

集中講義 2026年2月24日～26日

コンピュータシステム入門

Day 3: 未来のコンピュータ技術と応用の展望
～「0と1」の世界から、未知の領域へ～

講師 陳 オリビア (大学院システム情報科学研究院)

TA GPT-5 Thinking (OPEN AI)

Gemini 2.5 pro (Google)



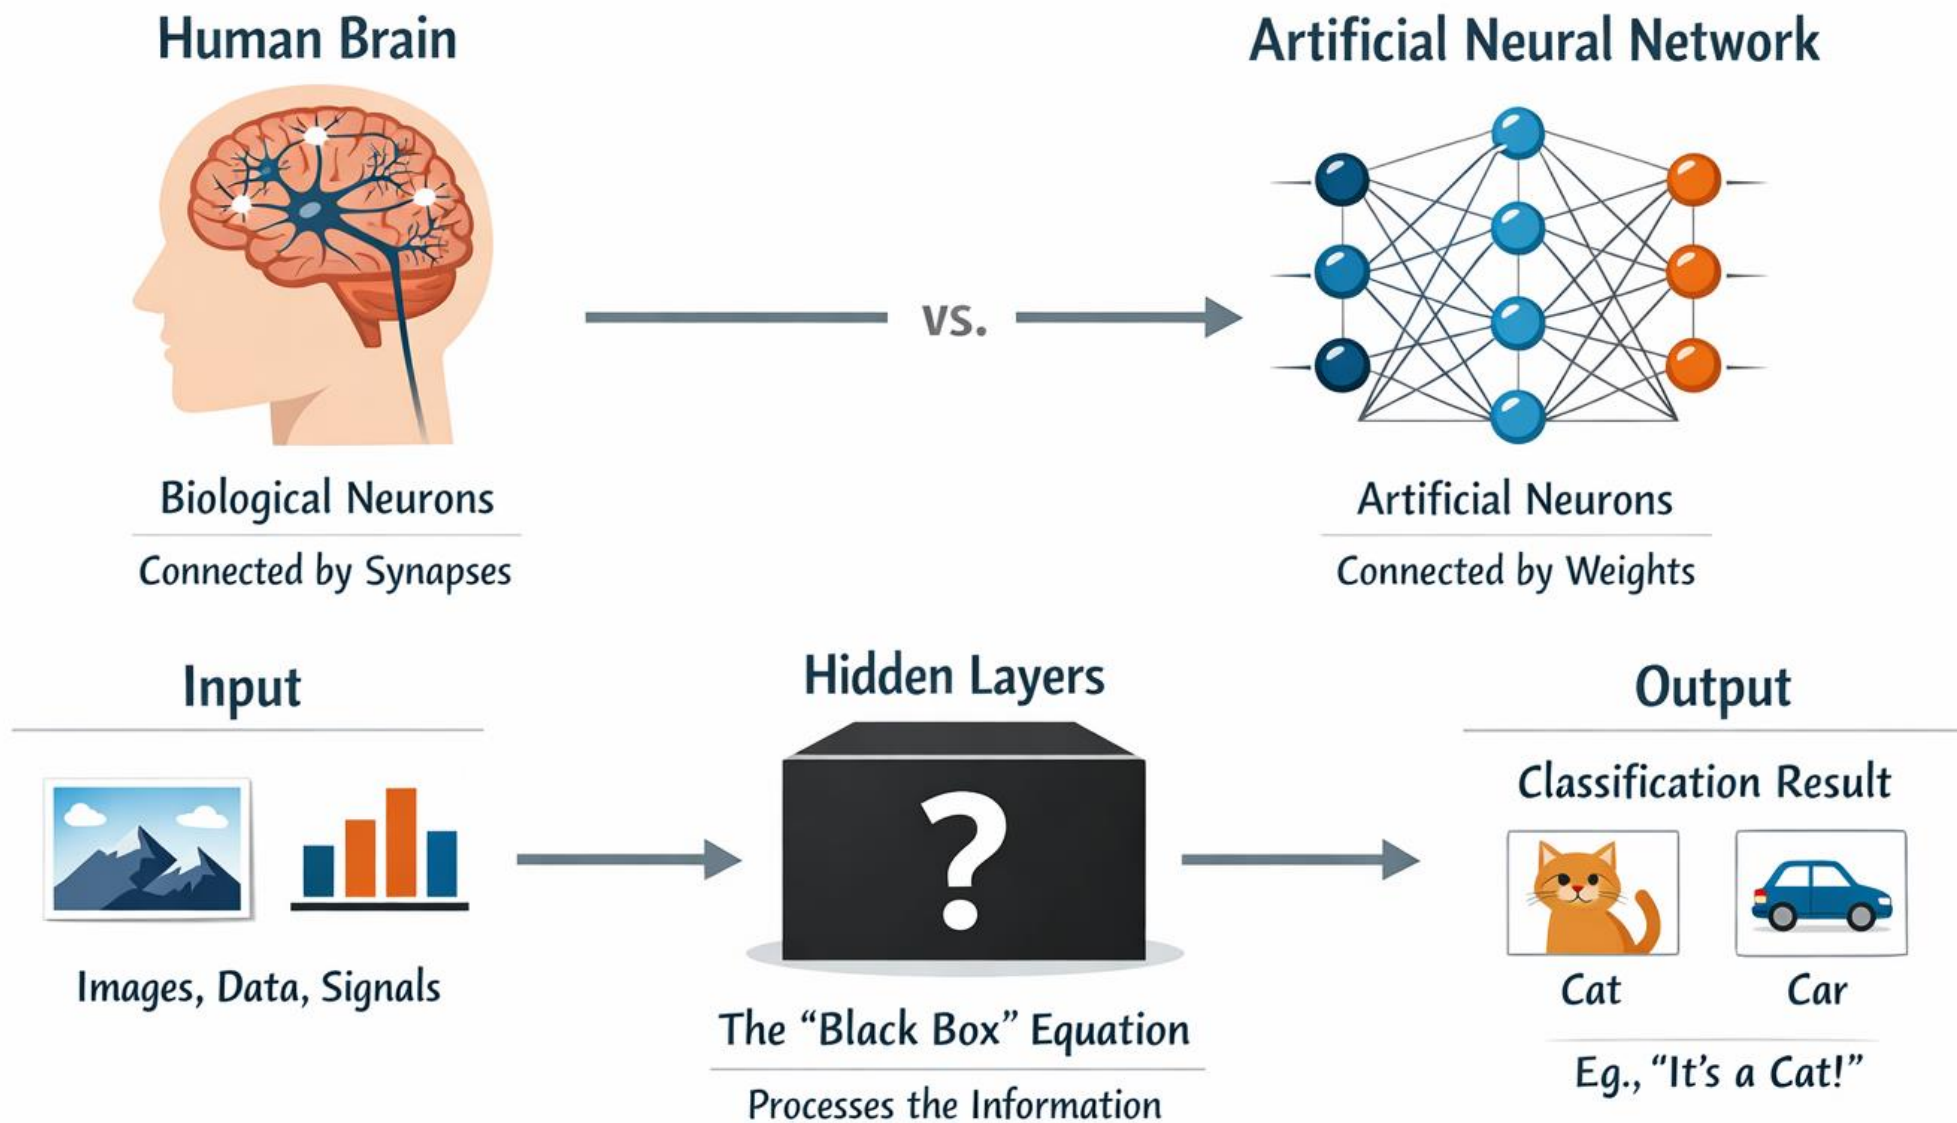
今日のスケジュール

	時間帯	モジュール	タイプ
午前中	10:00 ~ 11:00	オペレーティングシステムの役割と仕組み	講義
	11:00 ~ 11:15	Coffee Break	
	11:30 ~ 12:30	未来のコンピュータ技術と応用の展望	講義
	12:30 ~ 13:30	Lunch Break	
午後	13:30 ~ 16:00	LINUX操作演習	演習


未来のコンピュータ技術と応用の展望




人工知能とは？



From Human Intuition to Machine Intelligence




The Human Supercomputer



- 一次視覚野（V1）には約1億4千万個のニューロンがある
- 処理時間：瞬時

The Programmer's Nightmare




Rule 1: Loop at top? (Fails on open loops).


