

# 創薬DX Platformのための HPCとワークフロー

2024年8月6日

千葉峻太朗

R-CCS HPC/AI 駆動型医薬プラットフォーム部門  
分子デザイン計算知能ユニット



# 自己紹介

# 計算の計算による計算のための科学

理化学研究所

計算科学研究センター（R-CCS）

理研の12研究センターの一つであると同時に  
高性能計算科学における国家「知の拠点」センター

新しいコンピュータ・  
アーキテクチャや  
計算モデル

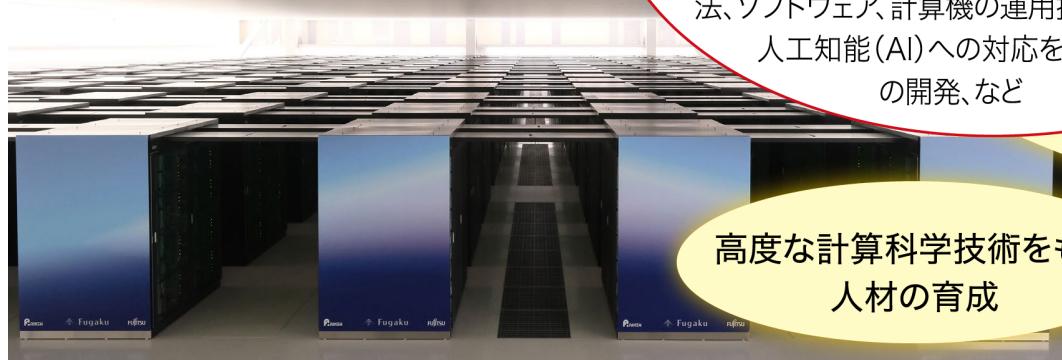
新しいデバイスの  
ためのアルゴリズムや  
プログラミングモデル

## 計算の科学

高性能計算の本質となる  
コンピューティング技術の研究

ポストムーア時代を見据えた新たなコンピューティング技術、  
アーキテクチャ、アルゴリズム等の開発やプログラミング手  
法、ソフトウェア、計算機の運用技術、ビッグデータ・  
人工知能（AI）への対応を実現する手法  
の開発、など

スーパーコンピュータ「富岳」



高度な計算科学技術をもつ  
人材の育成

## 計算のための科学

さまざまな科学分野との連携により  
高性能計算を進化させる

光・量子・再構成可能コンピューティング・ニューロモル  
フィックコンピューティングなど、新しいコンピュー  
ティングの概念を支える材料やデバイスの開発

## 相乗効果と融合

## 計算による科学

高性能計算を活用し  
科学・社会の課題解決を目指す研究

高信頼性かつ高精度な解析・シミュレーションを用いた、  
生命科学、工学、気象・気候、防災・減災、物質科学、宇  
宙・素粒子物理学や社会科学などの研究、来る  
べきSociety5.0社会に向けた機械学  
習の応用開発など

