

# 光が実現する人工知能技術



菅野 円隆

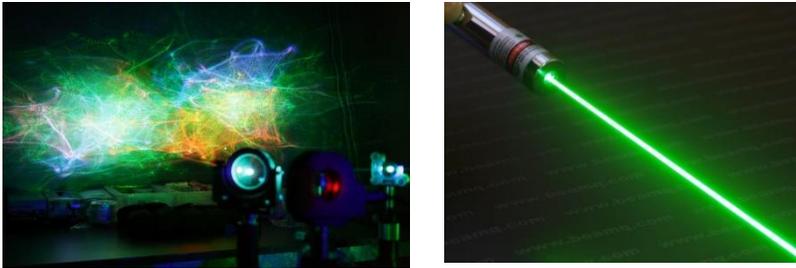
Email: [kkanno@mail.saitama-u.ac.jp](mailto:kkanno@mail.saitama-u.ac.jp)

埼玉大学大学院理工学研究科情報工学PG

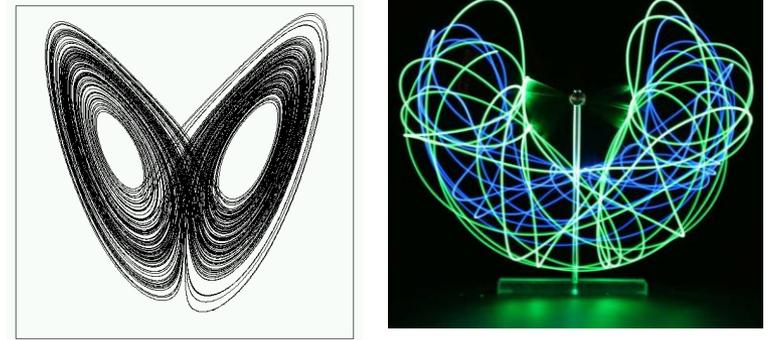
HiGEPS-STAR基礎セミナー 2025/9/27(土)

