

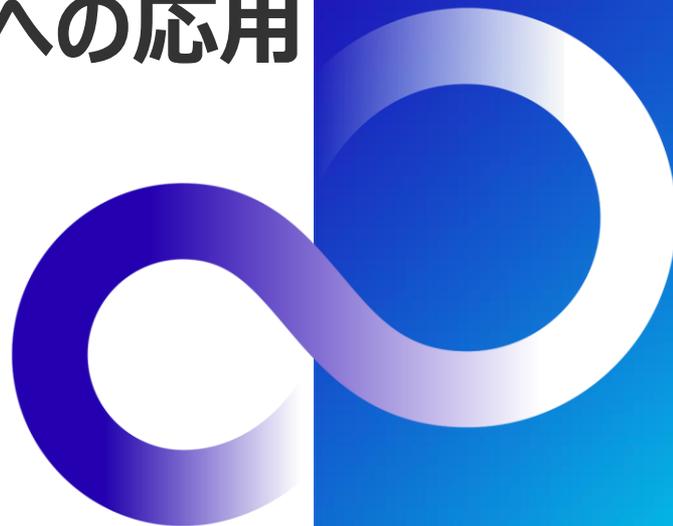
HPC技術とAIおよび量子計算への応用

HPC Technology and its Application to AI and Quantum Computation

2023.4.19

富士通株式会社

中島 耕太



5 Key Technologies

技術を組み合わせて信頼のある質の高いデータを生み、信頼のある新たな価値を提供



Fujitsu
UVance



Converging Technologies

人文社会科学との融合



Data & Security

分散型トラスト



AI

人と創造的にコラボレーション



Network

超高速ネットワーク/エッジコンピューティング



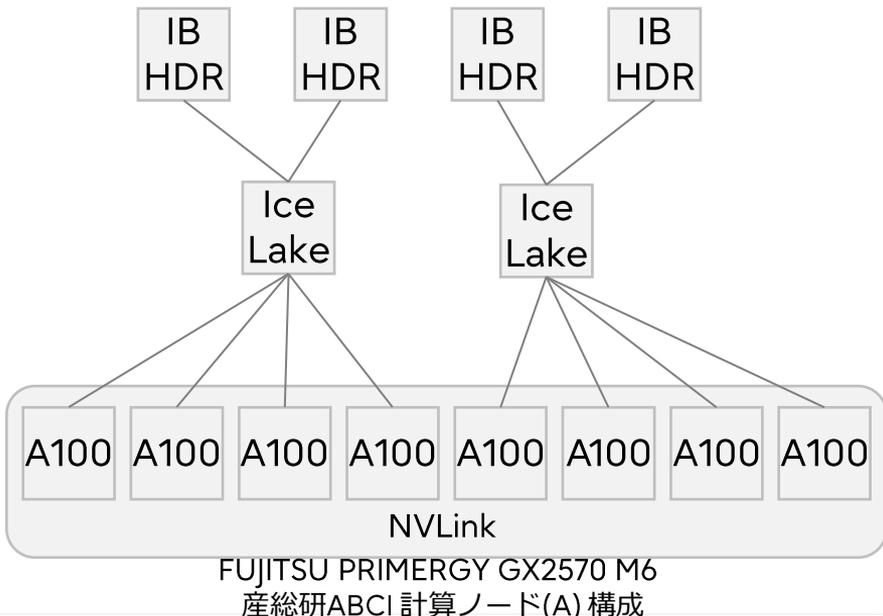
Computing

民主化された超スケールの
コンピューティングパワー

コンピューティングは新たな価値創造・高度な意思決定を支えるベースの技術

- GPU cluster

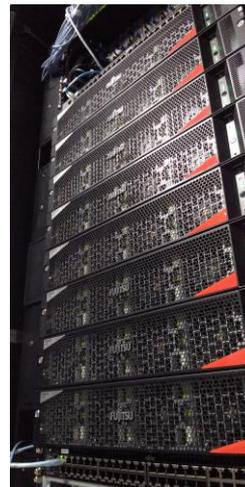
- 産総研ABCI



日本語自然言語モデル (LLM)

