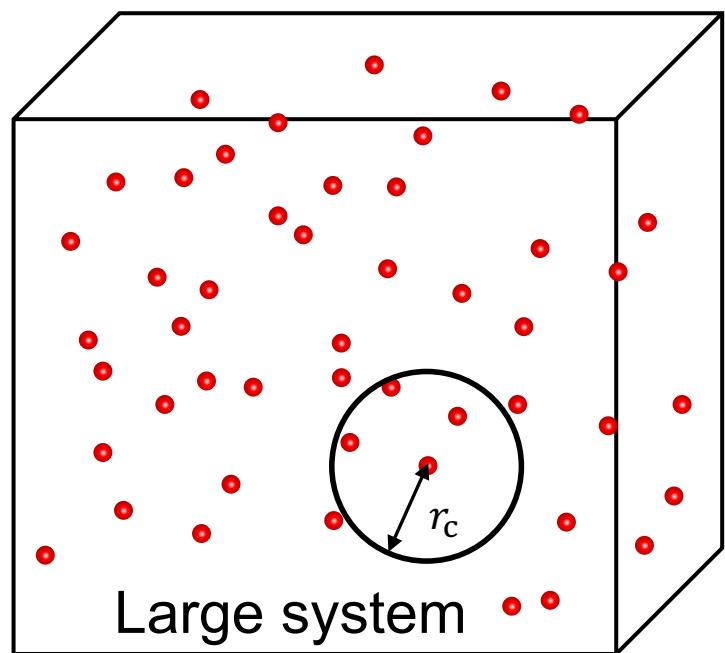


大量の第一原理計算の結果を教師データとしてトレーニング

非線形関数 $\epsilon(D_{r_c}^{(i)})$ が得られる

機械学習分子動力学法詳細 3/3

- 大きな系への適用



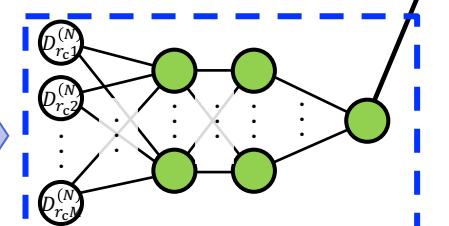
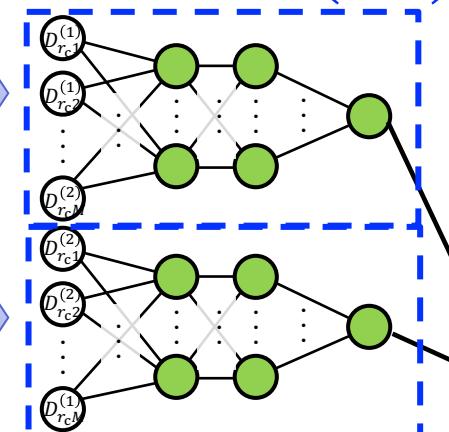
$$\mathbf{D}_{r_c}^{(1)} = \begin{pmatrix} D_{r_c1}^{(1)} \\ \vdots \\ D_{r_cM}^{(1)} \end{pmatrix}$$

$$\mathbf{D}_{r_c}^{(2)} = \begin{pmatrix} D_{r_c1}^{(2)} \\ \vdots \\ D_{r_cM}^{(2)} \end{pmatrix}$$

⋮

$$\mathbf{D}_{r_c}^{(N)} = \begin{pmatrix} D_{r_c1}^{(N)} \\ \vdots \\ D_{r_cM}^{(N)} \end{pmatrix}$$

トレーニング済みの
非線形関数 $\epsilon(\mathbf{D}_{r_c}^{(i)})$



$$E_{\text{tot}}^{\text{large}} := \sum_{i=1}^N \epsilon(\mathbf{D}_{r_c}^{(i)})$$

トレーニング済みの $\epsilon(\mathbf{D}_{r_c}^{(i)})$ を組み合わせて、大きな系の全エネルギーを表す人工ニューラルネットワークを構築する

全エネルギーを原子位置で微分すれば力が得られる
→ 分子動力学計算が可能！