Rule 2: Vertical stroke? (Fails on slant).

A New Paradigm: Learning from Examples

Algorithm: Don't define the rules. Infer them.



知能の最小単位：パーセプトロン



ニューロンはどう判断する？：「花見に行くか」

x1: 天気はいい？ (+1, -1)


重み(w1) : 6 (重要度 : 高)

x2: 友だちも行く？ (+1, -1)

重み(w2) : 3 (重要度 : 中)

x3: アクセスが良い？ (+1, -1)


重み(w3) : 2 (重要度 : 低)




花見に行く？

$$y = f(x1 \cdot w1 + x2 \cdot w2 + x3 \cdot w3)$$

The Architecture of the Network




Breaking Down the Image



Layer 2: Identifying Components

The Cost of Being Wrong

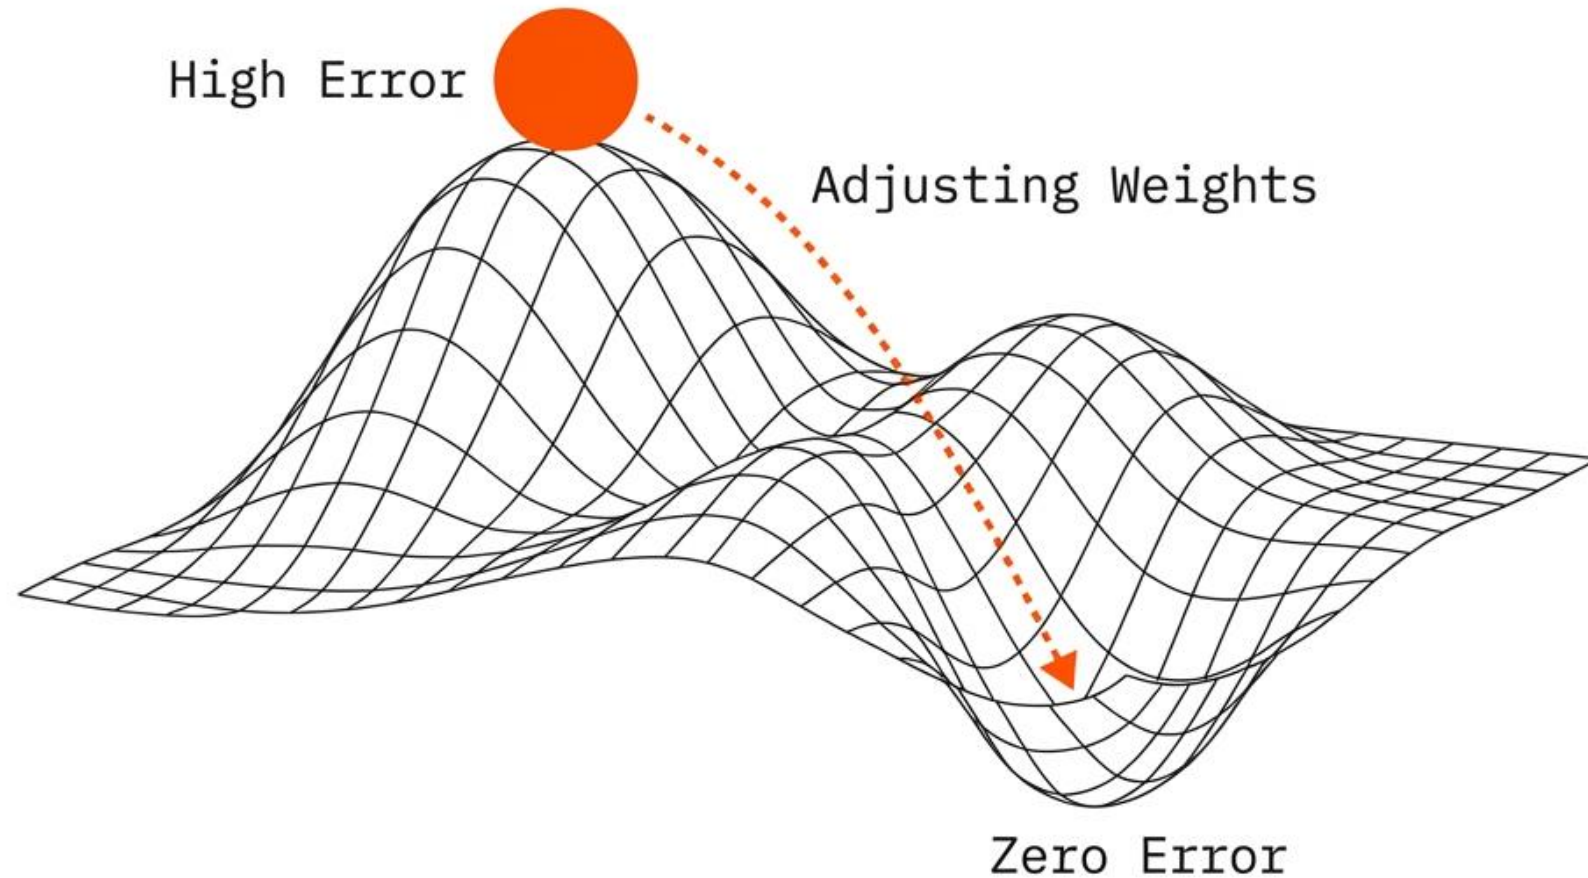


COST/ ERROR RATE



Difference between Guess and Reality

Gradient Descent: Rolling Down the Hill



Enter Deep Learning

input layer

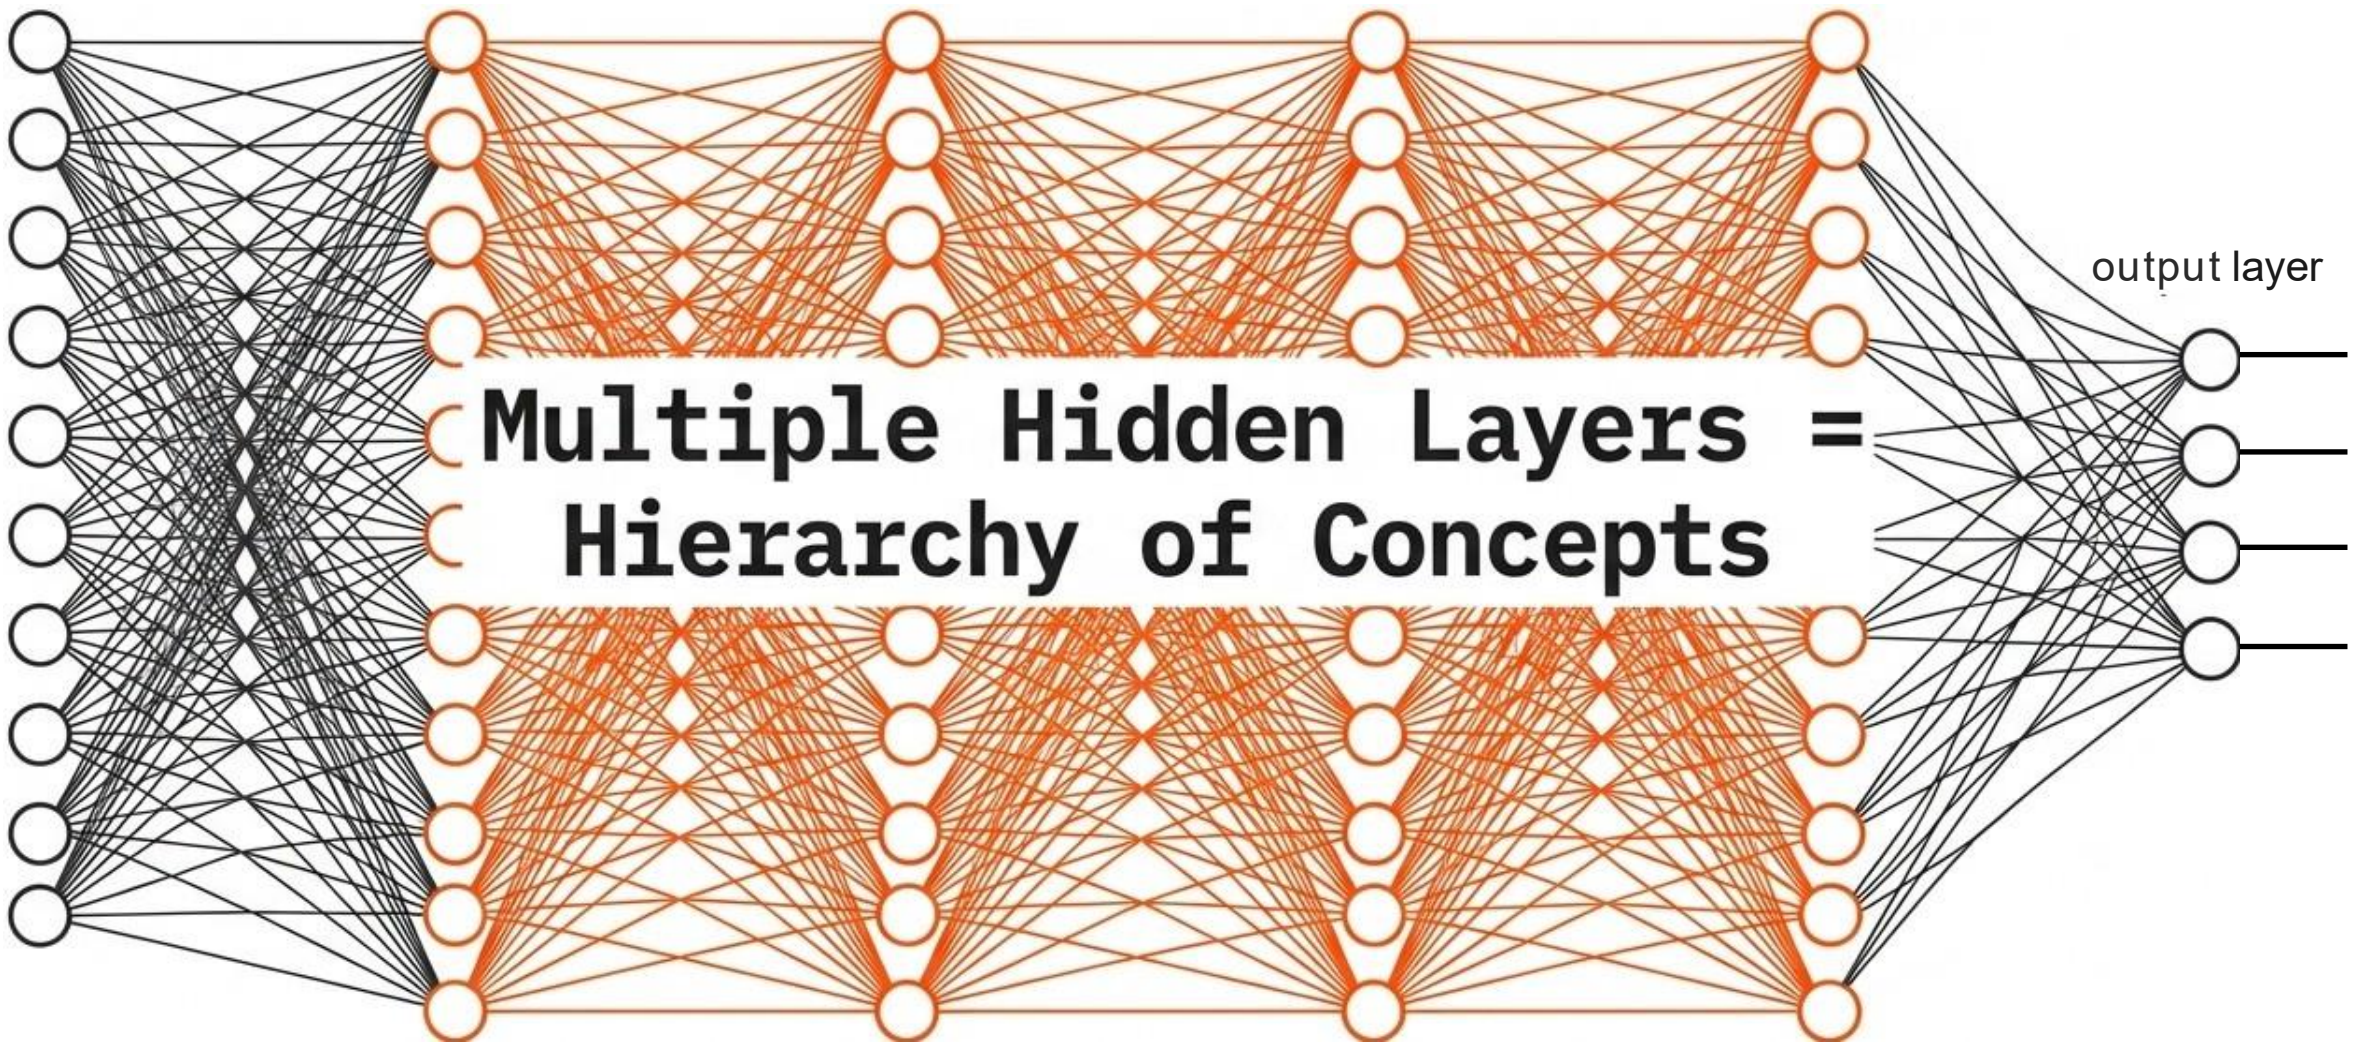
hidden layer 1

hidden layer 2

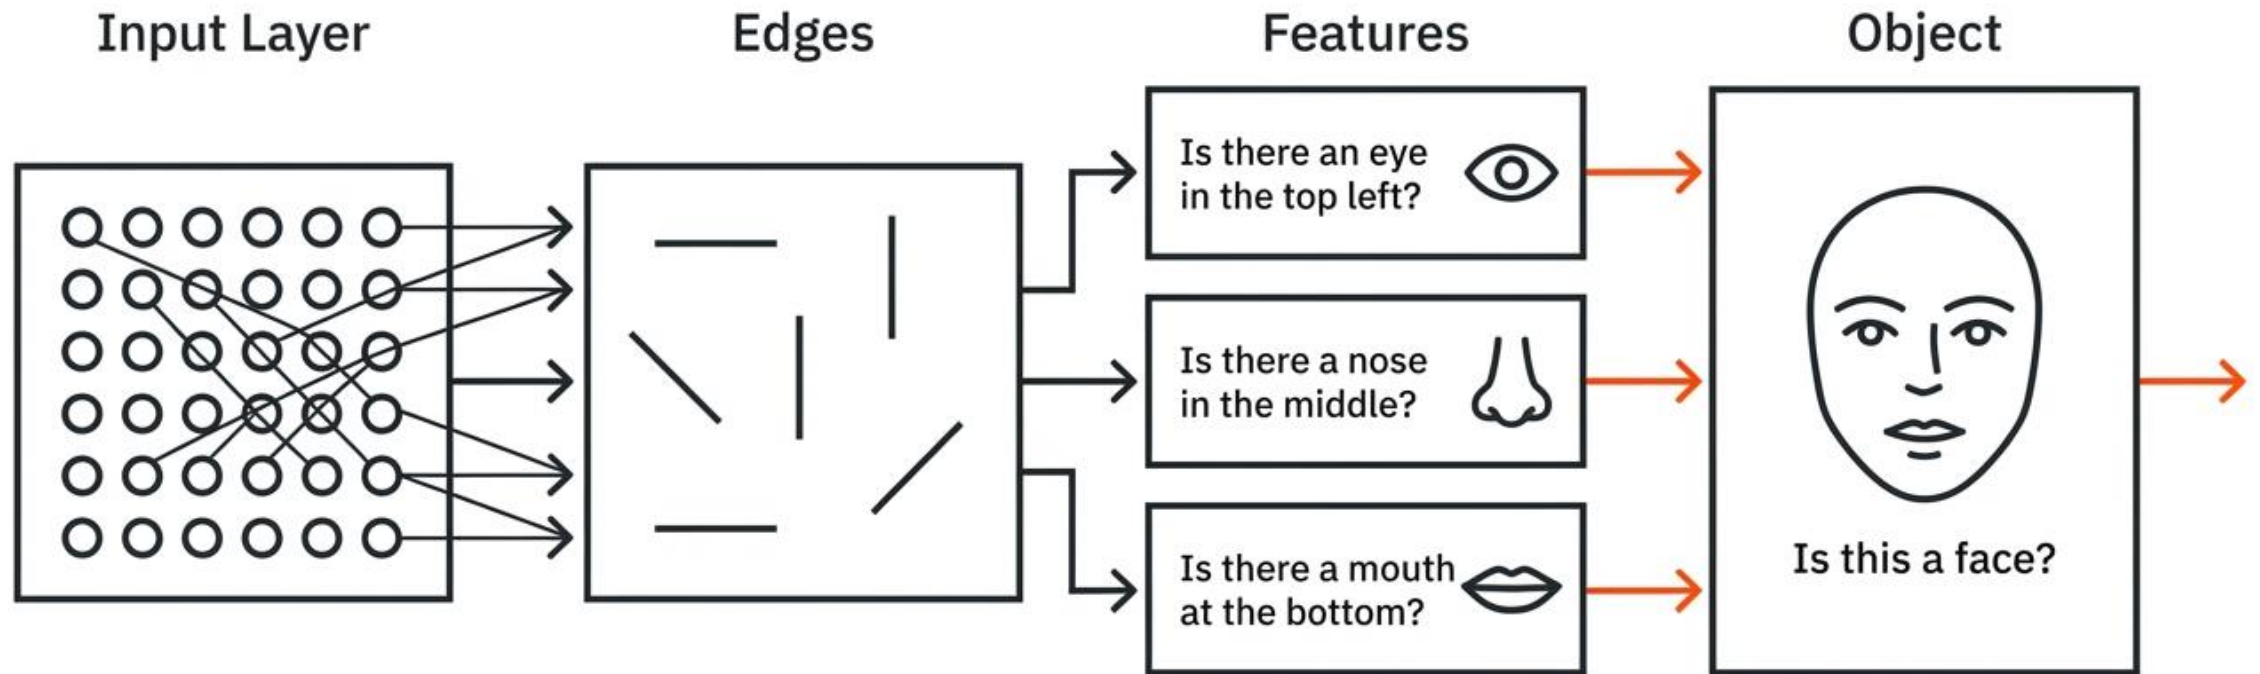
hidden layer 3

output layer

**Multiple Hidden Layers =
Hierarchy of Concepts**




Building a Hierarchy of Concepts



The Formula for Artificial Intelligence



Good Training