理研の他の研究センター  
および国内外の大学・  
研究機関との連携

R-CCSが橋頭保的な役割

新しいコンピューティング  
技術による計算の高度化

## 計算の科学



プログラミング環境  
研究チーム  
佐藤 三久



大規模並列  
数値計算技術  
研究チーム  
今村 俊幸



プロセッサ研究チーム  
佐野 健太郎



高性能ビッグデータ  
研究チーム  
佐藤 賢斗



高性能人工知能  
システム  
研究チーム  
松岡 聰



次世代高性能  
アーキテクチャ  
研究チーム  
近藤 正章

## 計算による科学



離散事象シミュ  
レーション  
研究チーム  
伊藤 伸泰



粒子系シミュレータ  
研究チーム  
牧野 淳一郎



総合防災・減災  
研究チーム  
大石 哲



量子系分子科学  
研究チーム  
中嶋 隆人



複合系気候科学  
研究チーム  
富田 浩文



量子系物質科学  
研究チーム  
柚木 清司



複雑現象統一的解法  
研究チーム  
坪倉 誠



粒子系生物物理  
研究チーム  
杉田 有治



連続系場の理論  
研究チーム  
青木 保道



計算構造生物学  
研究チーム  
Florence TAMA

## 2021年4月1日設置

HPC/AI駆動型医薬  
プラットフォーム部門

バイオメディカル  
計算知能ユニット  
奥野 恒史



創薬化学AIアプ  
リケーション  
ユニット  
本間 光貴



分子デザイン計算  
知能ユニット  
池口 満徳



AI創薬連携基盤  
ユニット  
奥野 恒史

## 運用技術部門



施設運転技術  
ユニット  
塚本 俊之



システム運転技術  
ユニット  
宇野 篤也



チューニング技術  
ユニット  
庄司 文由



利用環境技術  
ユニット  
庄司 文由



先端運用技術  
ユニット  
山本 啓二

# 背景：創薬の常識を覆したCOVID-19と欧米の底力

## 創薬の常識

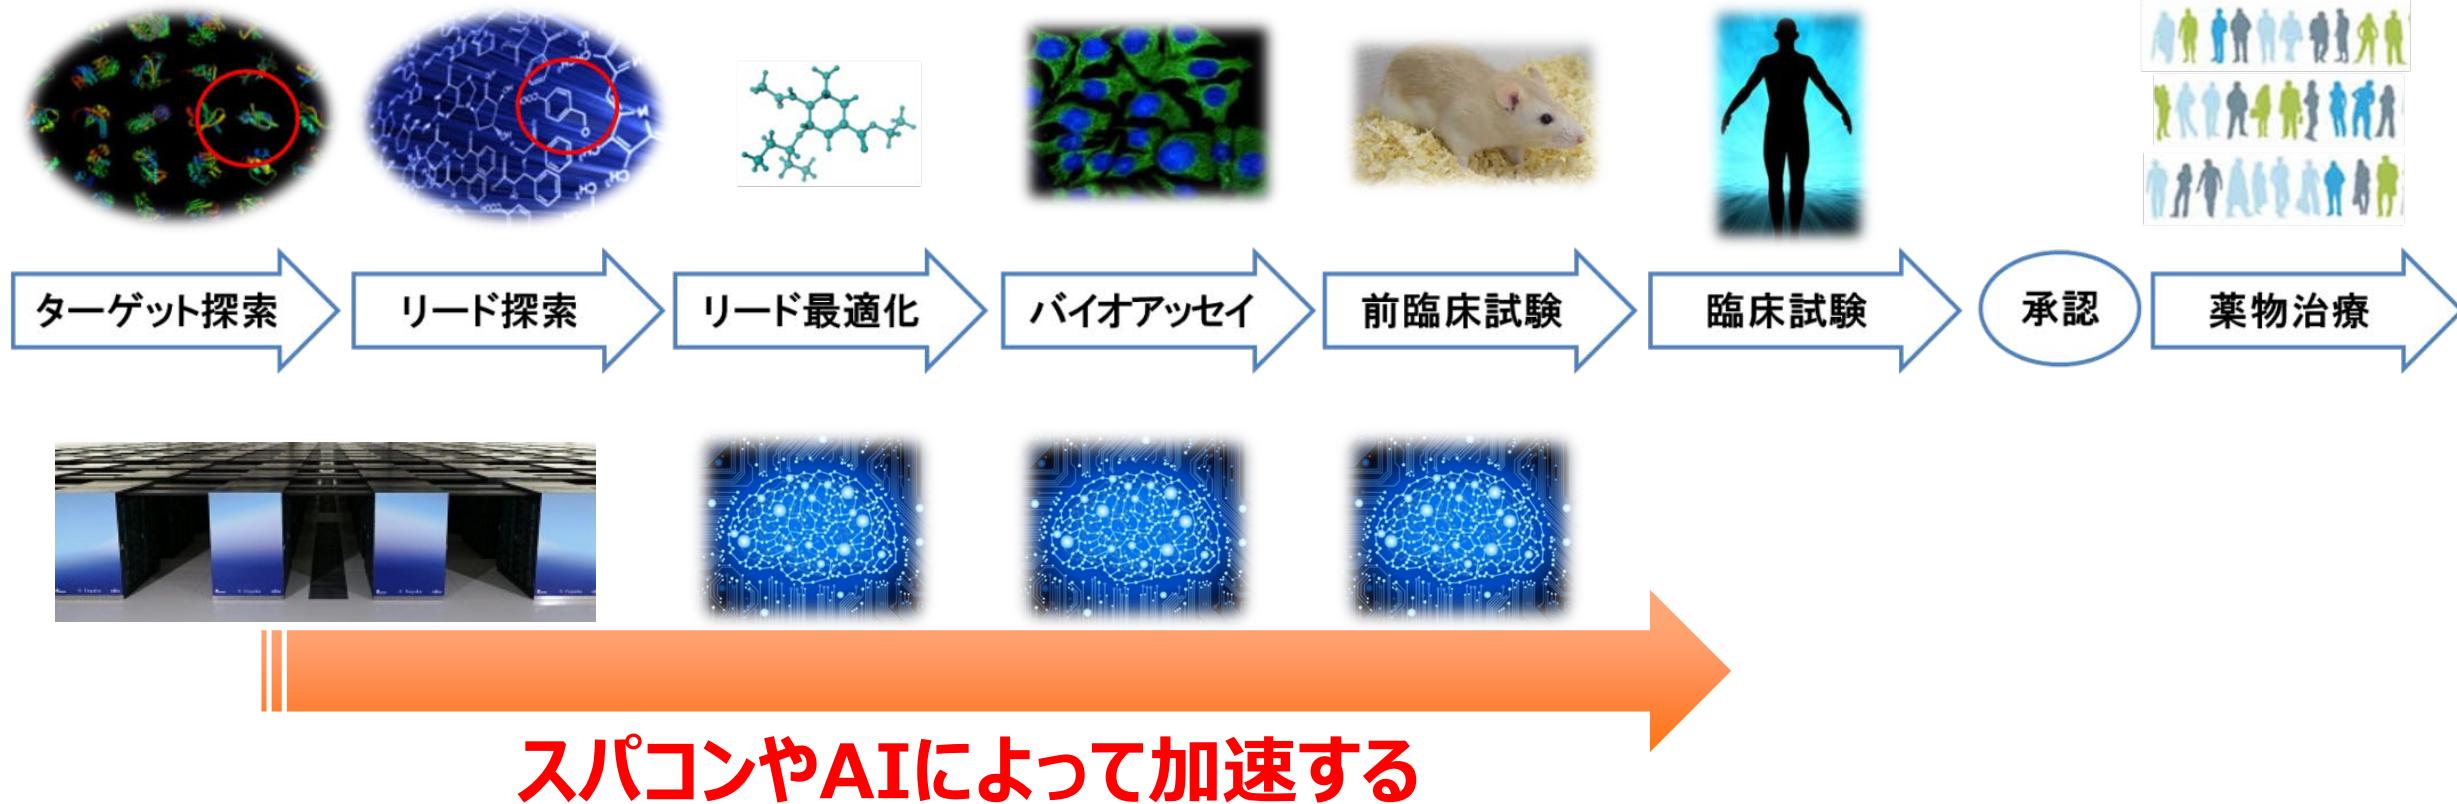
医薬品開発の成功確率：2.5万分の1以下  
(開発費用1200億円、開発期間約10年以上)