# 自己紹介 ~専門分野~

## 光学, レーザ



## 非線形科学, カオス



<https://getnews.jp/archives/2181457/chaosmaker1-2>

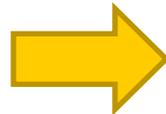
光の速さ・高速性

複雑なふるまい

レーザーの高速性



非線形科学の複雑さ



新たな情報通信技術の創出

- 情報セキュリティ
- 新コンピューティング

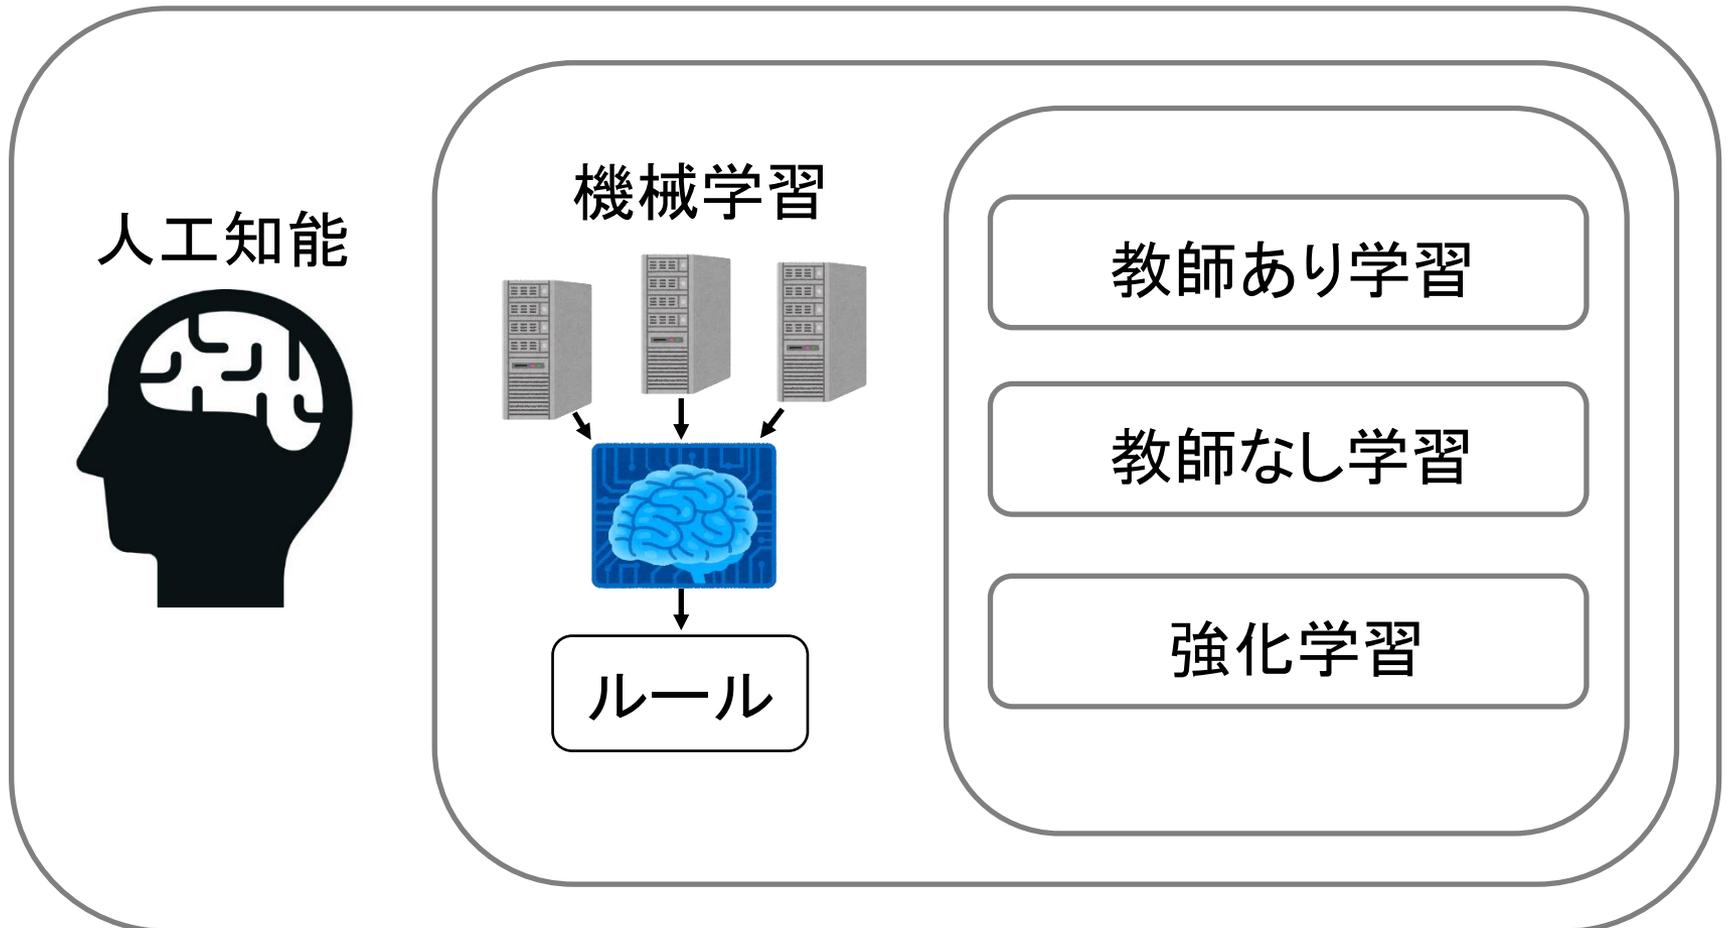
# 目次

---

- 機械学習の発展と課題
- 機械学習への光の寄与, 光電融合
- 深層ネットワークの学習方法の基礎
- 物理リザバークンピューティング

# 機械学習

- 人工知能における研究課題の1つであり，大量のデータに内包される特徴を抽出し，学習する技術



# 機械学習とその分類

## 機械学習

### 教師あり学習

入力と正解例の関係を学習データとして入力し、その関係を再現するように特徴を抽出、学習モデルを生成する。

例：画像認識など、回帰や分類に基づく処理

### 教師なし学習

なんの説明もない学習データを入力し、抽出した特徴から類似したグループを見つけ、それぞれのモデルを生成する。

例：異常検知やクラスタリング

### 強化学習

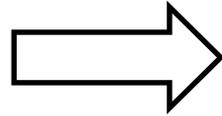
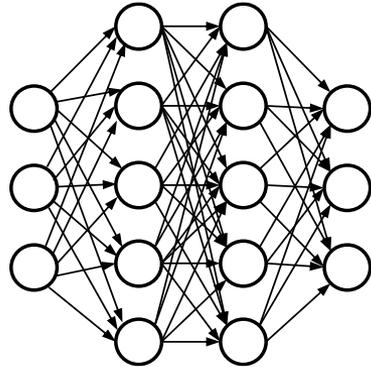
推論結果に対して報酬を与えることで、どのような結果を出して欲しいかを示し、その結果を再現するモデルを生成する。