- CPU(Arm) cluster

- 「富岳」, FX1000, FX700 cluster

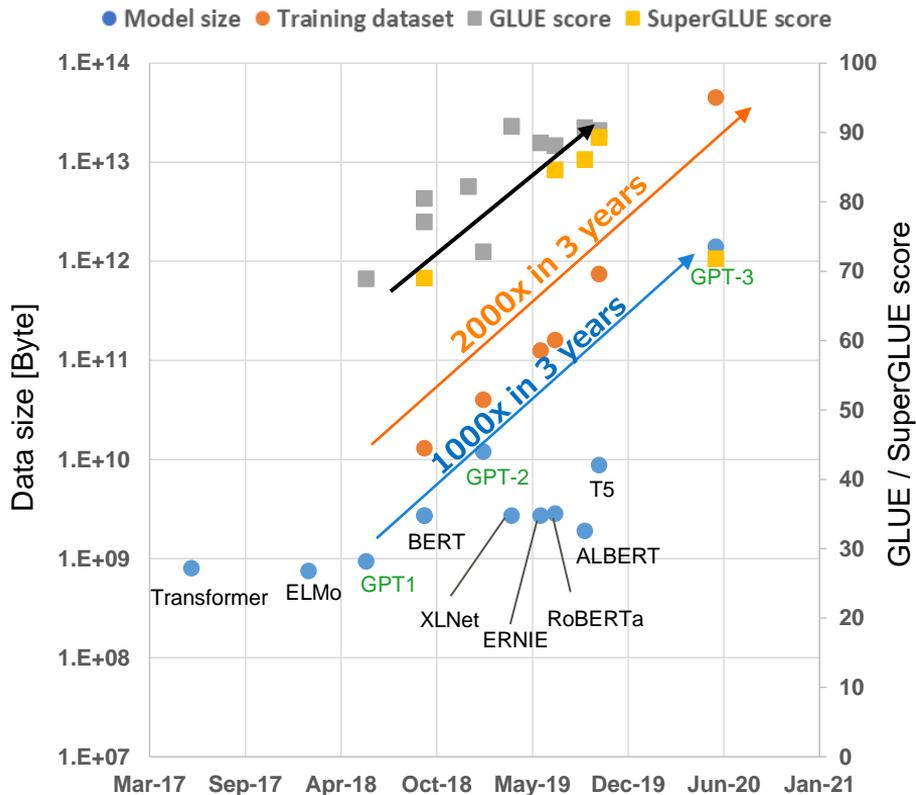


FX700 cluster (64 nodes): Todoroki

大規模因果発見・量子シミュレータ
(Large-scale casual discovery, Quantum simulator)

