

Educational Research Foundation
ERF Research Companion Series No.1

Google DeepMind

From AGI to ASI

第4回

スケーリングだけで ASI に到達で きるのか

計算資源、モデル、データ、推論時間を拡大する第一の
経路

Publication Edition

Version 1.0

2026

目次

はじめに.....	3
第1節 四つの経路の中で、スケーリングが特別である理由.....	5
第2節 スケーリングとは何を増やすことなのか.....	6
第3節 なぜスケーリングがAIを進歩させてきたのか.....	9
第4節 しかし、計算量だけでは十分ではない.....	11
第5節 スケーリング則とは何か.....	12
第6節 大きなモデルを作ればよいわけではない.....	13
第7節 学習時の計算と推論時の計算.....	14
第8節 「学習済み知識」と「その場で考えること」.....	15
第9節 データの壁.....	16
第10節 テキスト以外のデータ.....	17
第11節 合成データはデータの壁を越えられるか.....	18
第12節 自己対戦が示す可能性.....	20
第13節 Mixture-of-Experts と効率的スケーリング.....	22
第14節 量的拡大から質的飛躍は起きるのか.....	23
第15節 スケーリングが効かない問題.....	25
第16節 一体のAIが賢くならなくても ASI になり得る.....	26
第17節 実効計算量とは何か.....	27
第18節 スケーリングを支える物理的条件.....	28
第19節 経済的にどこまで続けられるのか.....	29
第20節 限界効用の低下.....	30
第21節 スケーリングの中心的な未解決問題.....	31
ERF Commentary.....	32
第22節 AI のスケーリングと大学のスケーリングは異なる.....	32
第23節 大学教育における「より多く」と「より良い」.....	33
第24節 知識量よりも、選択と意味付けが重要になる.....	34
第25節 研究成果が大量生成される時代.....	35
第26節 スケーリングと知の集中.....	36
第27節 環境負荷と Ecological University.....	37
第28節 「大きいこと」と「賢いこと」は同じではない.....	38
結論.....	39

はじめに

Google DeepMind の『From AGI to ASI』は、AGI から ASI へ進む可能性のある技術的経路を、次の四つに整理しています。

1. 計算資源、モデル、データのスケーリング
2. AI のアルゴリズムや学習パラダイムの転換
3. AI による再帰的自己改善
4. 多数の AI エージェントによる集合知

これらは互いに排他的な経路ではありません。複数の経路が同時に進み、互いに強化し合う可能性があります。

その中で最初に扱われるのが、Scaling compute, models, and data——計算資源、モデル、データのスケーリングです。

これは現在の AI 発展に最も直接つながる経路です。

過去十年ほどの AI の急速な進歩は、主として、

- ・ より多くの計算資源を使う
- ・ より大きなモデルを訓練する
- ・ より多くのデータを与える
- ・ 推論時にも追加の計算を使う

ことによって実現してきました。

原報告書は、この延長によって AGI から ASI へ進める可能性を検討します。

しかし、この問いは単純ではありません。

計算量を増やせば、知能も増えるのでしょうか。

モデルを巨大化すれば、人間の大規模組織を超えられるのでしょうか。

量を増やし続ければ、いつか質的な飛躍が起きるのでしょうか。

それとも、データ、電力、半導体、費用、アルゴリズムの壁にぶつかるのでしょうか。

第4回では、この第一の経路を詳しく検討します。

第1節 四つの経路の中で、スケーリングが特別である理由

AGI から ASI への四つの経路のうち、スケーリングには一つの大きな特徴があります。

それは、過去のデータに基づいて、ある程度の予測モデルを作れることです。

アルゴリズム上の大発見がいつ起きるかは予測困難です。

AI が自ら AI 研究をどの程度加速するかについても、十分な歴史的 precedent がありません。

多数の AGI が形成する集合知についても、現在の実証的知識は限られています。

これに対してスケーリングについては、モデルのパラメータ数、学習データ量、計算量と性能の関係について、過去の実験結果があります。

そのため、四つの経路の中では唯一、過去の傾向を統計的に外挿できる経路です。

もちろん、過去の傾向が将来も続くとは限りません。

それでも、少なくとも予測の出発点となるデータが存在します。原報告書は、この点でスケーリング経路を、他の三経路より予測可能性が高いものとして位置付けています。（原報告書、Section 5.1）