例：ロボット制御など

# 世の中の機械学習

- 画像分類, 画像生成, 物体検出, セグメンテーション

深層学習



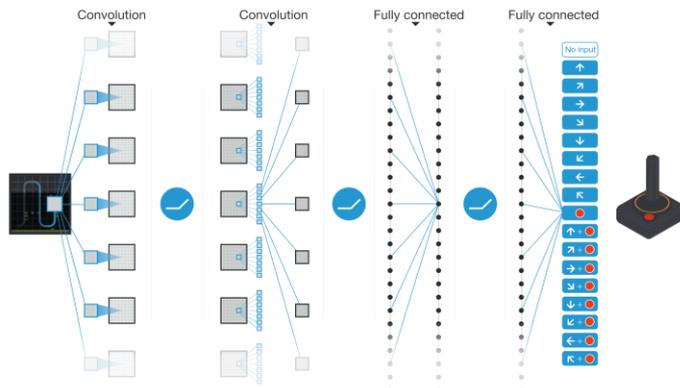
画像分類, 画像生成,  
物体検出, セグメンテーション



物体検出

S. Shuai, et al., Proc. of ICCV 2019 (2019).

- 強化学習による制御



ロボット制御



<https://ai.googleblog.com/2016/03/deep-learning-for-robots-learning-from.html>

V. Mnih et al., *Nature*, **518**, 529 (2015).  
2025/9/27 HiGEPS-STAR基礎セミナー

# 世の中の機械学習

## □ 大規模言語モデルによる自然言語処理

### ChatGPT

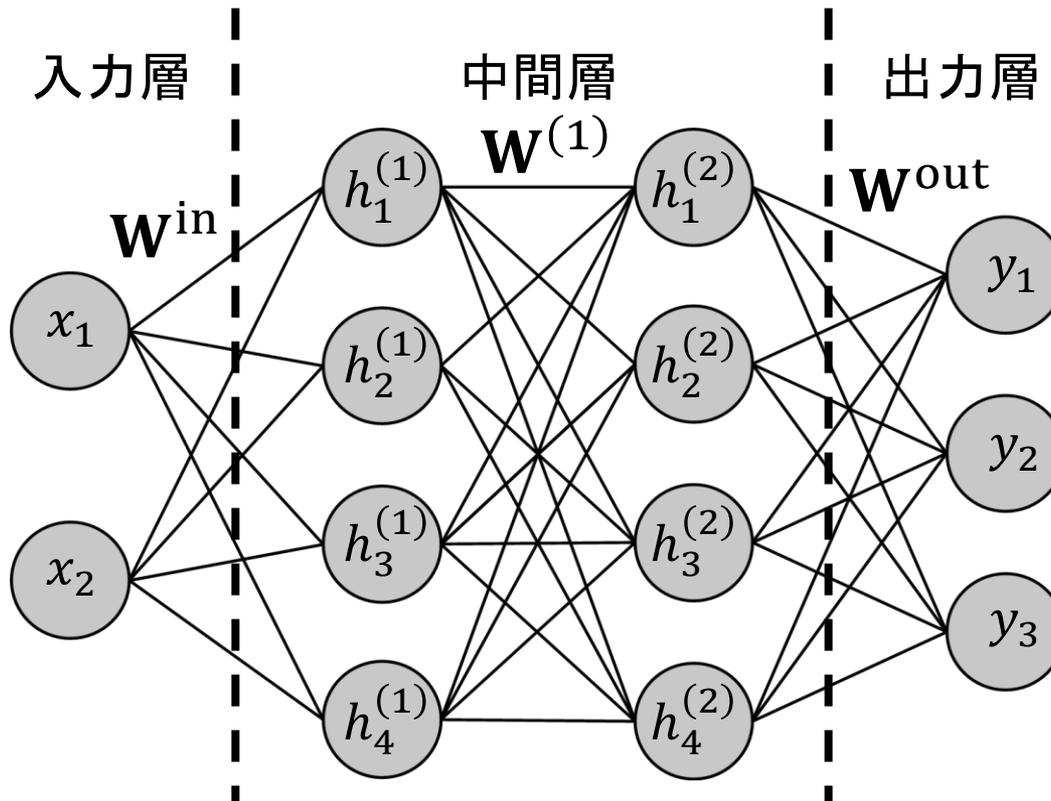
☀ Examples	⚡ Capabilities	⚠ Limitations
"Explain quantum computing in simple terms" →	Remembers what user said earlier in the conversation	May occasionally generate incorrect information
"Got any creative ideas for a 10 year old's birthday?" →	Allows user to provide follow-up corrections	May occasionally produce harmful instructions or biased content
"How do I make an HTTP request in Javascript?" →	Trained to decline inappropriate requests	Limited knowledge of world and events after 2021