大規模並列計算技術を活用した 日本語自然言語モデル学習

Japanese LLM training using large-scale parallel computing technologies



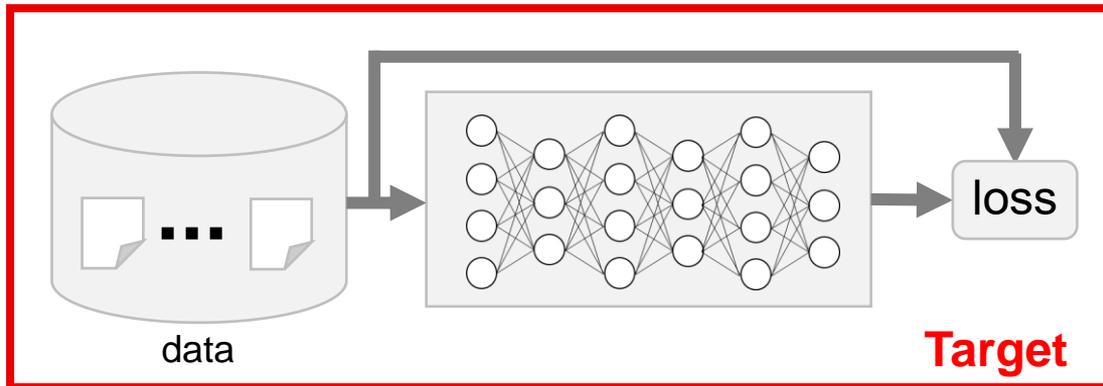
● AIワークロードが求める計算量

- モデルサイズ
- データセット
- 精度

自然言語モデルはより高い
計算パワーを必要とする

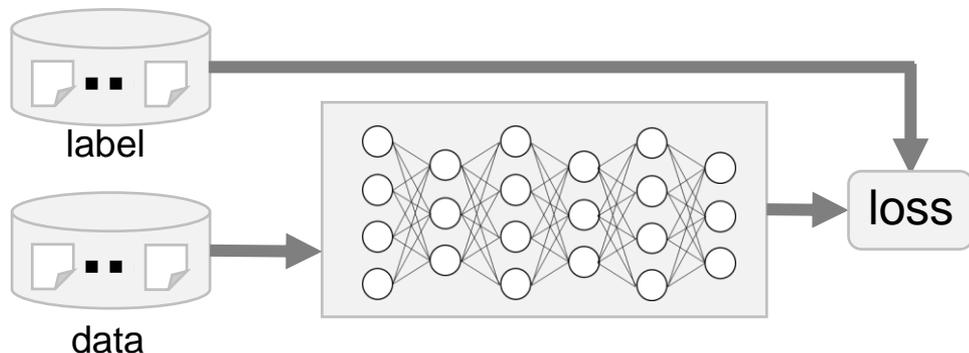
● 事前学習 (Pre-training)

- 自己教師あり学習
- 大量のデータ
- **非常に長い計算時間**



● ファインチューニング

- 実際の解きたい課題に合わせ込む
 - 教師あり学習
- 比較的少ないデータ量
- 計算時間も比較的短い



- 精度(validation loss)
 - **モデルの大規模化により精度は向上**
 - **アルゴリズム的工夫(Random Data Packing)は精度向上に大きく寄与**
- BERT-3.9bの場合に最大精度を達成

Trial #	Model	Batch size	Data packing	# of GPUs	Consumed samples	Iterations	Validation loss	Execution time [hour]
(i)	BERT-large	1,280	No	64	128,000,000	100,000	1.841	7.26
(ii)	BERT-xlarge	1,024	No	128	102,400,000	100,000	1.717	13.44
(iii)	BERT-xlarge	1,024	Yes	128	102,400,000	100,000	1.482	13.62
(iv)	BERT-xlarge	6,144	Yes	768	184,320,000	30,000	1.422	4.65
(v)	BERT-3.9b	1,536	Yes	768	122,880,000	80,000	1.349	17.52

ファインチューニング後の精度検証

- 公開されている他のモデルより高い精度を達成

- Twitter RAでは4.65時間の事前学習で、最高精度を達成
- JSNLIでは、BERT-3.9bによって最大精度を達成

JSNLI: 自然言語推論の標準的ベンチマークSNLIの日本語版。前提文に対して仮説文が与えられたときに、含意、矛盾、どちらでもないを推測する問題。
Twitter RA: Twitter日本語評判分析。判別する分が「ポジティブ」「ネガティブ」「ポジティブ&ネガティブ」「ニュートラル」を推測する問題。

Model	Parameter	JSNLI	Twitter RA	Pre-train time [hour]	# of GPU
Our BERT-large	0.6 billion	93.18 %	89.66 %	7.26	128
Our BERT-xlarge	1.2 billion	94.08 %	90.63 %	4.65	768
Our BERT-3.9b	3.9 billion	94.30 %	90.27 %	17.52	768
NICT's BERT[1]	0.11 billion	93.26 %	89.45 %	-	
Shibata's BERT[2]	0.33 billion	93.00 %	89.28 %	-	