Data




Simple Learning
Algorithm



Sophisticated
Intelligence

人工知能の発展



人工知能の発展



基礎段階

機械学習の発展

深層学習の急展開

普及と応用へ

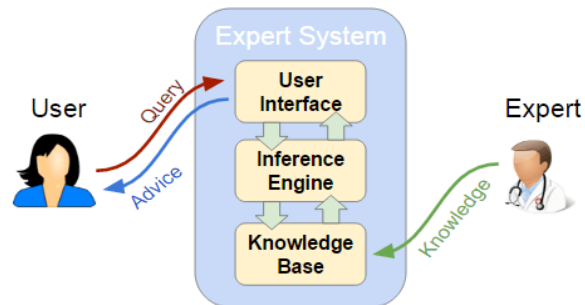
1950s: Turing Test



1956: Dart Mouth会議

1960s: 簡単なニューラルネットワーク

1980s: エクスパートシステム



人工知能の発展



基礎段階

機械学習の発展

深層学習の急展開

普及と応用へ


1950s: Turing Test



1956: Dart Mouth会議

1960s: 簡単なニューラルネットワーク

1980s: エクスパートシステム



概念提出

人工知能の発展





基礎段階

機械学習の発展

深層学習の急展開

普及と応用へ


1950s: Turing Test



1956: Dart Mouth会議

1960s: 簡単なニューラルネットワーク

1980s: エクスパートシステム



概念提出


2001 : 3D Data Management by META Group

Big dataへの準備

2009 : ImageNet
14M labeled image



人工知能の発展




基礎段階

機械学習の発展

深層学習の急展開

普及と応用へ


1950s: Turing Test



1956: Dart Mouth会議

1960s: 簡単なニューラルネットワーク

1980s: エクスパートシステム




概念提出

2001 : 3D Data Management by META Group


Big dataへの準備

2009 : ImageNet
14M labeled image



データが揃った

人工知能の発展





基礎段階

機械学習の発展

深層学習の急展開

普及と応用へ


1950s: Turing Test



1956: Dart Mouth会議

1960s: 簡単なニューラルネットワーク