[ChatGPT Mar 14 Version](#). Free Research Preview. Our goal is to make AI systems more natural and safe to interact with. Your feedback will help us improve.

# ディープラーニング

## □ 多層のネットワーク

\* 例なので層数が少ない

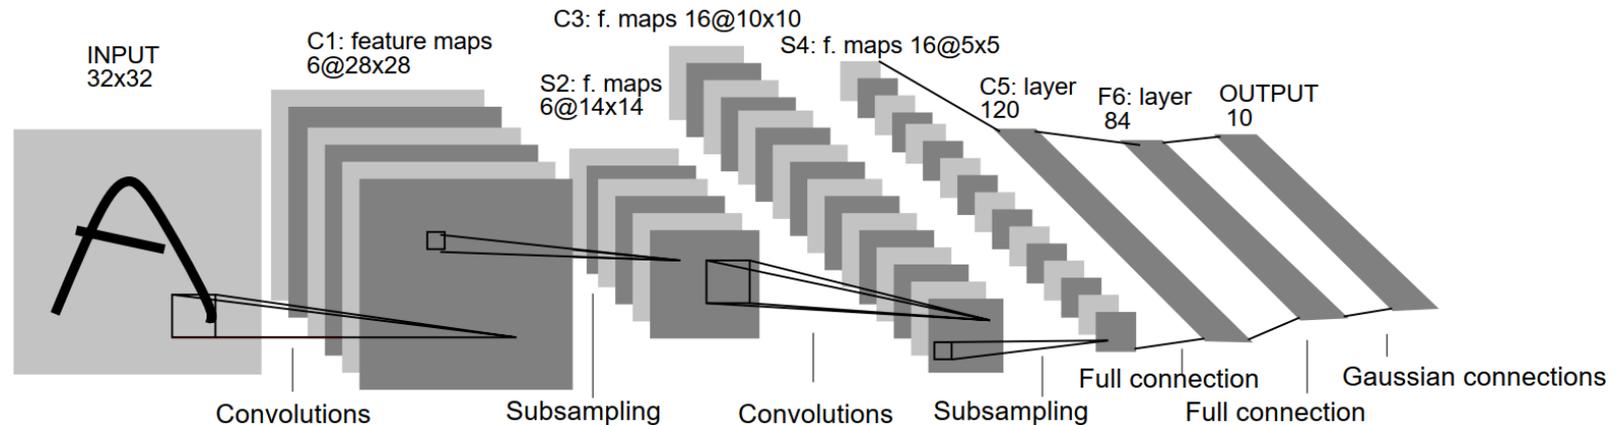


## □ 大規模画像認識コンテストILSVRC2015の優勝モデルの層数

- 152層のResNet(2014年は22層)