[1] NICT BERT [Online]. Available: <https://alaginrc.nict.go.jp/nict-bert>

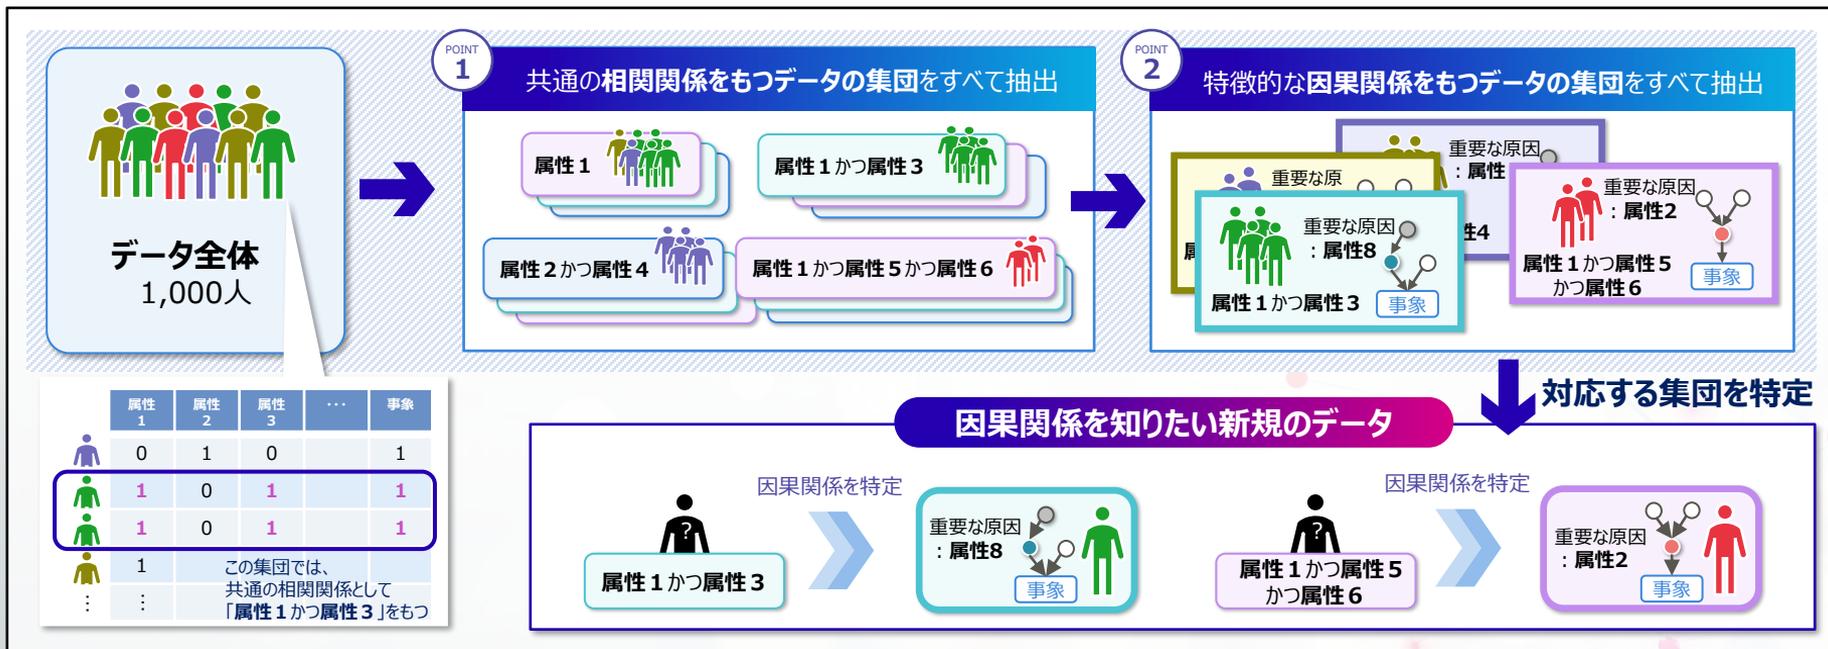
[2] T. Shibata, D. Kawahara, and S. Kurohashi. Kyoto University download BERT. [Online]. Available: https://nlp.ist.i.kyoto-u.ac.jp/?ku_bert_japanese