# AIやシミュレーションで少人数・低成本で創薬の超効率化を目指す

## 創薬の常識

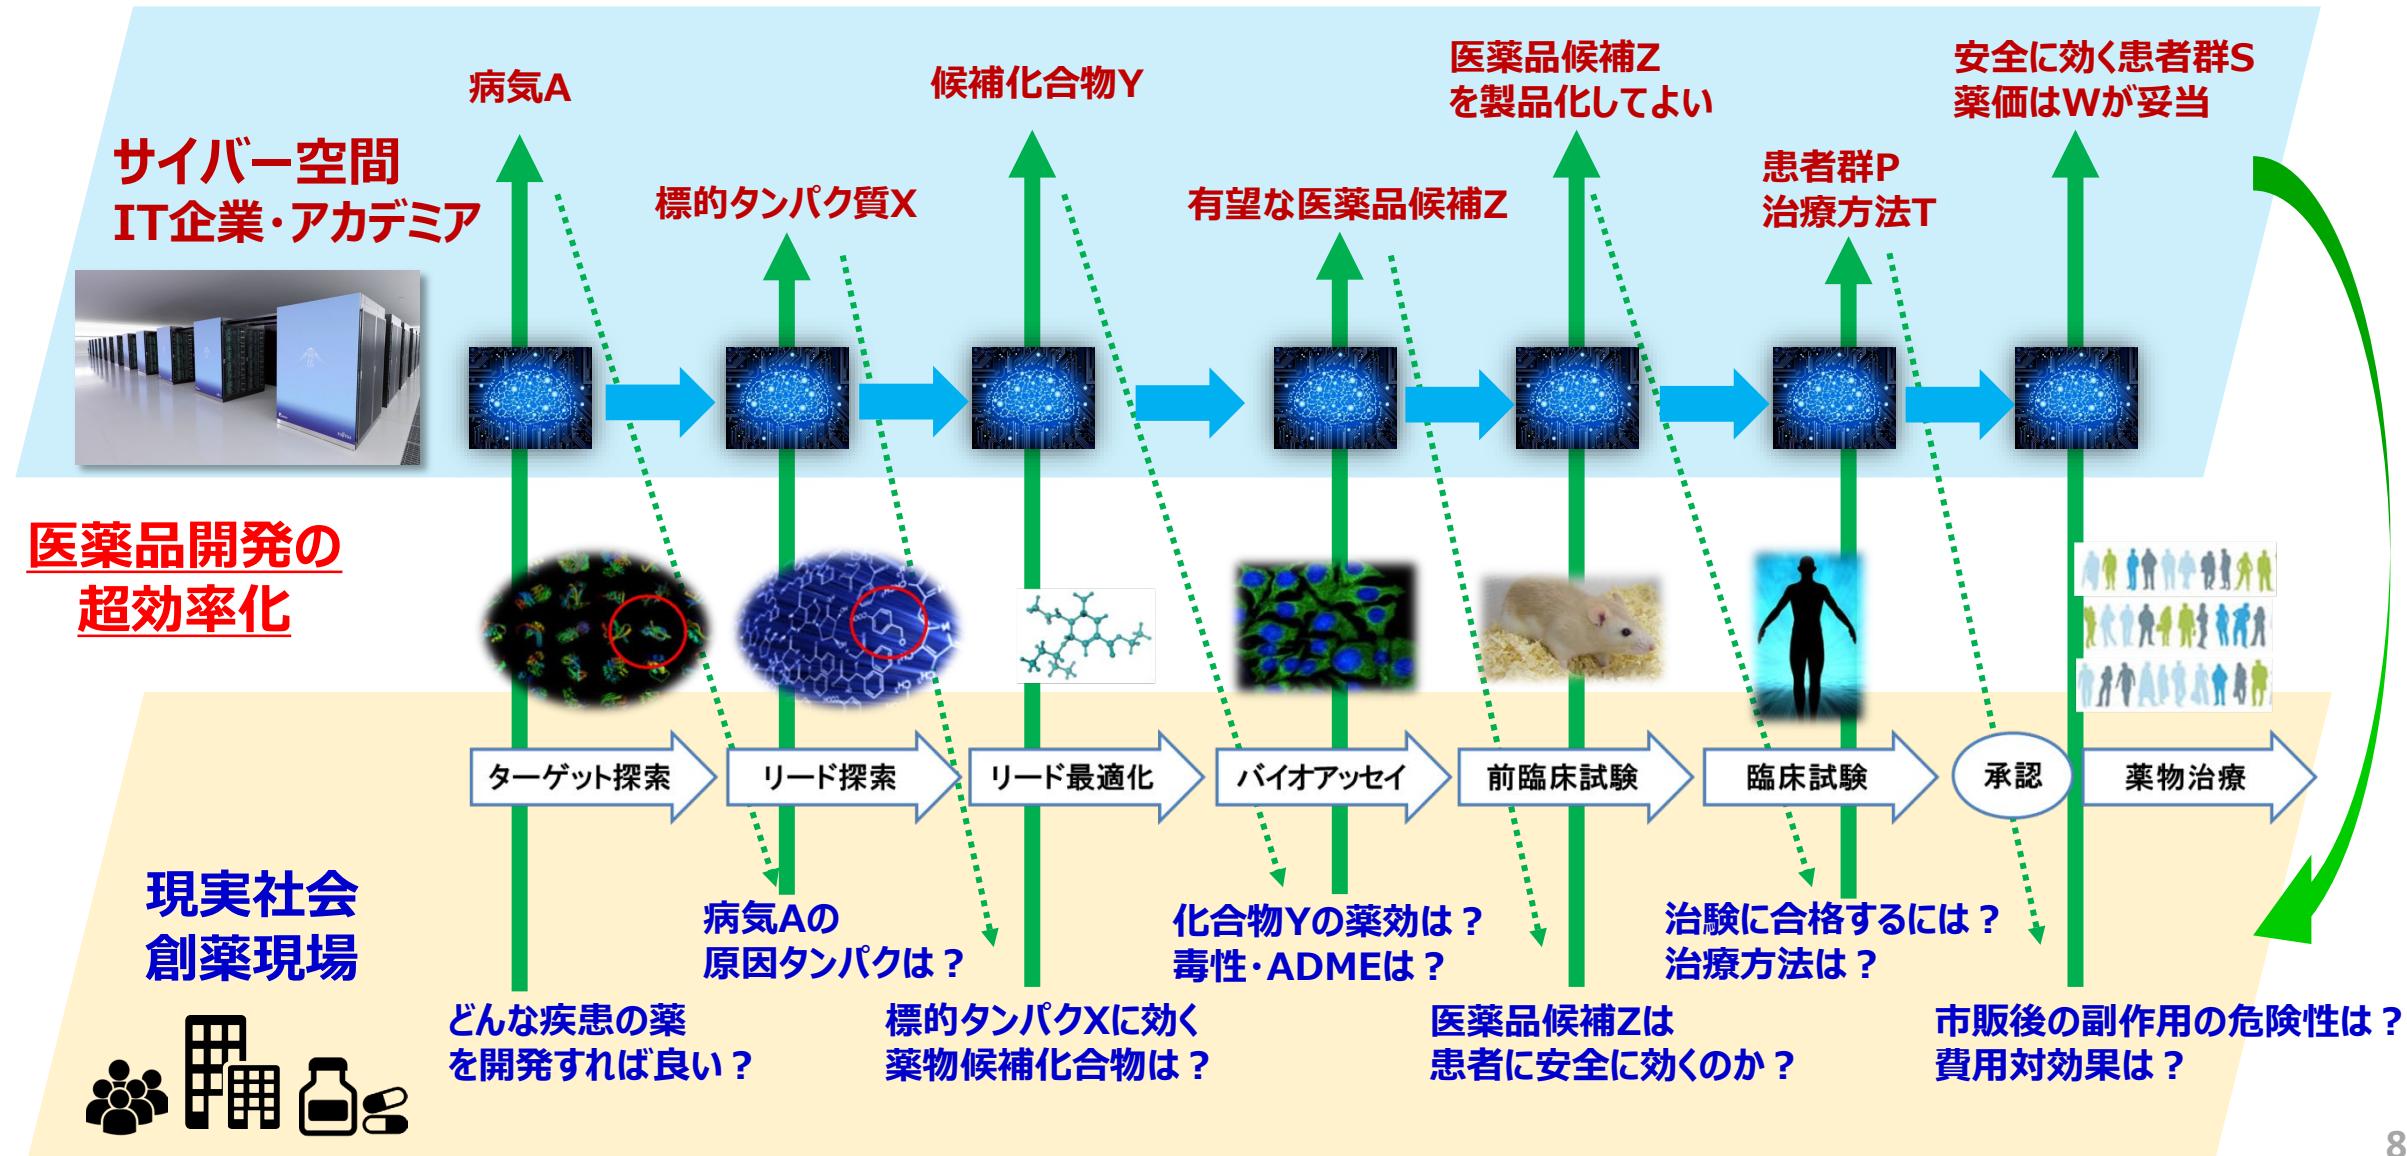
医薬品開発の成功確率：2.5万分の1以下  
(開発費用1200億円、開発期間約10年以上)