1980s: エクスパートシステム

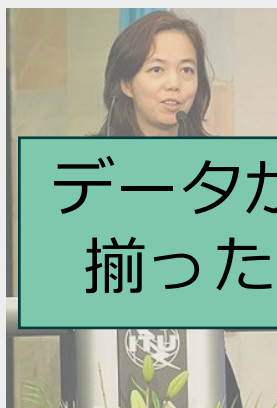


概念提出

2001 : 3D Data Management by META Group

Big dataへの準備

2009 : ImageNet
14M labeled image



データが揃った

2010s: GPUの性能が大幅に上昇

2012年 : AlexNetがImageNetコンペティションで優勝

2014年 : Ian Goodfellowらが生成対抗ネットワーク (GANs) を提唱し、生成モデルの新たな分野を開拓

2015年 : ResNet (残差ネットワーク)、深層ニューラルネットワークの訓練における退化問題を解決

2016年 : DeepMindのAlphaGo、強化学習と深層学習の大きな進歩を示す

2017年 : VaswaniらがTransformerモデルを提唱し、自然言語処理 (NLP) タスクの性能を大幅に向上させる

人工知能の発展





基礎段階

機械学習の発展

深層学習の急展開

普及と応用へ


1950s: Turing Test



1956: Dart Mouth会議

1960s: 簡単なニューラルネットワーク

1980s: エクスパートシステム

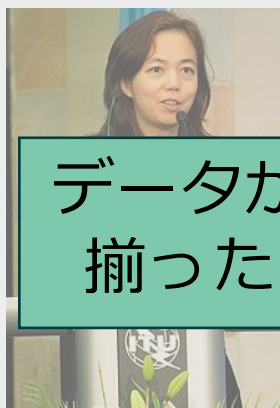


概念提出

2001 : 3D Data Management by META Group

Big dataへの準備

2009 : ImageNet
14M labeled image



データが揃った

2010s: GPUの性能が大幅に上昇

2012年 : AlexNetがImageNetコンペティションで優勝

計算資源が揃った
(GPU)


+

手法のブレイクスルー
(AlexNet/ResNet/Transformer)

2016年 : DeepMindのAlphaGo、強化学習と深層学習の大きな進歩を示す

2017年 : VaswaniらがTransformerモデルを提唱し、自然言語処理 (NLP) タスクの性能を大幅に向上させる