第2節 スケーリングとは何を増やすことなのか

AIにおけるスケーリングは、単にモデルのパラメータ数を増やすことではありません。

少なくとも次の五つを区別する必要があります。

2.1 学習計算量

モデルを訓練するために使用する計算量です。

より多くの計算を使えば、

- より大きなモデルを訓練する
- より多くのデータを処理する
- より長く訓練する
- より複雑な学習方法を使う

ことができます。

2.2 モデル規模

一般には、ニューラルネットワークが持つパラメータ数や内部構造の規模を指します。

モデルが大きくなると、より複雑なパターンや知識を保持できる可能性があります。

ただし、大きいモデルが常に効率的とは限りません。

十分なデータや学習計算量がなければ、大きなモデルでも十分に訓練されず、性能を発揮できないことがあります。

2.3 データ量とデータ品質

学習に使用する文章、画像、音声、映像、コード、行動記録、科学データなどです。

量だけでなく、

- 正確性

- 多様性
- 難易度
- 重複の少なさ
- 現実との対応
- 学習目的との関連性

が重要です。

2.4 推論時の計算量

モデルを訓練した後、実際の問題に答える際に使用する計算量です。

これは test-time compute または inference-time compute と呼ばれます。

AI に即答させるのではなく、

- 長く考えさせる
- 複数の解答候補を生成させる
- 自己検証させる
- 探索を行わせる
- 外部ツールやシミュレーションを使わせる

ことで、同じモデルでもより高い能力を引き出せます。

2.5 稼働する AI の個体数

同じモデルを一体だけ動かすのではなく、数千、数百万、数億のコピーを同時に動かす方法です。

これは個々のモデルの知能を高めるわけではありません。

しかし、集団全体の問題解決能力を高める可能性があります。

原報告書は、この問題を第一経路のスケーリングと第四経路のマルチエージェント集合知の接点として扱っています。（原報告書、Section 5.1）

第3節 なぜスケーリングがAIを進歩させてきたのか

過去のAI研究では、研究者が人間の知識をルールとして細かく書き込む方法が重視されていました。

たとえば、チェスAIであれば、

- この局面では駒を中央に置く
- キングを安全にする
- ポーン構造を守る

といった人間の知識をプログラムに組み込む方法です。

しかし、長期的に大きな成果を上げたのは、人間がルールを細かく記述する方法よりも、

- 大量の計算
- 探索
- 学習
- 自己対戦
- 一般的なアルゴリズム

を使う方法でした。

この考え方は、強化学習研究者 Richard Sutton の The Bitter Lesson として知られています。

その中心的な教訓は、長期的には、人間が作り込んだ知識よりも、計算量の増加を利用できる一般的方法の方が大きく進歩するというものです。

『From AGI to ASI』は、この教訓をスケーリング経路の重要な根拠として挙げています。

もし知能の中心に探索があるなら、

- 学習とは、モデルや仮説の空間を探索すること
- 計画とは、可能な未来を探索すること

- 推論とは、解答候補を探索すること

と捉えられます。

その場合、計算量を増やすことは、より広く、より深く探索することを可能にし、知能の向上につながるかもしれません。（原報告書、Section 5.1）

第4節 しかし、計算量だけでは十分ではない

原報告書は、「計算量を増やせば知能が自動的に増える」という単純な見方を採用していません。

力ずくの探索は、ほとんどの現実的な問題では機能しないからです。

たとえば、チェスには膨大な数の可能な局面があります。

すべての手を最後まで調べることはできません。

現実世界の科学、政策、経営、医療は、チェスよりもはるかに複雑です。

したがって、能力向上には計算量だけでなく、探索効率が必要です。

具体的には、

- ・ 重要な可能性を優先する
- ・ 不要な選択肢を早く捨てる
- ・ 有望な仮説を推定する
- ・ 問題をより小さな部分に分解する
- ・ 近似モデルを使う
- ・ 過去の経験を事前知識として利用する