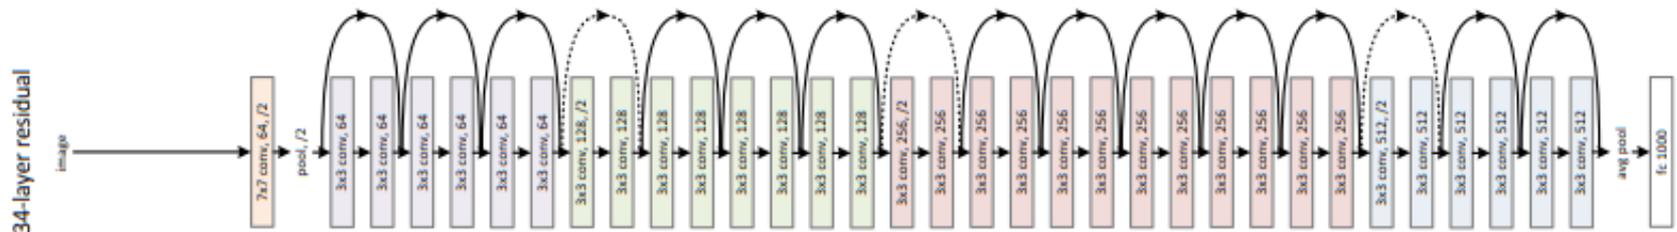
# ディープラーニングモデル

## 畳み込みニューラルネットワーク



Y. LeCun et al., Proc. of the IEEE, 86(11):2278–2324, 1998.

## Residual Network

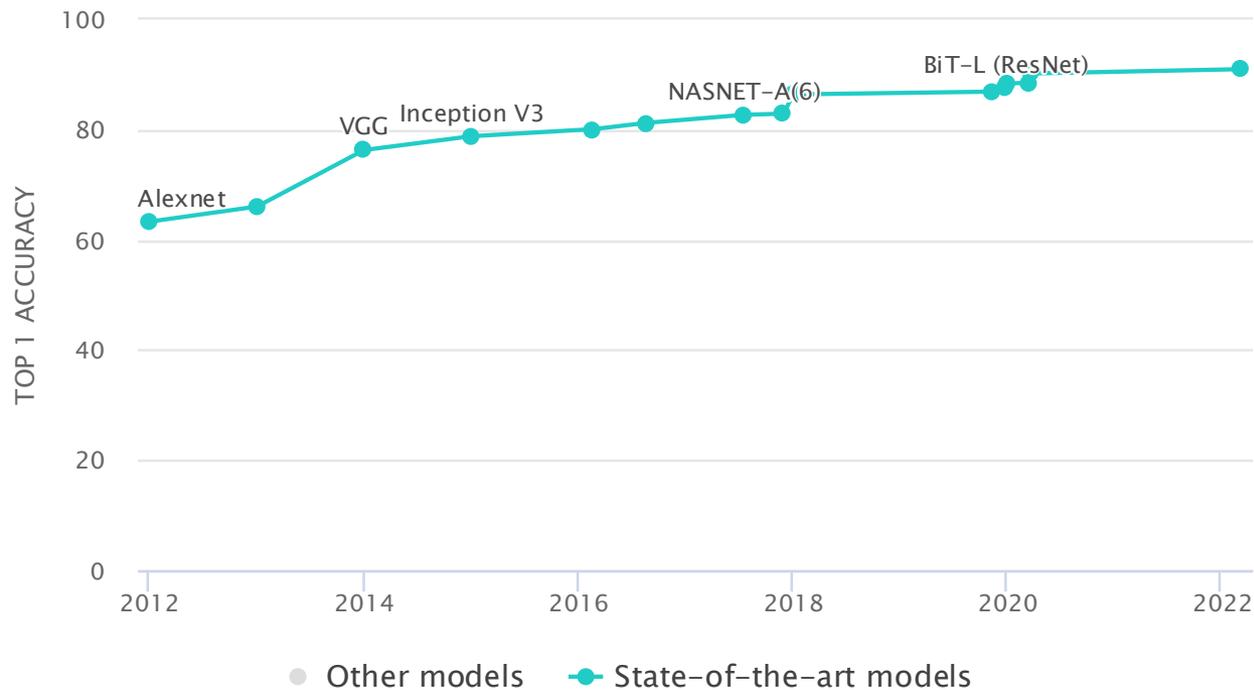


Kaiming He, et al., Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 770-778

# Image Classification on ImageNet

## □ ImageNet: カラー写真画像データベース

- 1400万枚以上のカラー写真(教師ラベルは2万クラス)