人工知能の発展




基礎段階

機械学習の発展

深層学習の急展開

普及と応用へ


1950s: Turing Test



1956: Dart Mouth会議

1960s: 簡単なニューラルネットワーク

1980s: エクスパートシステム




概念提出

2001 : 3D Data Management by META Group

Big dataへの準備

2009 : ImageNet 14M labeled image



データが揃った

2010s: GPUの性能が大幅に上昇

2012年 : AlexNetがImageNetコンペティションで優勝

計算資源が揃った (GPU)

+

手法のブレイクスルー (AlexNet/ResNet/Transformer)

2016年 : DeepMindのAlphaGO、強化学習と深層学習の大きな進歩を示す

2017年 : VaswaniらがTransformerモデルを提唱し、自然言語処理 (NLP) タスクの性能を大幅に向上させる


2020年 : GPT-3発表

2021年 : DeepMindのAlphaFold2がタンパク質折り畳み予測で大きな進展を遂げ

2022年 : 深層強化学習と深層学習モデルが自動運転、医療診断、金融予測など

2023年 : ChatGPTなどの対話システムが各業界での応用が増加

人工知能の発展





基礎段階

機械学習の発展

深層学習の急展開

普及と応用へ


1950s: Turing Test



1956: Dart Mouth会議

1960s: 簡単なニューラルネットワーク

1980s: エクスパートシステム




概念提出

2001 : 3D Data Management by META Group

Big dataへの準備

2009 : ImageNet
14M labeled image



データが揃った

2010s: GPUの性能が大幅に上昇

2012年 : AlexNetがImageNetコンペティションで優勝

計算資源が揃った
(GPU)

+

手法のブレイクスルー
(AlexNet/ResNet/Transformer)