といった仕組みです。

チェス AI が強いのは、単に多くの局面を調べるからではありません。

どの局面を重点的に調べるべきかを、評価関数や学習済みモデルによって選べるからです。

原報告書は、この点から、計算量と知能の関係は単純な比例ではないと指摘します。

より多くの計算を、有効な探索へ変換するアルゴリズムが必要なのです。（原報告書、Section 5.1）

第5節 スケーリング則とは何か

近年の大規模 AI モデルでは、モデル規模、データ量、計算量を増やすと、性能が比較的規則的に向上することが観測されてきました。

この関係は、しばしば *scaling laws*——スケーリング則と呼ばれます。

一般には、計算量を一定倍率で増やすと、損失や誤差が一定の規則に沿って減少するという、べき乗則に近い関係が観測されます。

これは重要です。

なぜなら、AI 性能が完全に不規則に変化するのではなく、一定範囲では予測可能であることを意味するからです。

たとえば、

- 計算量を 10 倍にしたとき、性能がどの程度改善するか
- データ量を増やしたとき、どの程度誤差が減るか
- モデルを大きくしたとき、どの程度能力が向上するか

を推計できる可能性があります。

原報告書は、過去の AI 性能が、パラメータ数、データ量、計算量に対して、おおむね予測可能で連続的なスケーリングを示してきたと説明します。

ただし、この傾向が AGI 以後も持続するかどうかは未解決です。（原報告書、Section 5.1）

第6節 大きなモデルを作ればよいわけではない

モデル規模だけを大きくすれば性能が上がる、という考え方には限界があります。

大きなモデルには、それに見合う量のデータと学習計算量が必要です。

モデルだけを大きくし、十分に訓練しなければ、計算資源を効率的に利用できません。

この点を示した代表的な研究が、Google DeepMind の Chinchilla 研究です。

Chinchilla は、より大きい十分に訓練されていないモデルよりも、モデル規模を抑えながら、より多くのデータで訓練したモデルの方が優れた性能を示し得ることを明らかにしました。

つまり、重要なのは最大のモデルを作ることではなく、

- モデル規模
- データ量
- 学習計算量

を適切な比率で拡大することです。

これを compute-optimal scaling——計算量最適なスケーリングと呼びます。

原報告書は、AGI から ASI へのスケーリングも、単なる巨大化ではなく、モデル、データ、計算資源を協調して増やす必要があると論じています。（原報告書、Section 5.1）

第7節 学習時の計算と推論時の計算

従来の AI スケーリングでは、主として学習時の計算量が注目されてきました。

一度巨大なモデルを訓練し、利用時には一回の前向き計算で答えを出すという考え方です。

しかし、近年は推論時の計算量が重要になっています。

同じモデルでも、問題に応じて長く考えさせれば、より良い答えを出せることがあります。

推論時スケーリングには、次のような方法があります。

- 思考過程を段階的に展開する
- 複数の候補を生成して比較する
- 解答を批判・修正する
- 木構造やグラフ構造で探索する
- コードを実行して検証する
- 数学ソフトや検索ツールを使う
- シミュレーションを行う
- 別の AI に評価させる