# 「富岳」創薬DXプラットフォーム

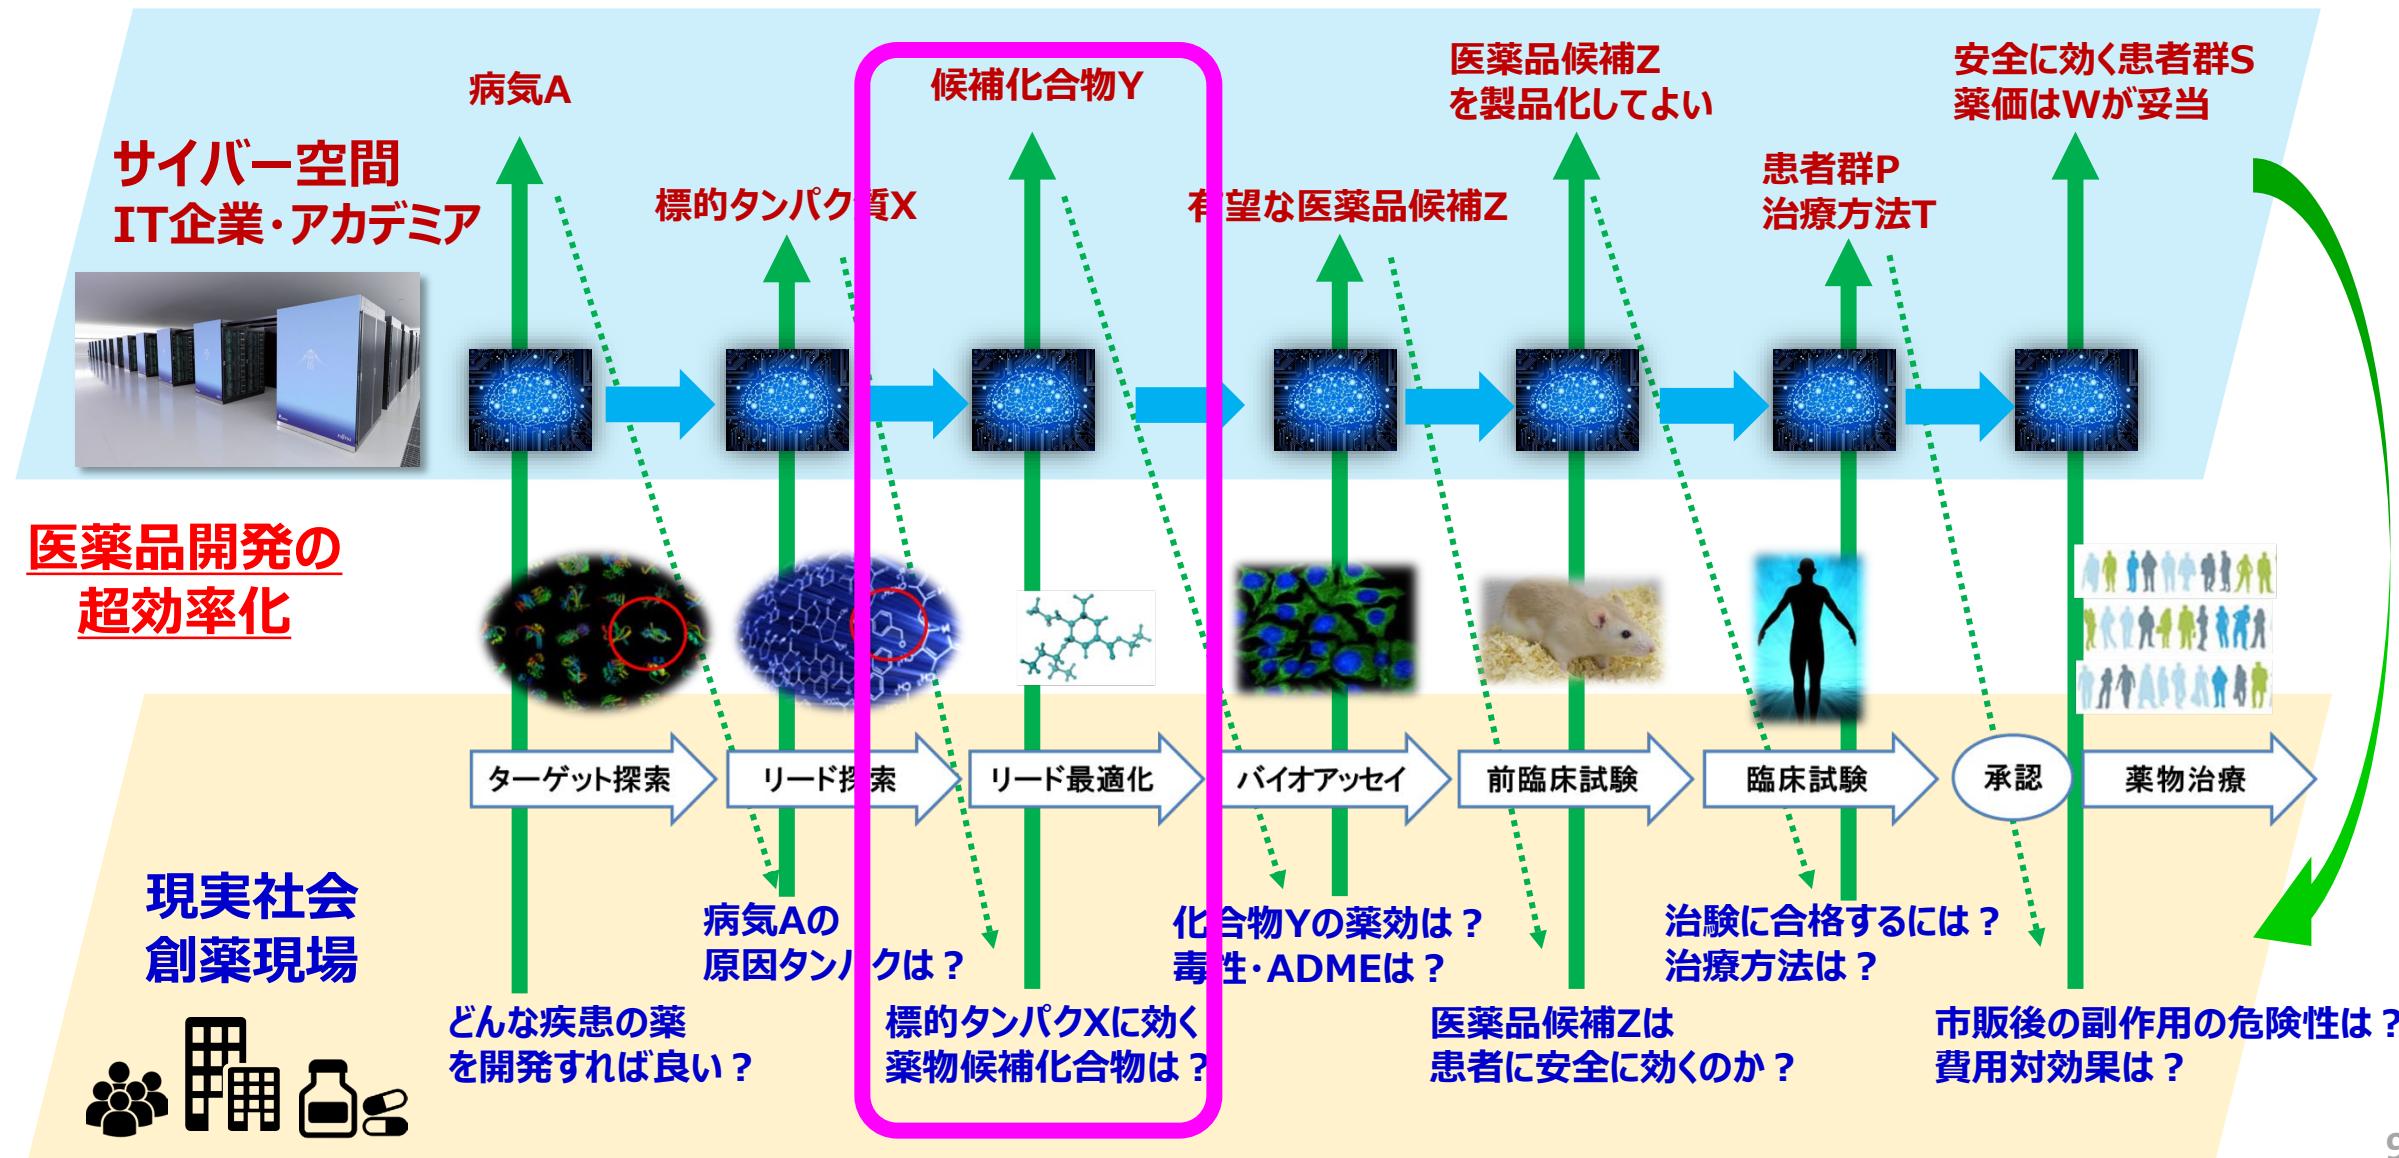


「富岳」を基軸として、AIとシミュレーションを融合させた革新的な創薬DXプラットフォームを構築し、創薬プロセスの超効率化を目指す。これにより、新薬やワクチン開発の少人数・低コスト・迅速化を実現する。



# 「富岳」創薬DXプラットフォーム

「富岳」を基軸として、AIとシミュレーションを融合させた革新的な創薬DXプラットフォームを構築し、創薬プロセスの超効率化を目指す。これにより、新薬やワクチン開発の少人数・低コスト・迅速化を実現する。