2016年 : DeepMindのAlphaGO、強化学習と深層学習の大きな進歩を示す

2017年 : VaswaniらがTransformerモデルを提唱し、自然言語処理 (NLP) タスクの性能を大幅に向上させる


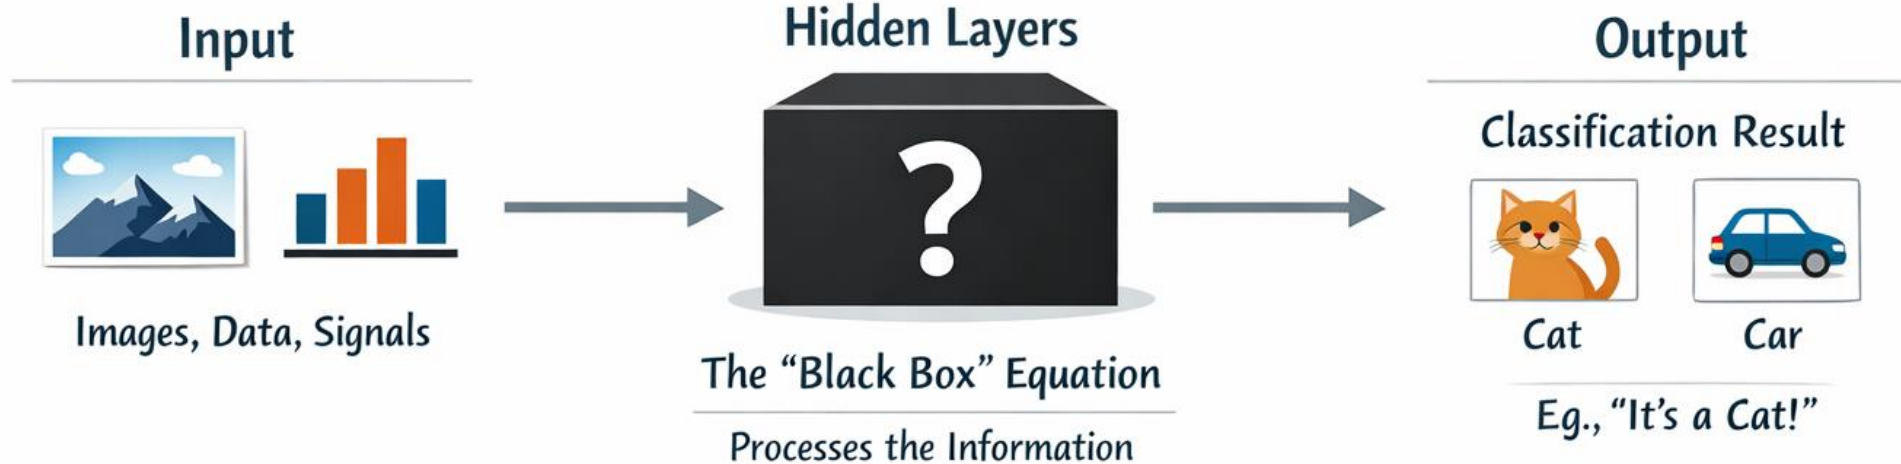
2020年 : GPT-3発表

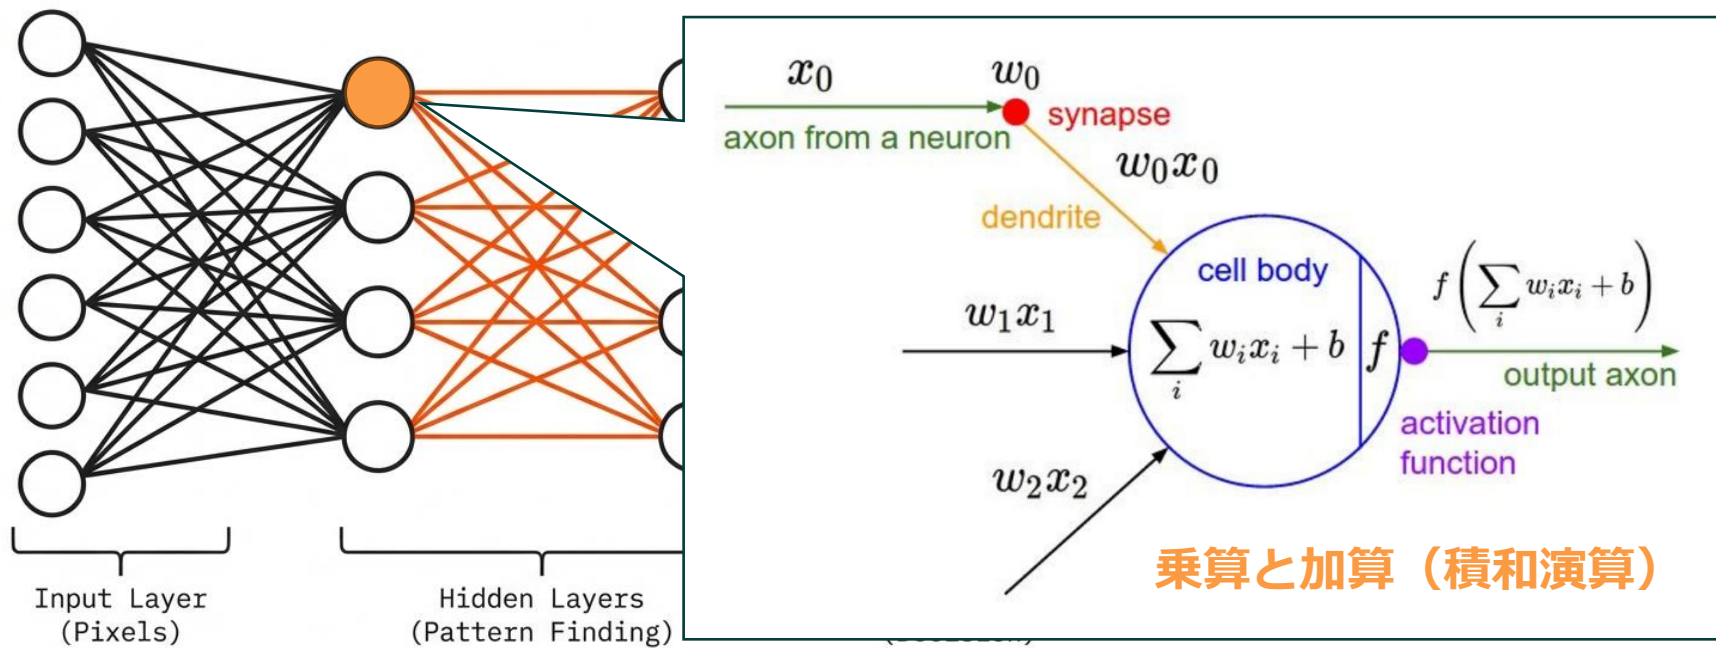
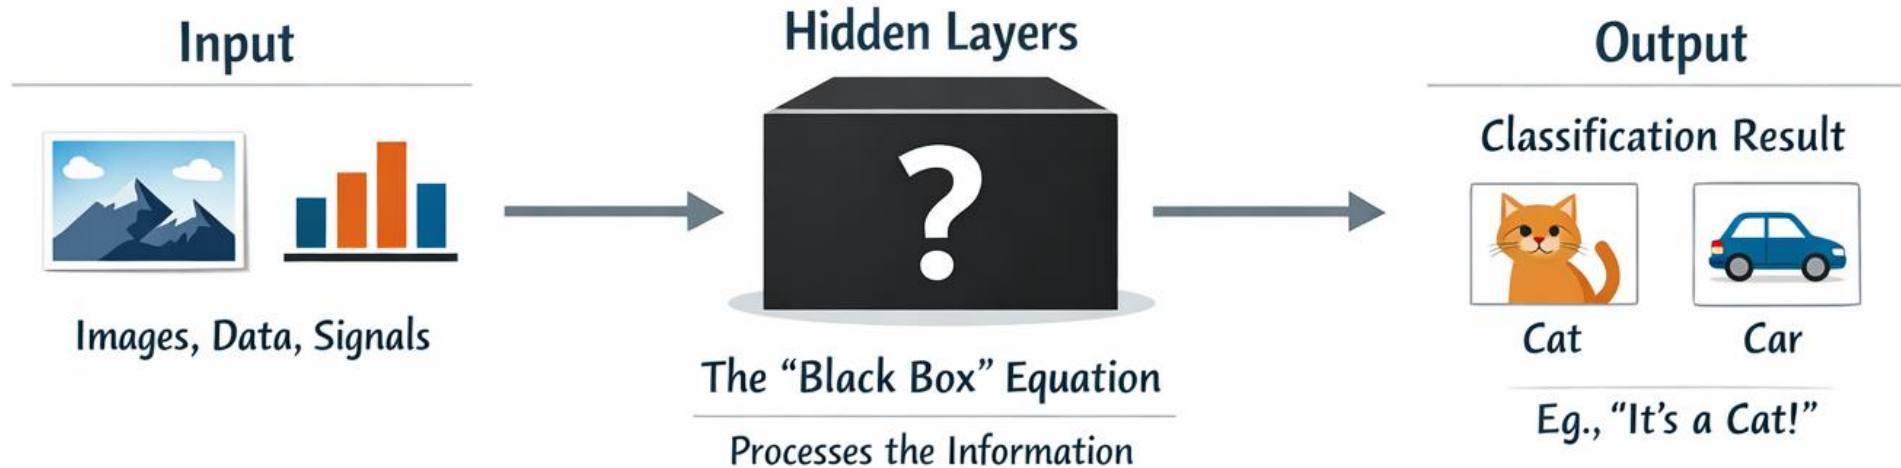
プロダクト化

パク質折り畳み予測で大きな進展を遂げ

2022年 : 深層強化学習と深層学習モデルが自動運転、医療診断、金融予測など

2023年 : ChatGPTなどの対話システムが各業界での応用が増加







AI時代計算の特徴

CPU :