この方法では、すべての問題に最大の計算量を使う必要はありません。

簡単な問題には少ない計算を使い、難しい問題には大量の計算を割り当てられます。

これは人間にも似ています。

簡単な質問には即答しますが、難しい研究課題には数日、数か月、数年をかけます。

原報告書は、モデル規模を過度に大きくすると、一回の推論自体が高価になるため、推論時スケーリングに使える計算資源が減る可能性にも言及しています。

そのため、将来はモデルの巨大化だけでなく、

適度な規模のモデルに、必要に応じて大量の推論計算を与える

方向が重要になる可能性があります。（原報告書、Section 5.1）

第8節 「学習済み知識」と「その場で考えること」

AI の能力には、大きく二つの形があります。

学習済みの能力

過去の訓練によって、モデル内部に圧縮された知識や技能です。

これは人間でいえば、長期記憶、専門知識、経験、直感に近いものです。

推論時に生成される能力

与えられた問題に対し、その場で探索、計画、検証を行う能力です。

これは人間が難問について時間をかけて考えることに近いものです。

一度大量の計算を使って見つけた有効な解法は、後の学習によってモデル内部に取り込める可能性があります。

つまり、

5. 推論時に多くの探索を行う
6. 良い解答や行動を発見する
7. その結果を学習データとして使う
8. 次世代モデルが、より少ない計算で同じ能力を示す

という循環が考えられます。

これは、後に扱う再帰的自己改善ともつながります。

推論時の計算によって得た成果を、次のモデルの事前知識へ圧縮できれば、計算と学習が相互に能力を高めるからです。

第9節 データの壁

スケーリングを継続するうえで、最も分かりやすい制約の一つがデータです。

現在の大規模言語モデルは、インターネット、書籍、論文、コード、ニュース、会話など、大量の人間生成データを利用して訓練されています。

しかし、高品質な人間生成テキストは有限です。

同じデータを繰り返し使っても、常に同じ効果が得られるわけではありません。

低品質な文章、重複した文章、誤情報を増やせば、モデルの性能を損なう可能性もあります。

原報告書は、現在の傾向が続けば、高品質な自然言語テキストの供給が近い将来に制約となる可能性を指摘しています。

さらに、AGI から ASI へ進むためには、人間がすでに生成した文章を学ぶだけでは足りない可能性があります。

人間の知識全体を学習しても、それは人間の知的到達点を圧縮したものだからです。

人間を大幅に超えるには、人間の既存知識を再現するだけでなく、新しいデータ、新しい経験、新しい発見を生み出す必要があります。（原報告書、Section 5.1）

第10節 テキスト以外のデータ

データの壁は、テキストデータだけを考えた場合の問題でもあります。

世界には、まだ十分活用されていない多様な情報があります。

- 画像
- 映像
- 音声
- 科学観測データ
- 医療データ
- ロボットの行動記録
- センサーデータ
- 衛星データ
- 遺伝情報
- 化学実験
- 産業設備の稼働記録

マルチモーダル AI は、これらを統合することで、人間の言語に明示的には記録されていない世界の構造を学べる可能性があります。

特に、物理世界で行動する AGI には、文章だけでなく、

- 行動すると何が起こるか
- 物体はどのように動くか
- 現実の環境にはどのような因果関係があるか

という経験が必要です。

しかし、テキスト以外のデータを増やせば問題がすべて解決するわけではありません。

データの収集、整理、権利処理、安全な利用には多額の費用と時間がかかります。

また、センサーデータが大量にあっても、そこから有用な概念や因果関係を学習できるとは限りません。

第 11 節 合成データはデータの壁を越えられるか

人間生成データが有限なら、AI 自身に訓練データを作らせる方法が考えられます。

これが synthetic data——合成データです。

たとえば AI に、

- 数学問題を作らせる
- プログラミング課題を作らせる
- 模擬会話を生成させる
- 科学的シミュレーションを行わせる
- 自己対戦させる
- 複数の解法を生成して評価させる

ことができます。

合成データには大きな可能性があります。

人間が一つずつ教材や問題を作るよりも、はるかに大量に生成できるからです。

しかし、危険もあります。

現在のモデルが生成したデータをそのまま次世代モデルへ学習させると、

- 誤りが蓄積する
- 多様性が失われる
- もっともらしい虚偽が増える
- 元のデータ分布から離れていく
- モデル自身の偏りを反復する

可能性があります。

これはモデル崩壊やデータ汚染と呼ばれる問題につながります。

原報告書は、現在の AI では合成データによる退化の危険がある一方、AGI レベルのシステムでは事情が変わる可能性を指摘します。

AGI が、

- 高精度なシミュレーション
- 探索に基づく問題生成
- 検証可能な数学やコード
- インタラクティブな環境
- 実験結果による評価

を利用できれば、人間生成データを超える高品質なデータを生み出せるかもしれません。

(原報告書、Section 5.1)