大規模並列技術により言語モデルを大規模化することで高い精度を達成

大規模因果探索による ゲノム医療での発見

Discovery for genome using large-scale casual
discovery technologies

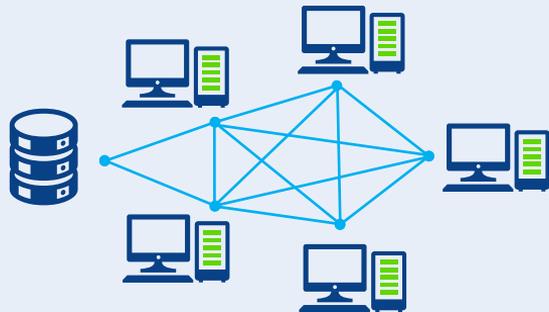
データ全体に共通する因果関係だけでなく、
個々のデータに特徴的な因果関係を網羅的に抽出可能に。



従来では数百変数に対する因果探索が限界だったが、
数万変数に対する因果探索が実行可能に。

大規模な因果探索のための処理の高速化

因果探索アルゴリズムの並列化



スーパーコンピュータ上での計算処理



スーパーコンピュータ「富岳」

事例

ゲノム医療への応用

薬剤耐性の原因究明

肺がんへの薬剤応答データから、
薬剤耐性メカニズムに関わる遺伝子関係を抽出。

- ヒトの全遺伝子（20000種類）に対して重要な因果関係を網羅的に抽出

従来技術では4000年かかっていた → 1日で完了

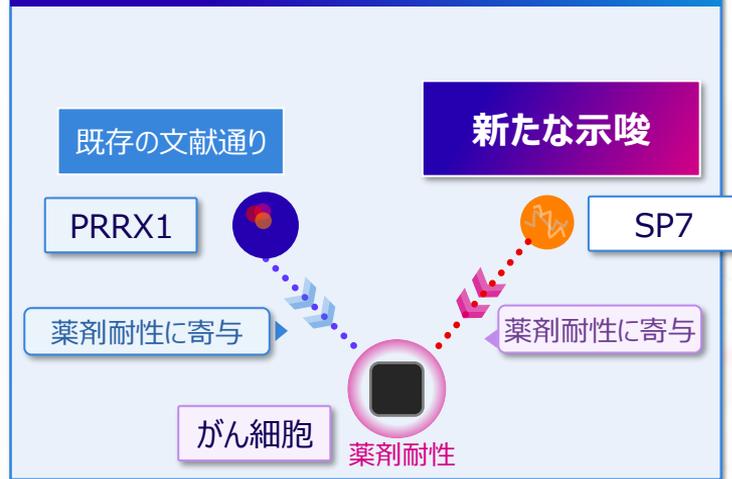
- 肺がんの治療薬として知られる「ゲフィチニブ」の耐性獲得メカニズムに関して、
専門家が認める新仮説の抽出に成功