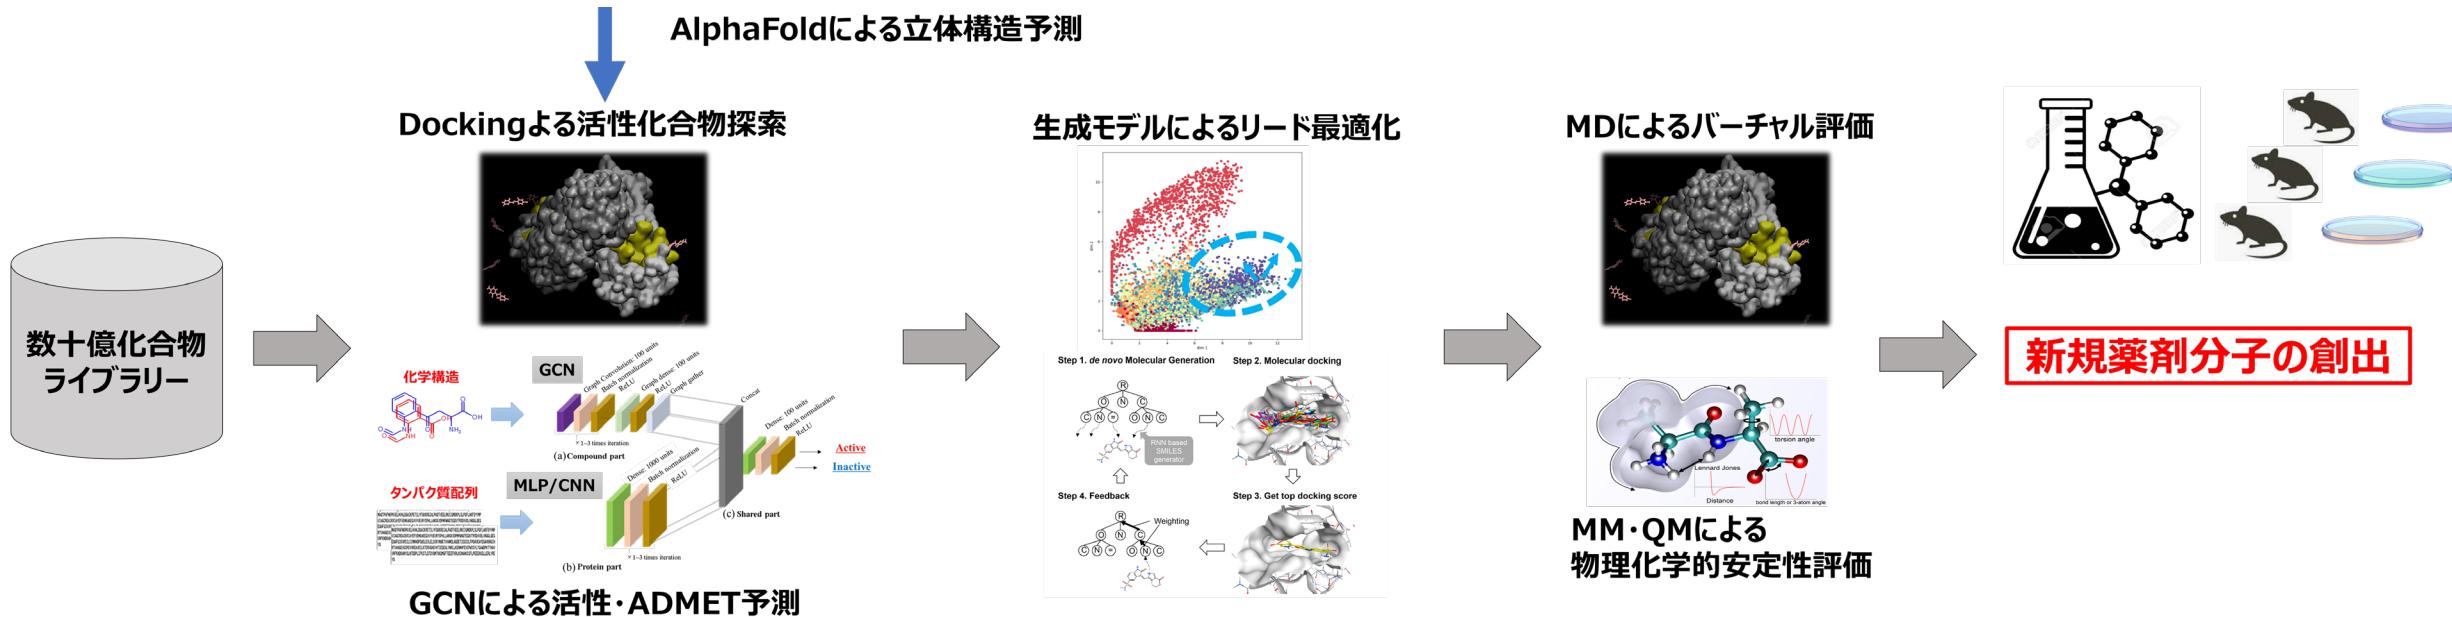


# リード化合物創出 ワークフロー



- 「富岳」を中心に、HPC/AIフローの自動化を図ることで、創薬の超効率化を実現
- リード化合物創出：標的タンパク質名を入力して、リード化合物を推定するHPC/AIフロー

## 創薬標的分子の遺伝子名（例：タンパク質のアミノ酸配列）



# 世の中にあるOSSワークフローエンジン

## （参考）OpenSourceのWorkflow Framework

2022~2023年調査

JN: Jupyter Notebook, WM: Workflow Management

○: 対応済み・わずかな手間で対応可, △: ある程度の手間で対応可, ×: 対応不可・相当手間をかけないと対応できない, ?: 不明

名称	Owner	License	DX Platformで必要な機能					GitHub		備考	
			富岳ジョブ投入 対応	GUI/連携動作	中途再実行	マルチ ユーザ	フロー 作成	フロー GUI管理	☆	⌚	
Airflow	Apache Airflow Community	Apache 2.0	×? Job Schedulerとかは標準では無いAdd-onにあるか	△-x 本体にタスクのGUIを実現する機能は無い。別個に作成	○ GUIでも操作可能	× (フローの実行履歴の表示)	Python	○	27,800	760	Pythonで制御するWMエンジンApache Projectなので情報が豊富なEco Systemも確立。多彩なadd-onビジネス向けの定型Workflow構築が主目的なので、DXPEのようなフロー構築に適しているのか？
Prefect	Prefect Technologies	Apache 2.0 (open source版)	○ PythonでSSHのWrapperを組めばよいか	△-x AirFlowに同じ	○ GUIでも操作可能？	×	Python	○	11,800	153	Airflowの代替を目標に開発されたWM Pythonの関数として定義したTaskをつなげてflowにして実行。軽量。シンプルで理解しやすい動的なflow（Taskの結果で後続の作業が変わるもの）を作成することが可能
Ray	The Ray Team	Apache 2.0	×? Ray Clusterで管理するには、各々に専用の常駐プログラムが必要？	△-x AirFlowに同じ	?	×	Python	×	22,300	427	分散タスクを管理するRay Coreを中心としたシステムクラスタを管理するRay Cluster, MLフローをサポートするRay AIR等から構成される
Luigi	Spotify	Apache 2.0	×? Job Schedulerとかは標準では無いAdd-onにあるか	△-x AirFlowに同じ	?	×	Python	○	16,000	486	Pythonで制御するWMエンジンビジネス向けの定型Workflow構築が主目的なので、DXPEのようなフロー構築に適しているのか？
Task	Task core developers	BSD3 Clause	×? Job Schedulerはあるが、富岳用にconfigできないっぽい	△-x AirFlowに同じ	?	×	Python	×	10,400	221	Pythonで制御するWMエンジンPythonのDataframeやndarrayを分散処理できる機能があるDXPEのように、HPC上のアプリケーションをPipelineでつなげたFlowを管理するという用途には適していない？