第12節 自己対戦が示す可能性

合成データの有効性を示す代表例が、AlphaGo や AlphaZero の自己対戦です。

囲碁やチェスでは、AI は人間の棋譜だけに依存する必要がありません。

自分自身と対戦し、

- ・ 新しい局面を生成する
- ・ 良い手と悪い手を評価する
- ・ より強い戦略を発見する
- ・ その成果を次の学習に使う

ことができます。

この方法により、人間が過去に考えた戦略を超えることが可能になりました。

ただし、囲碁やチェスには明確な利点があります。

- ・ ルールが明確
- ・ 勝敗が明確
- ・ シミュレーションが正確
- ・ 一局を短時間で大量に生成できる

という点です。

科学研究や社会問題では、正解が簡単には分かりません。

医療政策が良かったかどうかは、数年後にしか分からないかもしれません。

教育の成果は、試験点数だけでは評価できません。

したがって、自己生成データが有効かどうかは、

結果を信頼できる方法で検証できるか

に大きく依存します。

第13節 Mixture-of-Experts と効率的スケーリング

スケーリングには、単に全モデルを大きくする以外の方法があります。

その一例が、Mixture-of-Experts——専門家混合モデルです。

この構造では、一つの巨大なネットワークのすべてを毎回使用するではありません。

入力に応じて、必要な一部の専門モジュールだけを動かします。

たとえば、

- 数学の専門部分
- 言語の専門部分
- コードの専門部分
- 画像の専門部分

を持ち、課題に応じて必要な部分を選択する構造です。

これにより、モデル全体は非常に大きくても、一回の推論で使用する計算量を抑えられます。

原報告書は、Mixture-of-Experts を、計算効率を高め、スケーリングの余地を広げるアーキテクチャ上の革新例として挙げています。（原報告書、Section 5.1）

ただし、専門家混合モデルにも課題があります。

- どの専門モジュールを選ぶか
- 専門間で情報をどう統合するか
- 一部の専門家に負荷が偏らないか
- 全体の一貫性をどう保つか

という問題です。

それでも、モデル全体を毎回動かさずに容量を拡大できる点で、重要なスケーリング技術です。

第 14 節 量的拡大から質的飛躍は起きるのか

スケーリングをめぐる最大の問いは、

量を増やすだけで、質的に新しい知能が現れるのか。

というものです。

モデルを大きくすると、性能が少しずつ滑らかに向上するだけなのでしょうか。

それとも、ある規模を超えたとき、

- 推論
- 計画
- 抽象化
- ツール利用
- 一般化
- 自己評価

のような新しい能力が突然現れるのでしょうか。

近年、一部の AI 能力について、モデル規模が一定水準を超えると急に能力が現れるという emergent abilities——創発的能力が議論されてきました。

しかし、原報告書は慎重です。

一見すると突然の飛躍に見える現象でも、

- 評価指標の設計
- 合否を二値で測る方法
- ベンチマークの飽和
- 測定間隔の粗さ

によって、不連続に見えているだけかもしれないからです。

たとえば、正答率が 49% から 51% へ滑らかに上昇したとしても、「50% 以上を合格」と設定すれば、ある時点で突然能力が現れたように見えます。

したがって、真の質的飛躍と、測定上の見かけを区別する必要があります。（原報告書、Section 5.1)