共同研究：東京医科歯科大）宮野先生



スーパーコンピュータ「富岳」成果創出加速プログラム
「大規模データ解析と人工知能技術によるがんの起源と多様性の解明」 研究代表

因果関係の仮説と新発見の可能性

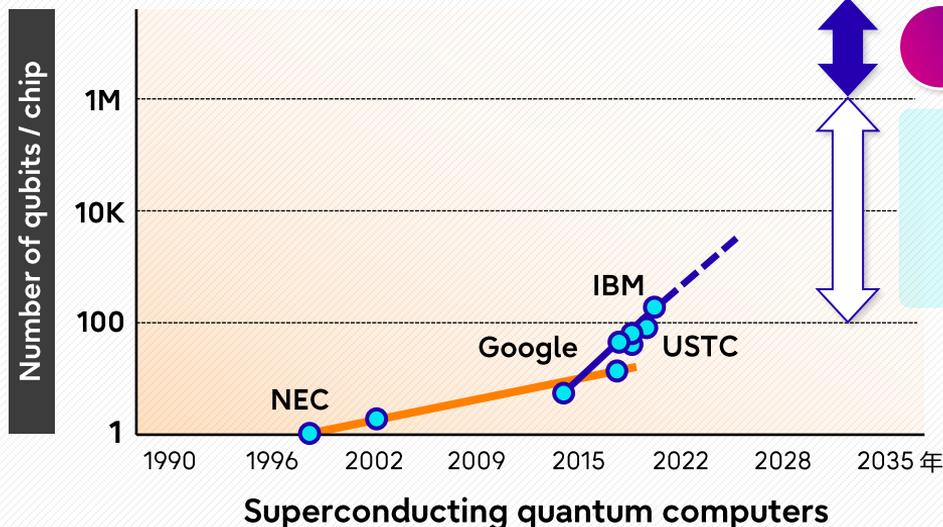


FX700/A64FXを活用した 量子シミュレータ高速化技術

High-speed Quantum Simulator accelerated by
FX700/A64FX

● エラーフリーで量子計算可能な量子シミュレータは研究開発に必須

- 100量子ビット級の実機（NISQ*）は実現され始めたが、誤り耐性量子計算はまだ先
- NISQはノイズが多く、量子アルゴリズムなどの理論的な研究開発での利用は困難



誤り耐性量子コンピュータ (100万量子ビット以上)

NISQ* コンピュータ
限定アプリケーションでの有用性に期待

*NISQ : Noisy Intermediate-Scale Quantum

“ 1000論理量子ビットを持つ本格的量子コンピュータの実現には、数百万物理量子ビットが必要になるかもしれない

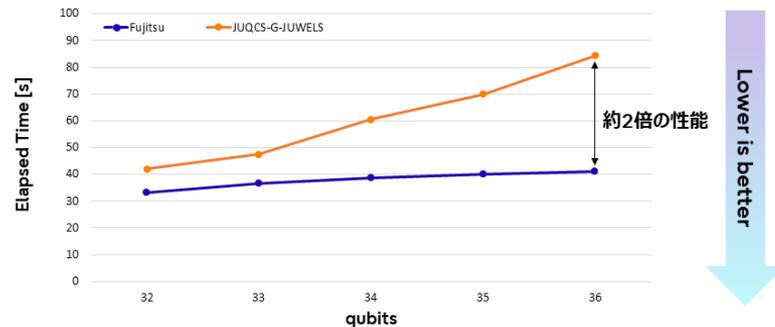
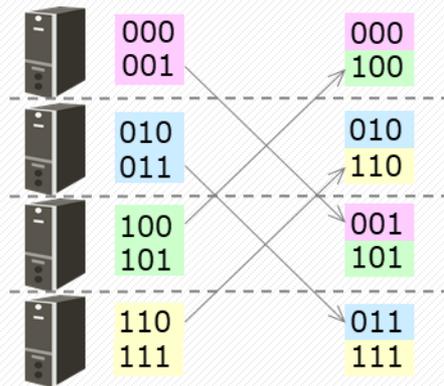
Adrian Cho, Science, 2020/7/9

●スーパーコンピュータ「富岳」のプロセッサA64FXの高速性を活かし、世界最速レベルの36量子ビットの量子シミュレータを開発 (2022.3)