## （参考）OpenSourceのWorkflow Framework – 続き

2022~2023年調査

JN: Jupyter Notebook, WM: Workflow Management

○: 対応済み・わずかな手間で対応可, △: ある程度の手間で対応可, ×: 対応不可・相当手間をかけないと対応できない, ?: 不明

名称	Owner	License	DX Platformで必要な機能						GitHub		備考
			富岳対応	GUI/連携動作	中途再実行	マルチ ユーザ	フロー 作成	フロー GUI管理	☆	⌚	
Cromwell	Broad Institute	BSD3 Clause	△ HPC制御機能をConfig可なのでいけそう	△-x AirFlowに同じ	○? CallCaching機能が相当しそう	×	WDL	×	850	113	Javaで動くプログラム
AiiDA	MARVEL National Centre of Competence in Research,	MIT	△ HPC制御機能をConfig可なのでいけそう	△-x AirFlowに同じ	○ 各ステップの入力/出力をDBで記録・管理	×	Python	×	327	27	PythonからWMエンジンの操作を可能にするライブラリ群を提供
Covalent	Agnostiq	AGPL3	×? SSHを飛ばせるがJob Schedulingが無さそう	△-x AirFlowに同じ	?	×	Python	○	173	10	見た目がWHEELに似ている
Makeflow	University of Notre Dame	GPLv2	△? 凱用Queue制御が使えそう	△-x AirFlowに同じ	△? "Make like"なので可能？	×	独自 Makefile like	×	109	18	CCL Toolsという分散システムコラボツールの一部
Stream Flow	Università di Torino	LGPLv3	? SSHでいいけるのか	?	?	×	CWL	×	23	7	ドキュメントがちょっとpoor
Jupyter Workflow	Università di Torino	LGPLv3	↑	JN連携	△ JNから動かすので可能？	×	↑	×	7	6	Stream FlowのJNの拡張 コア部分はStream Flowを使う Stream FlowをJNから使うためのUIの位置づけか

など多数

- Prefectを利用してDX Platformを構築

### DXプラットフォームコンセプト：

- 様々なアプリを一つのプラットフォームに実装し全体の最適化を図る
- 自由につなげた創薬シナリオを構築できる
- 創薬アプリの共通プラットフォームへ

# 創薬DX Platformのワークフローエンジン

flow\_trial.py

```

import requests
from prefect import flow, task

@task
def call_api(url):
    response = requests.get(url)
    print(response.status_code)
    return response.json()

@task
def parse_fact(response):
    fact = response["fact"]
    print(fact)
    return fact

@flow
def api_flow(url):
    fact_json = call_api(url)
    fact_text = parse_fact(fact_json)
    return fact_text

api_flow("https://catfact.ninja/fact") 最初の引数を与えてフローを実行
  
```



タスク1の定義



タスク2の定義


関数を引数でつなげる形  
で、タスク1→タスク2の  
フローを定義

## Prefect (Open source版Apache-2.0)

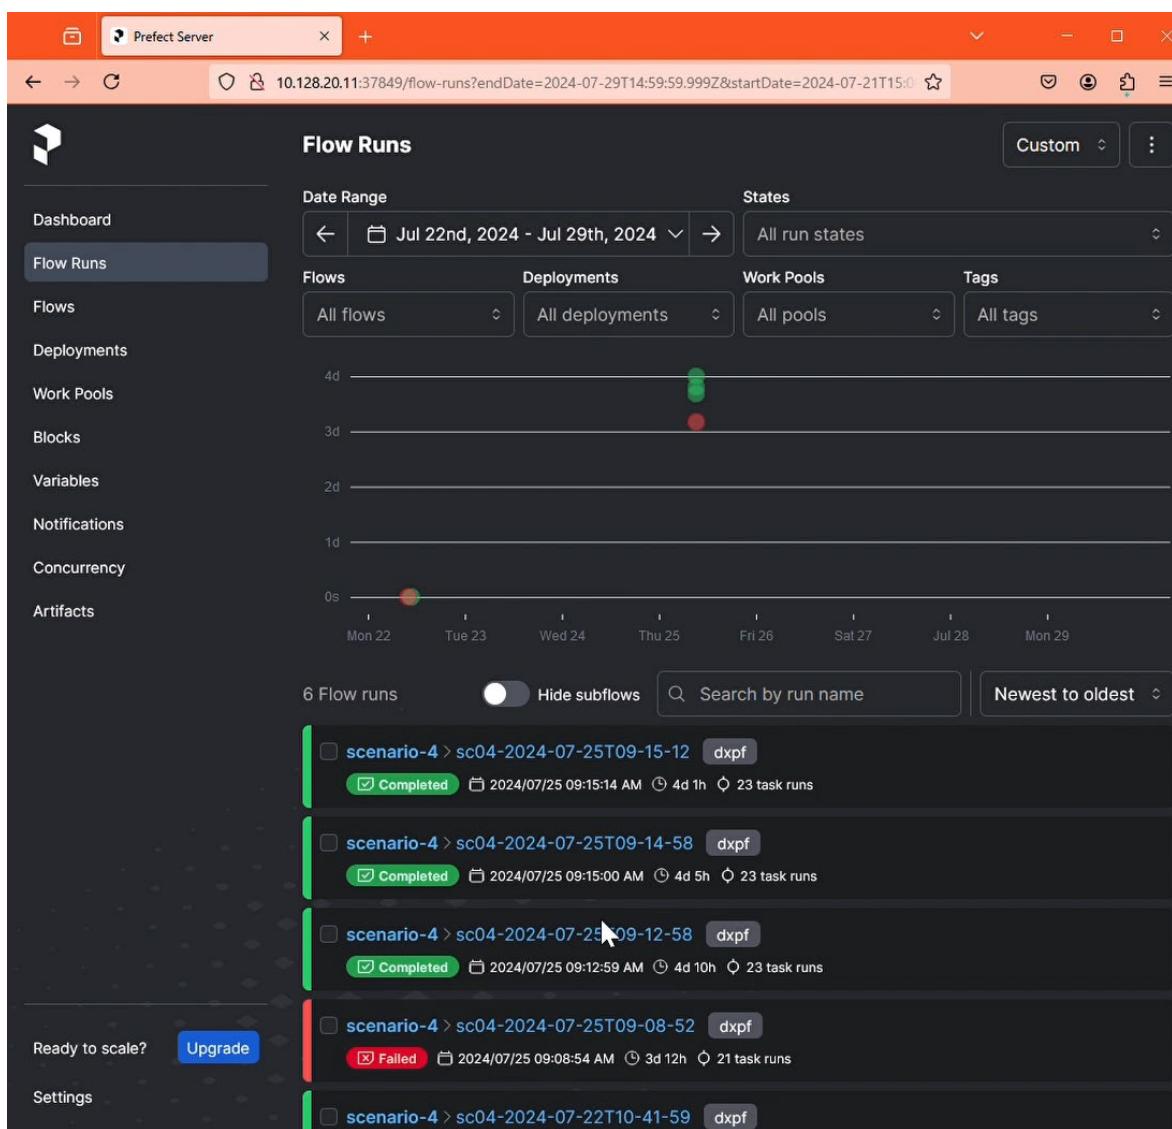
- 個別の機能をもった処理（タスク）を、フローとして複数つなげて実行するワークフローエンジン。全体として複雑なデータ処理を実現
- ワークフローエンジンとしてワークフローを効率的に実行する機能を提供する
  - 実行状況のモニタリング
  - タスクで発生したエラーの処理。
  - 保持した実行結果（キャッシュ）を利用した再実行
  - タスク間でのデータの受け渡しなど
- 「富岳」へのジョブ投入も可能
- GUIでフローに操作を加える場合は画面を構築する必要あり
- Prefect のPrefectの全体像やコンセプト、詳細<https://docs.prefect.io/latest/>
- Prefect には、Open source 版とCloud 版の二つのバージョンがある。
- 今回はOpen source版を利用。そのため、自前でサービスの立ち上げ・保守を実施する必要あり。