第 15 節 スケーリングが効かない問題

すべての問題が計算量の増加によって容易になるわけではありません。

特に、計算複雑性が高い問題では、問題規模が少し増えただけで、必要な計算量が爆発的に増えることがあります。

原報告書は、NP 困難問題のような問題を例に、単純な計算量の増加だけでは不十分な場合があると指摘します。

このような問題では、

- 優れた近似
- 問題構造の発見
- ヒューリスティック
- 分解方法
- 特殊な表現
- 新しいアルゴリズム

が必要です。

つまり、スケーリングは一部の問題には非常に有効でも、別の問題には限界があります。

ここから、第一経路と第二経路の関係が見えてきます。

スケーリングが限界に近づけば、アルゴリズムやアーキテクチャのパラダイム転換が必要になる可能性があります。

第 16 節 一体の AI が賢くならなくても ASI になり得る

原報告書の重要な指摘は、ASI への移行には、必ずしも一体の AI が人間をはるかに超える必要はないということです。

仮に個々の AGI が人間レベルで能力向上を止めたとしても、

- 数百万体
- 数億体
- 数十億体

を同時に稼働させることができれば、集合体として大規模な人間組織を超える可能性があります。

しかも AI には、

- 24 時間稼働できる
- 高速に複製できる
- 記憶を共有できる
- 同じ課題を大量に並列処理できる
- 異なる専門に分化できる

という特徴があります。

一体の AGI が平均的な人間程度でも、数百万体を高速で稼働させれば、社会全体としては超人的能力を持つ可能性があります。

原報告書はこの点から、中心的な問いは、

スケーリングだけで ASI が可能か。

ではなく、

ASI に到達するまで、経済的・技術的・自然的資源のスケーリングを持続できるか。

である可能性を指摘しています。（原報告書、Section 5.1）

第 17 節 実効計算量とは何か

計算能力を考えると、単純なハードウェア性能だけを見るのは不十分です。

重要なのは effective compute——実効計算量です。

実効計算量は、概念的には次の要素から成ります。

- 半導体の処理性能
- データセンターの規模
- 使用可能な電力
- アルゴリズム効率
- ソフトウェア最適化
- 並列処理効率
- モデルアーキテクチャ
- 学習データの品質

たとえば、同じ性能を半分の計算量で達成できるアルゴリズムが開発されれば、ハードウェアが変わらなくても、実質的には計算資源が2倍になったのと同じ効果があります。

逆に、半導体性能が上がっても、モデルが計算資源を効率よく利用できなければ、知能向上には結び付きません。

このため、AGI から ASI へのスケーリングは、チップを増やすことだけではありません。

ハードウェアとアルゴリズムの両方を改善し、同じ資源からより多くの知的成果を引き出すことが重要です。

第 18 節 スケーリングを支える物理的条件

スケーリングには、デジタル空間だけでなく、巨大な物理的基盤が必要です。

AI の計算量を何桁も増やすには、

- 半導体
- データセンター
- 電力
- 冷却設備
- 通信網
- 土地
- 水
- 金属や鉱物資源
- 製造装置
- 熟練労働者
- 巨額の資本

が必要です。

そのため、AI の進歩は純粋なソフトウェア問題ではありません。

エネルギー政策、産業政策、サプライチェーン、地政学、環境問題と直接結び付きます。

たとえば、より高度な AI モデルを設計できても、必要な半導体を生産できなければ、実際には利用できません。

電力供給を拡大できなければ、計算資源も増やせません。

原報告書は、スケーリングを ASI まで持続するには、経済投入、技術資源、自然資源を何桁にもわたって増やす必要がある可能性を強調しています。（原報告書、Section 5.1）