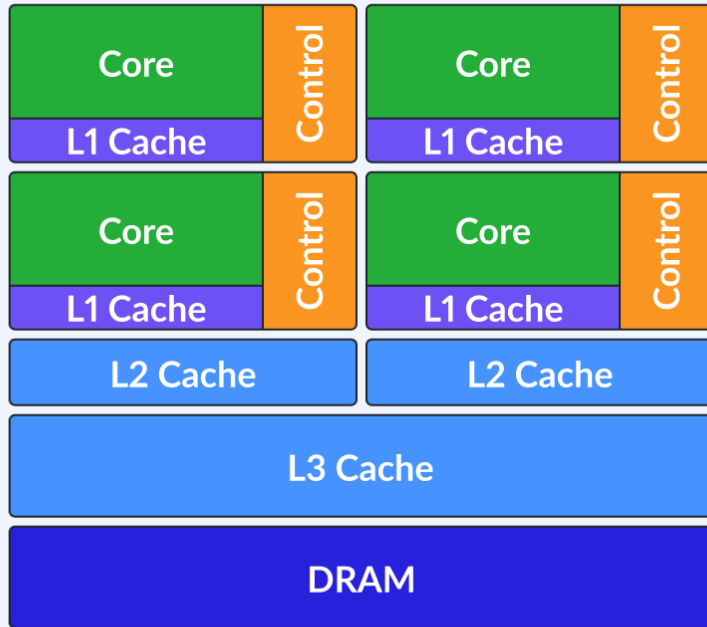
- 複雑な処理が得意
- 単純な計算の繰り返しには効率悪い






AIに関連する計算 :

- 何億回もの単純な「掛け算と足し算」
- 天才シェフ一人では終わらない

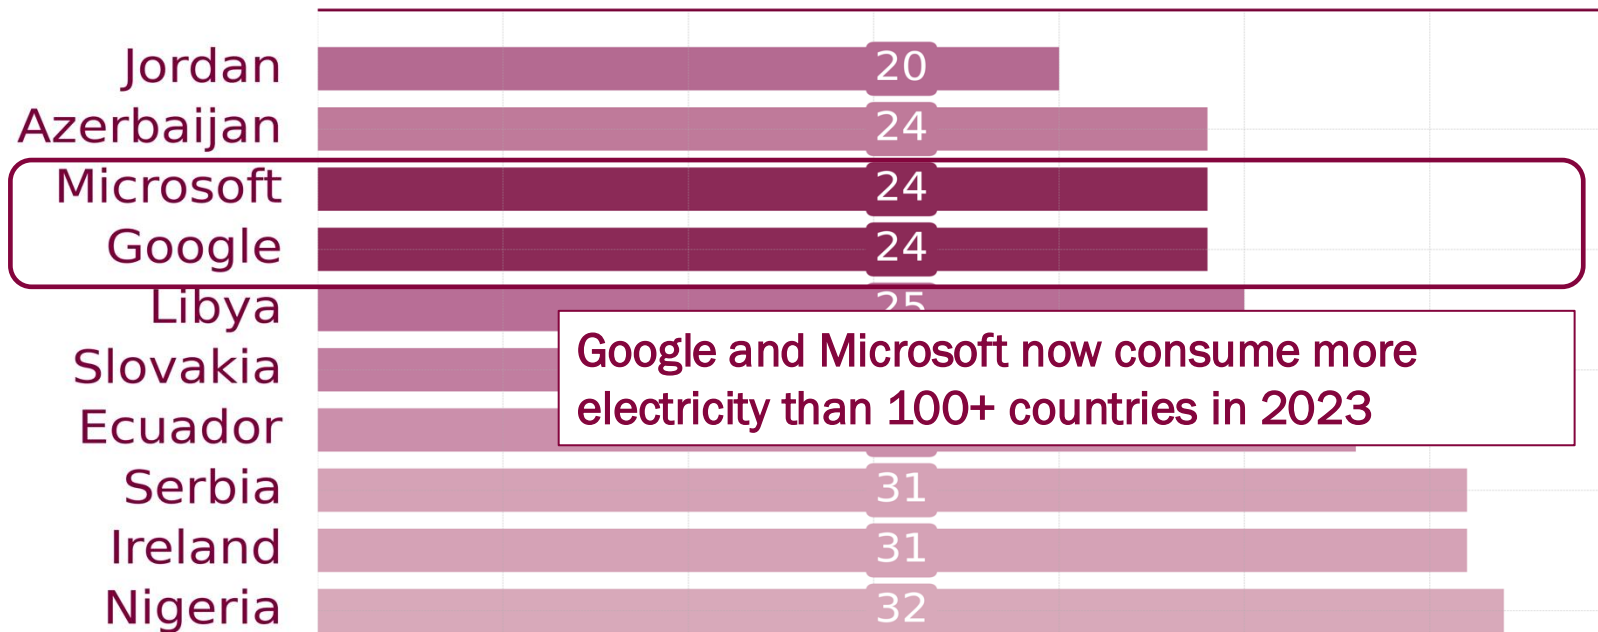
CPU



GPU




Electricity consumption (TWh)




Google and Microsoft now consume more electricity than 100+ countries in 2023

IEA *Energy & AI* (2025):
Data-center demand > doubles
to ~945 TWh by 2030
— slightly above Japan today.