- 他機関の主要な量子シミュレータの約2倍の性能を実現し、世界最高の処理速度を達成。
これにより、例えば丸一日かかっていた計算が夜間だけで済むようになり、研究開発サイクルの飛躍的な効率化が可能に
- 量子シミュレータを活用して量子アプリケーションを先行開発。富士フイルム様と材料分野で共同研究を開始
- 9月には、39量子ビットのシミュレータ(512ノード)へ拡大済み、2023年春には40量子ビット(1,024ノード)へと拡大予定

量子計算に合わせた データ再配置技術

量子計算の実行順序に
合わせて並列計算機上の
データを再配置して
通信時間を削減



JUQCS(GPU向けシミュレータ)と比較し、最大約2倍の速度を実現

● 富士通の大規模並列コンピューティング技術を活用

技術①

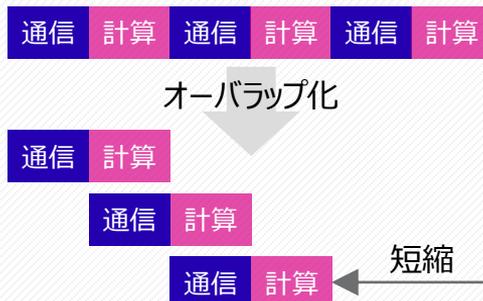
A64FXの性能を引き出す実装技術



複数の計算を同時実行するSVE命令を活用し
最大限のメモリ帯域を引き出す

技術②

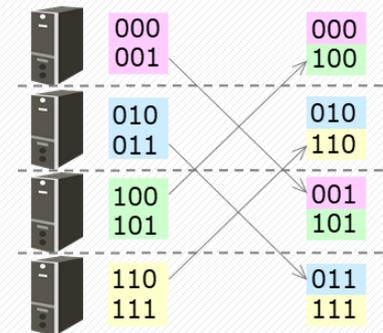
通信と計算のオーバーラップ化



通信と計算をオーバーラップさせることで
同時実行し、処理時間を削減

技術③

量子計算に合わせたデータ再配置技術



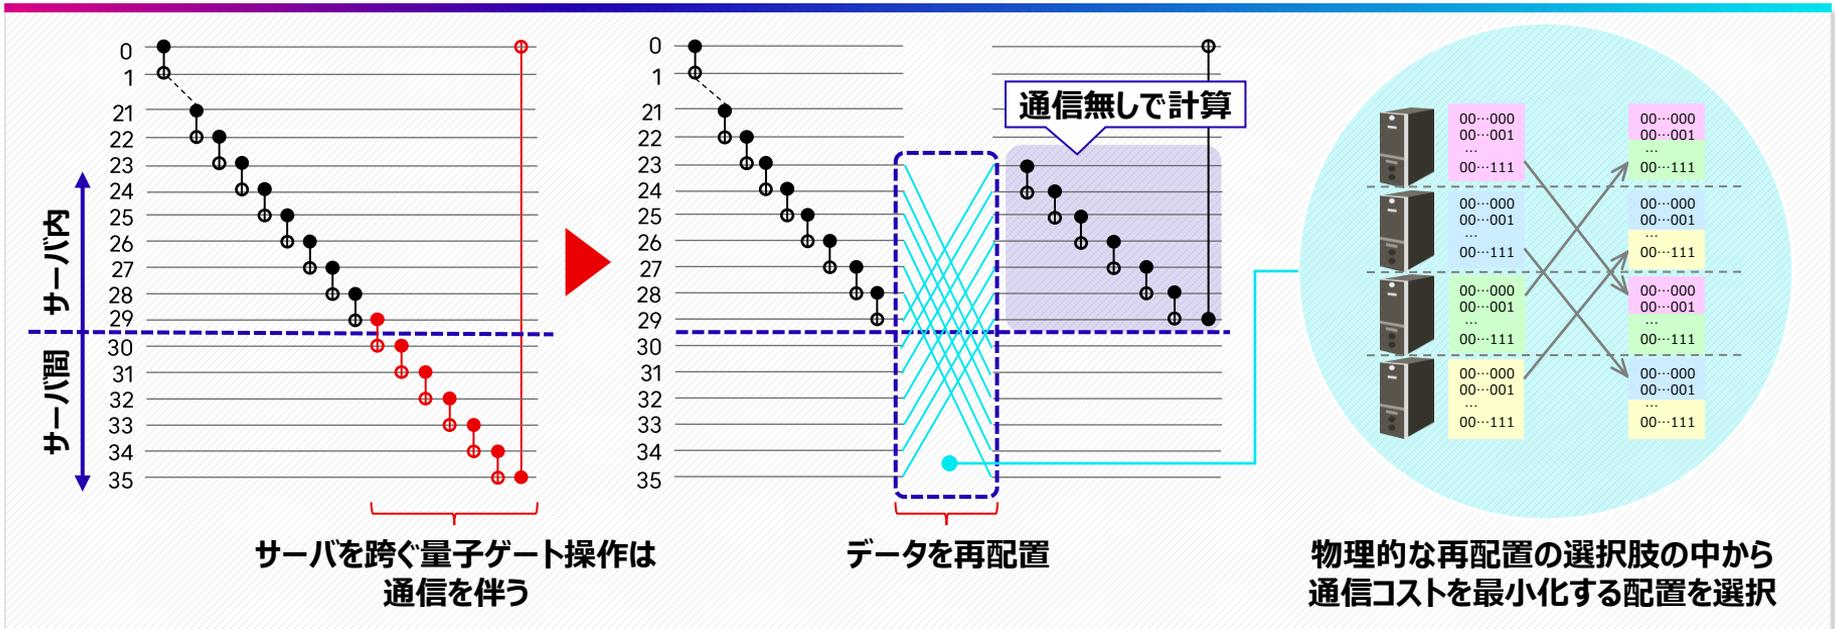
量子計算の実行順序に合わせて並列計算機上
のデータを再配置して通信時間を削減

64ノードのFX700を活用し、36量子ビットのシミュレータを実装

● 高速化の鍵は、新規開発の量子計算に合わせたデータ再配置技術*

- 例：2量子ゲートで代表的なCNOT操作