# フロー例：単純なドッキング

- 標的タンパク質分子に対して、
- 指定した化合物のドッキングを行い、
- 医薬品候補化合物の絞り込みを行う

# 計算 (原因不明で) 失敗した場合

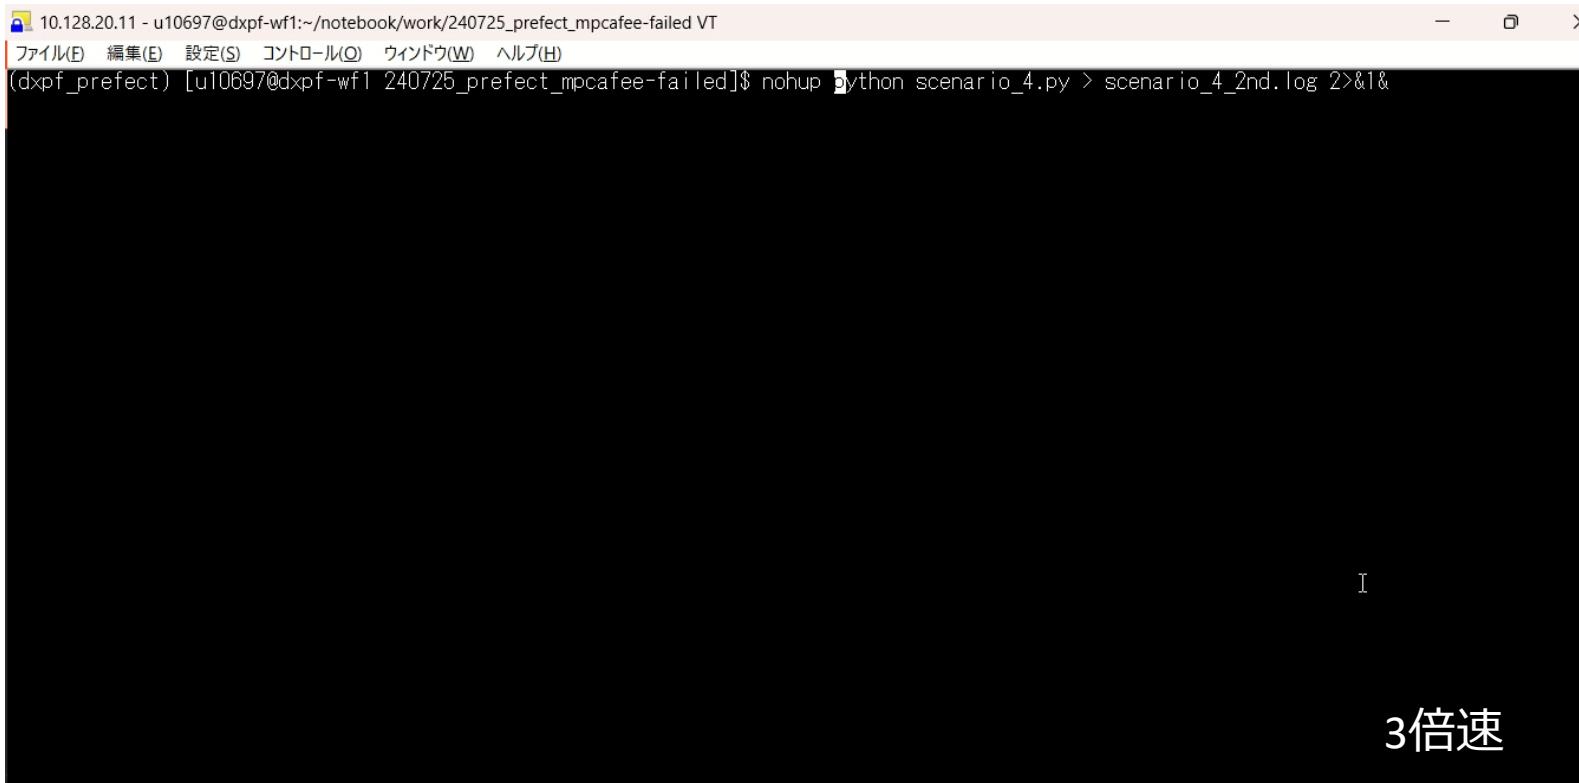
## タンパク質-医薬品候補化合物の間の結合力 ( $\Delta G$ ) 計算 : MP-CAFEE



候補化合物分実行 (10~100フロー)

- 多数のジョブの同時実行していると何らかのエラーで失敗することも多い
  - 例えば、通信切断、ほかユーザーの影響、一時的メモリ不足、原因特定困難（宇宙線...？）...

- まずはやり直してみる。
  - 各タスクの入出力は「ファイル渡し」になっているものが多い。また、各タスクの実装として、必要ファイルの存在有無でそのタスクの実行必要性を判定するように実装。
  - やり直しでダメなら入力ファイルなどを確認する。