第 19 節 経済的にどこまで続けられるのか

AI 開発には巨額の費用がかかります。

しかし、費用が高いだけでは、スケーリングが止まるとは限りません。

AI によって得られる経済的利益がさらに大きければ、投資は継続するからです。

たとえば、AI が、

- ・ 研究開発を加速する
- ・ ソフトウェア開発を自動化する
- ・ 医薬品開発を改善する
- ・ 企業運営を効率化する
- ・ 多くの知的労働を代替する

ことで大きな収益を生むなら、企業や政府はさらに多くの資本を AI へ投入するでしょう。

したがって、スケーリングの経済的限界は、単純な開発費用ではなく、

追加の計算資源に対して、どれだけの追加的価値が生まれるか。

によって決まります。

性能向上が小さくなり、追加計算の費用を正当化できなくなれば、スケーリングは鈍化します。

反対に、AI が経済成長そのものを加速すれば、より大きな計算設備へ投資できる可能性があります。

第 20 節 限界効用の低下

多くの技術では、規模を拡大するほど、追加投資から得られる効果が小さくなります。

これを限界効用の低下と考えることができます。

AI でも、

- 計算量を 10 倍にして大幅に性能が上がる段階
- 計算量を 10 倍にしても少ししか改善しない段階

があるかもしれません。

もし性能改善に必要な計算量が急速に増え続ければ、物理的・経済的に維持できなくなります。

一方で、性能向上が経済的価値を増やし、その利益が次の計算資源へ再投資されれば、拡大が続く可能性もあります。

したがって、重要なのは、

- 計算量の増加率
- アルゴリズム効率の改善率
- 性能向上率
- 経済的価値の増加率
- 資源コストの増加率

の相互関係です。

原報告書は、これらの関係を定量的に測定し、複数の予測モデルを継続的に更新する必要があるとしています。（原報告書、Section 5.1）

第 21 節 スケーリングの中心的な未解決問題

Section 5.1 が提示する問いは、次のように整理できます。

21.1 計算量はどの範囲で知能へ変換されるのか

より多くの計算が、単なる高速化ではなく、より深い理解や一般化を生むのでしょうか。

21.2 スケーリング則は AGI 以後も続くのか

現在のモデルで観測された規則が、人間レベルを超えた領域にも適用できるのでしょうか。

21.3 データの壁を越えられるのか

人間生成データが不足した後、合成データ、シミュレーション、実世界との相互作用が代替できるのでしょうか。

21.4 推論時スケーリングはどこまで有効か

同じモデルに長く考えさせれば、どこまで能力を高められるのでしょうか。

21.5 量的拡大は質的飛躍を生むのか

モデル規模と計算量を増やすだけで、新しい抽象能力や一般的推論が生まれるのでしょうか。

21.6 経済・資源面で持続可能か

電力、半導体、データセンター、資本、環境負荷は、必要な規模まで拡大できるのでしょうか。

21.7 個体の能力と集団の能力をどう区別するか

一体のモデルが賢くなることと、多数のモデルを組織して集合的能力を高めることを、どう測定するのでしょうか。

ERF Commentary

第22節 AIのスケーリングと大学のスケーリングは異なる

大学も長い間、規模の拡大によって発展してきました。

- 学生数を増やす
- 教員数を増やす
- 研究費を増やす
- 図書館を拡充する
- 研究施設を増やす
- 国際連携を広げる

という方法です。

しかし、人間組織のスケーリングには大きな摩擦があります。

大学が大きくなるほど、

- 部門間の調整が難しくなる
- 情報共有が遅くなる
- 管理業務が増える
- 専門分野が分断される
- 意思決定が複雑になる
- 組織目的が曖昧になる

可能性があります。

これに対してデジタル AI は、複製、通信、記憶共有において、人間組織より有利な可能性があります。

そのため、大学が単に規模の大きさや知識量で AI 組織と競うことは困難です。

第23節 大学教育における「より多く」と「より良い」

スケーリングの問題は、大学教育にも当てはまります。

教育ではしばしば、

- より多くの学生
- より多くの教材
- より多くのオンライン講義
- より多くの学習データ
- より多くの評価指標

が、教育の向上と考えられます。

しかし、量の増加は必ずしも質の向上を意味しません。

教材が増えすぎれば、学生は何を読むべきか分からなくなります。

評価データが増えても、教育の本質を測れているとは限りません。

AIによって大量の授業や教材を生成できても、学生が深く考え、人格的に成長するとは限りません。

AIのスケーリング論は、大学に対しても、

何を増やせば教育の質が本当に向上するのか。

という問いを投げかけます。

第24節 知識量よりも、選択と意味付けが重要になる

AIが膨大な情報を処理できる時代には、知識の不足よりも、知識の過剰が問題になります。

学生や研究者は、

- 何を読むべきか
- 何を信頼すべきか
- 何が重要なのか
- どの知識を組み合わせるべきか
- どの問いを優先すべきか

を判断しなければなりません。

したがって、大学の役割は、知識を大量に供給することから、

- 選択する
- 文脈化する
- 批判する
- 統合する
- 意味を与える

ことへ移っていくでしょう。

AIは知識をスケールできます。

しかし、どの知識が人間社会にとって重要かを公共的に判断することは、依然として制度的・倫理的課題です。

第 25 節 研究成果が大量生成される時代

多数の AGI 研究者が稼働すれば、論文、仮説、実験計画、データ分析が大量に生成される可能性があります。

その場合、研究の中心問題は、成果を作ることから、成果を評価することへ移ります。

- どの研究が正しいのか
- どの結果が再現可能か
- どの発見が重要か
- 複数の AI 研究者が同じ誤りを共有していないか
- 誰が研究成果に責任を負うのか
- 人間が理解できない研究をどう承認するのか