 - サーバを跨ぐ量子ゲート操作は毎回通信が発生
 - データを再配置し、量子ゲート操作の際の通信を削減

*今回は大阪大学開発の「Qulacs」を並列化用に改良し適用



● Shorのアルゴリズム

- 将来量子コンピュータが登場すると、暗号が破られるかもしれないと言われている計算
- 実機では、 $15 = 3 \times 5$ や $21 = 3 \times 7$ が検証されている最大例
- シミュレータでもあまり解かれていなかった

● 量子シミュレータを活用した素因数分解

- 汎用的なアルゴリズム実装で $N=15$ から $N=511$ まで(2^9 未満)の96個の素因数分解に成功
- データ再配置と回路最適化が高速化に大きく寄与し、 $N=253$ で10時間以上 → 306秒に

N	129	187	253	259	381	511
Qubits	34	34	34	38	38	38
Elapsed (s)	256	328	306	6,143	5,860	8,226

<https://pr.fujitsu.com/jp/news/2023/01/23.html>

<https://eprint.iacr.org/2023/092>

量子実機でも2,048ビット合成数分解は1万量子ビット+約104日RSA暗号は当面安全

- 大規模並列計算技術の応用
 - 自然言語モデルの学習
 - 大規模因果発見
 - 量子シミュレータ高速化

- コンピューティング技術による新領域開拓
 - AI技術は今後も膨大な計算量を必要とする
 - 量子技術も量子コンピュータ単体ではなくHPC技術との併用が実応用では重要に

並列計算技術が新たな領域を開拓

Thank you