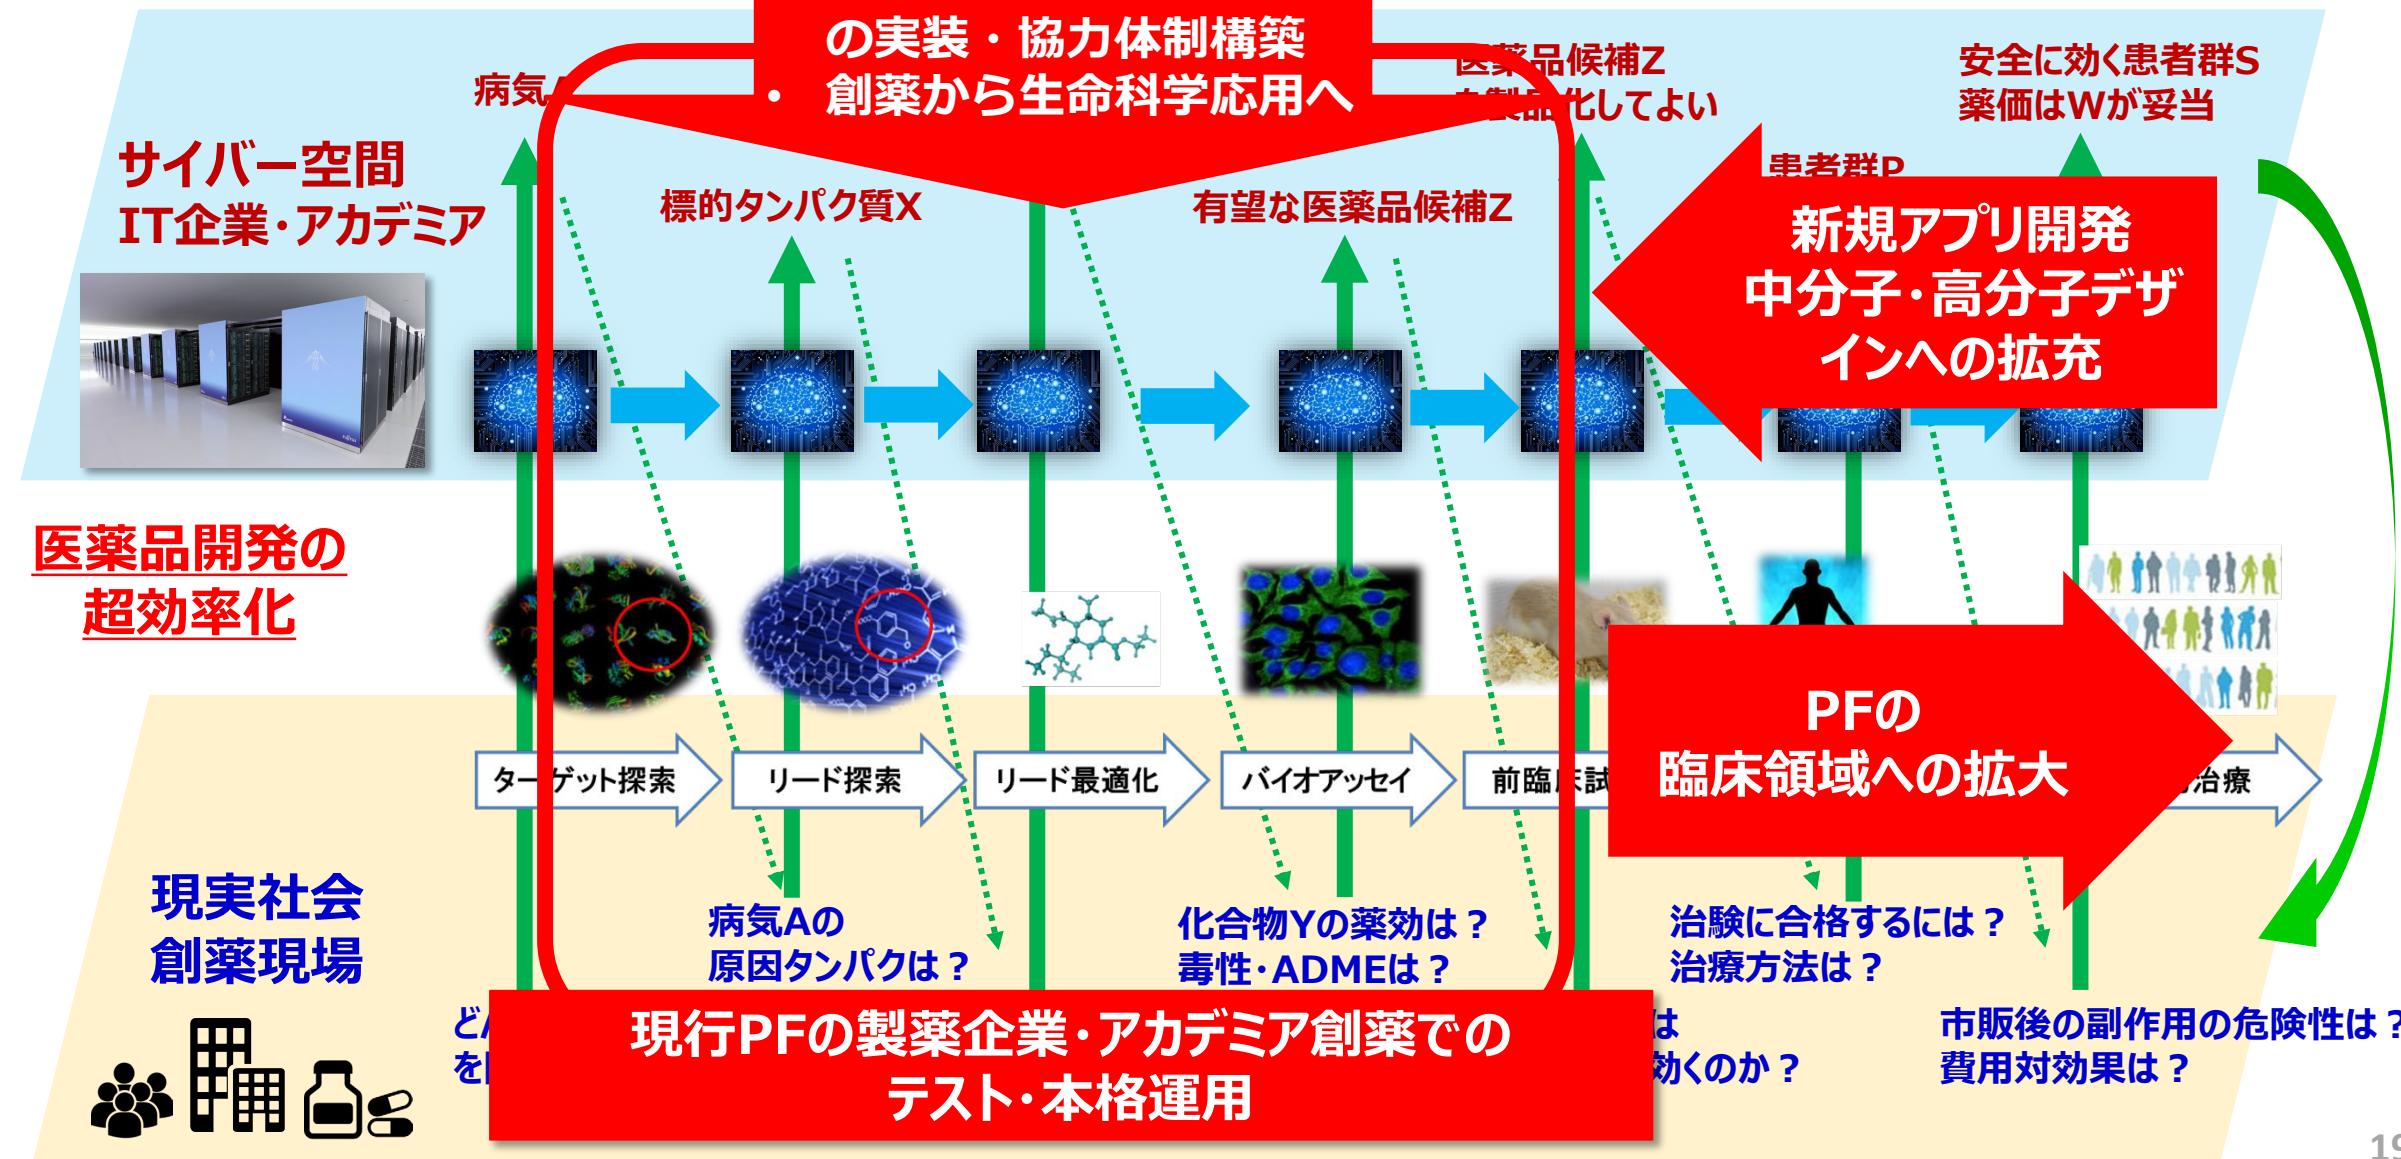
```
10.128.20.11 - u10697@dxfwf1:~/notebook/work/240725_prefect_mpcafee-failed VT
ファイル(F) 編集(E) 設定(S) コントロール(Q) ウィンドウ(W) ヘルプ(H)
(dxpf_prefect) [u10697@dxfwf1 240725_prefect_mpcafee-failed]$ nohup python scenario_4.py > scenario_4_2nd.log 2>&1&
```

3倍速

※そもそも「大量化合物→有望化合物への絞り込み」のような利用シーンでは、多少の失敗やエラーが起きてても無視して別の化合物の処理を進めるように実装

# 今後の展開

AIとシミュレーションを融合させた革新的な創薬DXプロトコームを構築し、創薬プロセスの超効率化を目指す。これにより、新薬やワクチン開発の実現度を大幅に高め、社会貢献度を実現する。



# 外部資金

- MEXT「富岳」Society 5.0推進利用課題 (hp220284、hp230189)
- MEXT「富岳」成果創出加速プログラム「「富岳」で目指すシミュレーション・AI 駆動型次世代医療・創薬」(JPMXP1020230120、hp230216)
- AMED 創薬支援推進事業・産学連携による次世代創薬AI開発 (DAIIA) JP22nk0101111