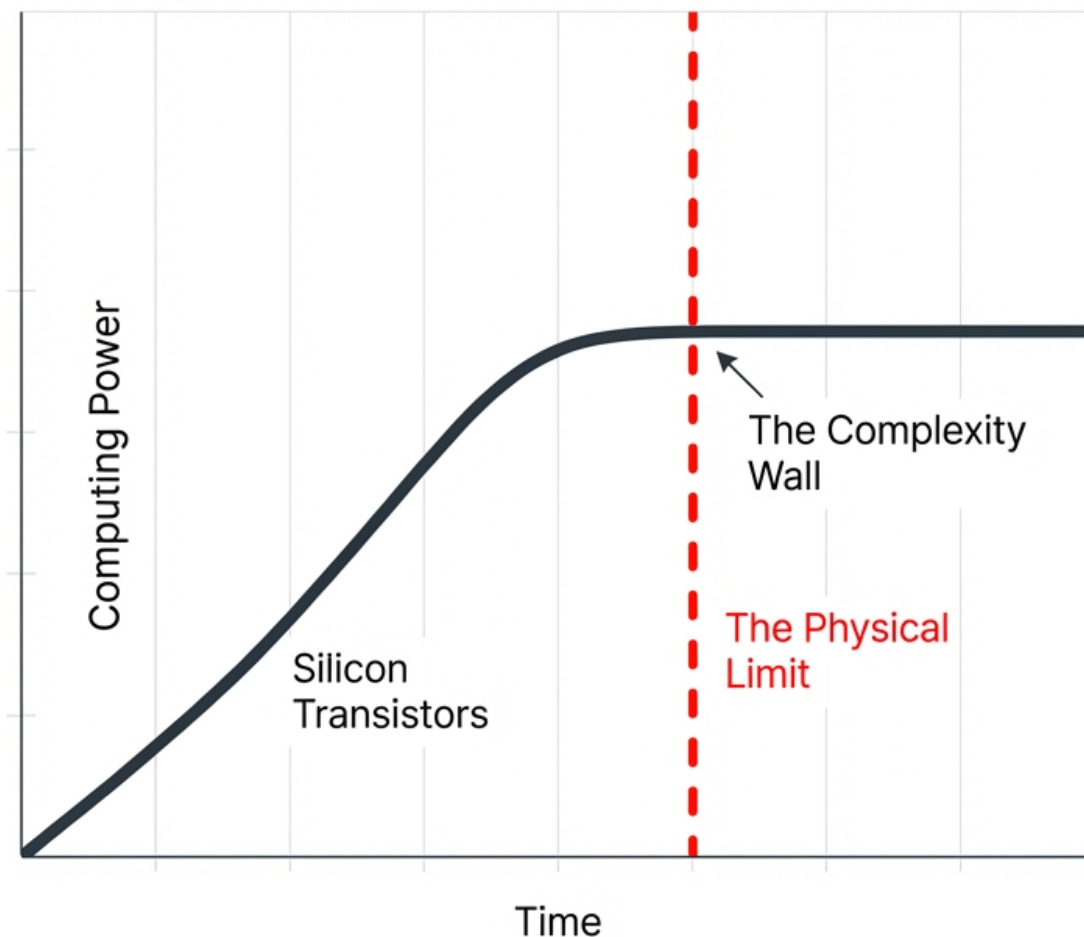
ビットを超えて：ポスト・クラシカル時代へ



私たちは 0 と 1 の決定論的な世界を学んできたが、トランジスタが物理限界に近づくいま、答えは“自然法則”の側にある。

古典計算の限界

- **ムーアの法則は有限**：トランジスタの微細化には限界（量子トンネル効果が支配的）
- **計算困難性**：古典計算は逐次的 → 一部問題は現実的時間では不可能（分子シミュレーション／巨大素因数分解など）
- **飛躍の必要性**：情報処理の物理を変える新原理（量子計算へ）



ビット



- **状態**：明確 (0 または 1)
- **振る舞い**：決定論的
- **測定**：測っても状態は変わらない


量子ビット (Qubit)



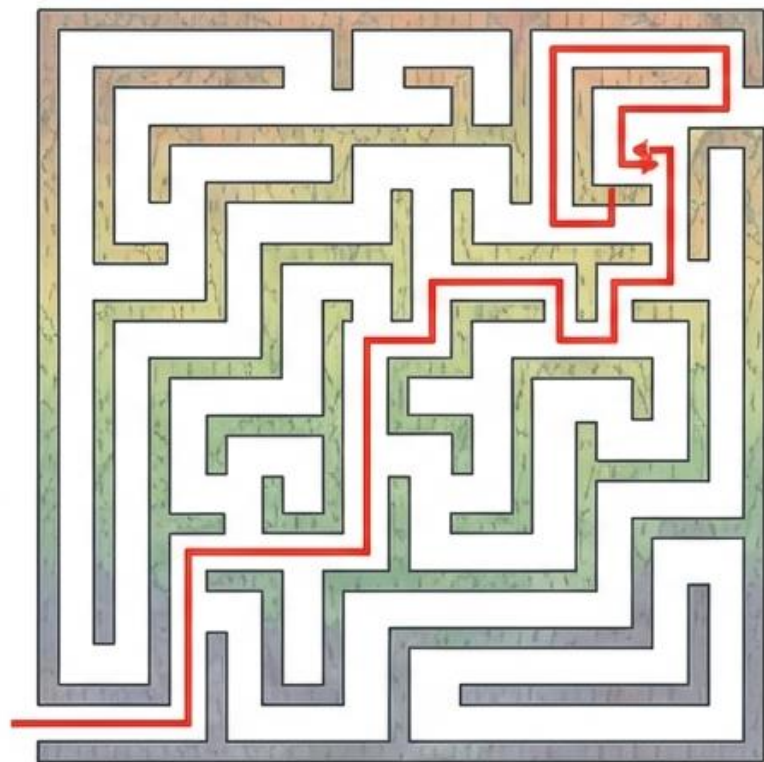
- **状態**： $|0\rangle$ と $|1\rangle$ の重ね合わせ
- **振る舞い**：確率的
- **測定**：測定により状態が収束 (コラプス) する

量子ビット状態の定義

- 情報は連続な状態空間に符号化
- 測定前：状態の複素線形結合（重ね合わせ）
- 要点：ビット=スイッチ / 量子ビット=ベクトル → 位相を含む関係に情報を表現




迷路：逐次探索 vs 量子の重ね合わせ



逐次実行

- 古典：経路が N 本なら N 回の試行
- 一度に 1 つの解だけを試す




量子（重ね合わせ + 干渉）

- 候補経路を重ね合わせで表現し、演算を一括適用
- 干渉により「正解側の振幅を増やし、誤り側を打ち消す」ことで、探索を加速する場合がある

指数の威力



32ビット=1つの整数



32量子ビット=約40億 (2^{32}) の同時状態

古典の成長：線形。1ビット増やすと表現できる値の範囲は2倍になるが、必要なハードウェア増加は基本的に線形。

量子の成長：指数。1量子ビット増やすと状態空間（ヒルベルト空間）の次元が2倍になる。

量子計算機の状態空間を2倍にするには：32量子ビット → 33量子ビット。

* 重ね合わせ = 状態空間は指数だが、得られる情報は測定とアルゴリズム設計（干渉）で制約される

ハードウェアの課題：デコヒーレンスとの戦い



極低温（ ~ 10 mK 級）



振動




電磁ノイズ

脆弱性： 量子ビットは非常に繊細で、環境とのわずかな相互作用も「測定」として働き、重ね合わせが収束（コラプス）してしまう。


必要条件： 「コインを回し続ける」ためには、真空チャンバー、磁気シールド、そして宇宙空間よりも低い温度などを用いて、系を徹底的に隔離する必要がある。

実装例：超伝導回路 (Superconducting Circuits)

- **アーキテクチャ**：超伝導ループで作る「人工原子」
(超伝導量子ビット)
- **主な特徴**：電気抵抗ゼロで電流が流れる (超伝導)
- **制御**：マイクロ波パルス
- **利点**：ゲート動作が高速
- **課題**：コヒーレンス時間が短め (量子状態の保持時間)
- **主なプレイヤー**：Google、IBM、Rigetti



実装例2：トラップドイオン (Trapped Atomic Ions)



- **アーキテクチャ**： 真空チャンバー内で、単一の自然原子（例：イッテルビウム）をイオン化し、電磁場で捕捉・整列させる。
- **制御**： 高精度レーザー
- **利点**： コヒーレンス時間が非常に長い（量子状態を安定に保持しやすい）
- **課題**： 超伝導方式に比べてゲート動作が遅め
- **主なプレイヤー**： IonQ、Quantinuum

The Hardware Landscape



Superconducting

Fast gates

Printable circuits

Harder to scale
connectivity



Trapped Ions

High connectivity

High accuracy

Slower clock cycles

Alternative Architectures

Photonic (Light-based)

Neutral Atoms


Topological

We are in the vacuum-tube era of quantum hardware. No single standard has won yet.

未来のアーキテクチャ：ハイブリッド計算

適材適所：全てが量子になるわけではない。

日常の処理はCPU、AIはGPU、特定の難問はQPU。これらがクラウド上で連携する。



変わる技術、変わらない思考

真空管からトランジスタ、そして量子へ。ハードウェアは変わり続ける。
しかし、「複雑なシステムを階層化し、抽象化して扱う」という本質は永遠に変わらない。