という問題です。

AI が研究成果を大量生成しても、学術的信頼性が自動的に生まれるわけではありません。

むしろ、査読、再現性、批判、異論、研究倫理といった大学の制度的役割が、さらに重要になる可能性があります。

第 26 節 スケーリングと知の集中

巨大な AI モデルの開発には、大規模な計算資源、データ、資本が必要です。

そのため、能力の高い AI が少数の企業や国家に集中する可能性があります。

これは高等教育にも影響します。

大学が独自にフロンティア AI を開発できず、少数企業のモデルに依存するようになれば、

- 研究課題の選択
- 教育内容
- 学術データ
- 知的所有権
- 研究成果へのアクセス

が、企業の方針や料金体系に左右される可能性があります。

したがって、大学に必要なのは AI を利用する能力だけではありません。

- 公共的な計算資源
- オープンな研究基盤
- 学術データの共有
- モデルの透明性
- 大学間共同利用
- 国際的な公共 AI インフラ

について考える必要があります。

AI のスケーリングは、技術能力の問題であると同時に、知識と権力の配分問題です。

第 27 節 環境負荷と Ecological University

スケーリングには電力、水、土地、半導体、鉱物資源が必要です。

したがって、AI の発展を知的進歩だけとして考えることはできません。

Ronald Barnett の Ecological University の観点から見れば、大学が AI を利用する際には、

- 技術的便益
- 教育的効果
- 経済的費用
- 環境負荷
- 社会的公正
- グローバルな資源配分

を同時に考える必要があります。

AI モデルの性能を高めることが可能であっても、そのために必要な環境コストが正当化できるとは限りません。

大学は、単に最も強力な AI を採用するのではなく、

どの程度の計算資源を、何のために使うのか。

を公共的・生態学的視点から判断する必要があります。

第28節 「大きいこと」と「賢いこと」は同じではない

Section 5.1 の核心は、スケーリングの可能性を認めながらも、規模と知能を同一視しない点にあります。

より大きなモデルは、より多くの知識を保持できるかもしれません。

より多くの計算は、より広い探索を可能にするかもしれません。

より多くの AI は、より多くの仕事を処理できるかもしれません。

しかし、

- 問題を正しく表現する
- 重要な問いを選ぶ
- 価値を判断する
- 新しい概念を作る
- 異なる分野を意味ある形で結び付ける
- 社会的責任を引き受ける

能力が、規模だけから自動的に生まれるとは限りません。

大学についても同じです。

学生数、論文数、研究費、ランキングが増えても、大学がより賢明な制度になるとは限りません。

重要なのは、規模を何のために使うかです。

結論

『From AGI to ASI』の Section 5.1 は、AGI から ASI へ向かう第一の経路として、計算資源、モデル、データのスケールリングを検討しています。

過去十年の AI 発展は、主としてスケールリングによって支えられてきました。

- モデル規模の拡大
- データ量の増加
- 学習計算量の増加
- 推論時計算量の増加
- アルゴリズム効率の改善

が、AI 能力を大きく向上させてきたのです。

もし計算量の増加が、より広く深い探索を可能にし、その探索を有効な知能へ変換できるなら、量的スケールリングだけでも AGI から ASI へ進める可能性があります。

特に、個々の AGI が人間レベルにとどまっていたとしても、数百万、数億の AGI を高速に稼働させれば、集合体として大規模な人間組織を超える可能性があります。

しかし、スケールリングには重大な不確実性があります。

- 計算量がどこまで知能へ変換されるか
- スケールリング則が AGI 以後も続くか
- 高品質なデータを確保できるか
- 合成データが退化を防げるか
- 量的増加が質的飛躍を生むか
- 電力、半導体、資本、自然資源を確保できるか
- 経済的に投資を継続できるか

は、いずれも未解決です。

原報告書の重要な結論は、

スケーリングが理論的に ASI を生み得るかどうかだけでなく、ASI に到達するまでスケーリングを現実を持続できるかどうかが中心問題である

という点です。

第 5 回では、原報告書の Section 5.2 に進み、第二の経路である Algorithmic Paradigm Shifts——現在の Transformer、大規模事前学習、固定モデルという枠組みを超えるアルゴリズム上の転換を詳しく解説します。