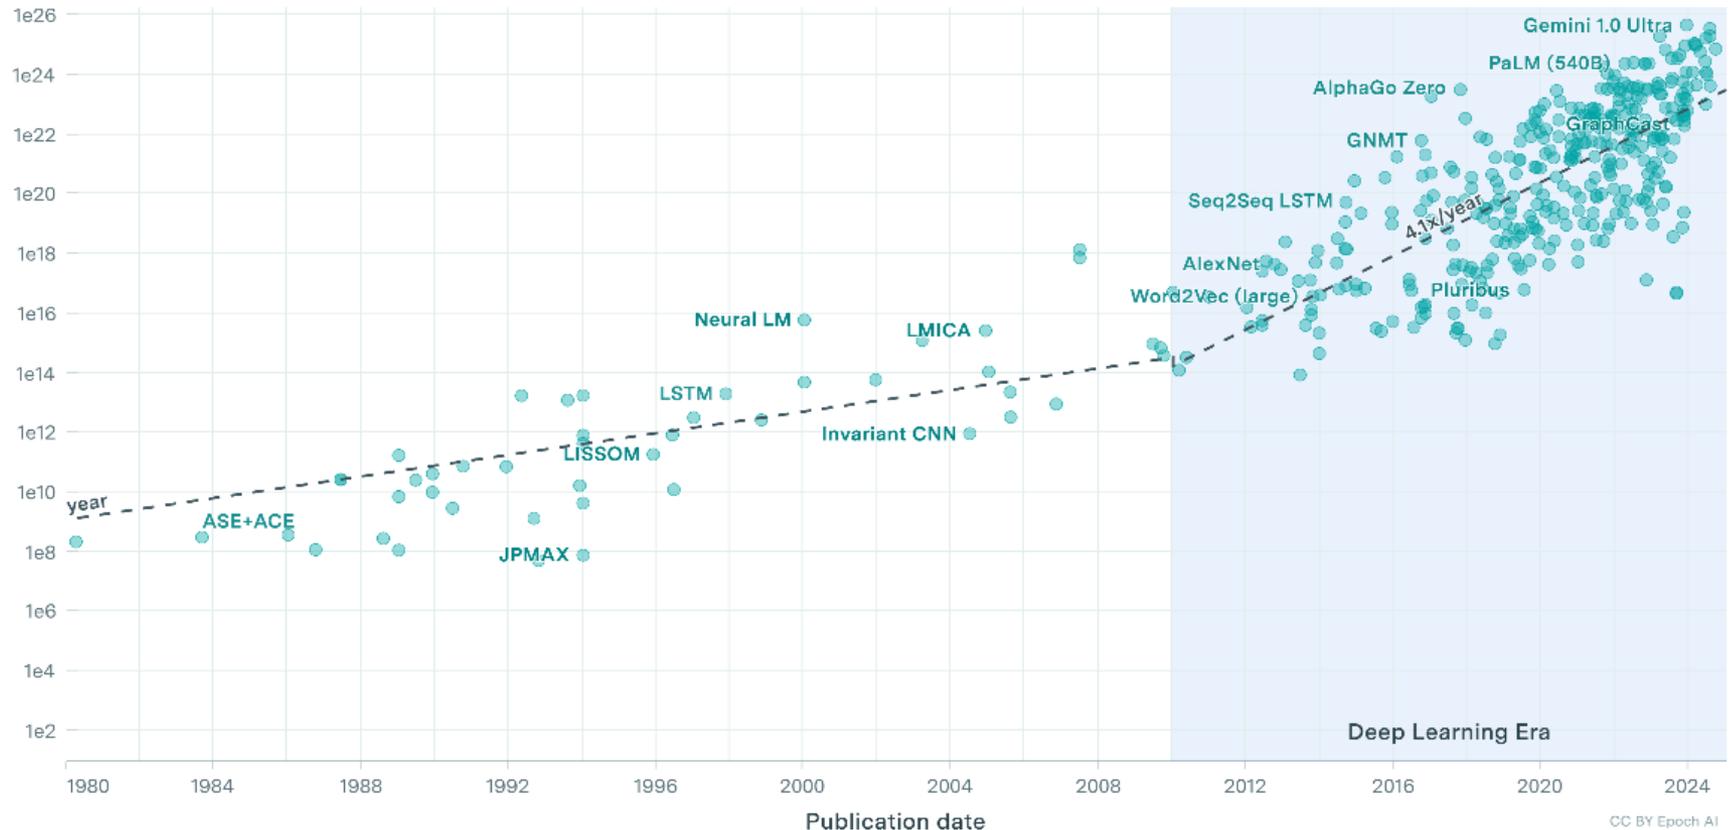
Top1 @2023: BASIC-L (2440Mパラメータ)

<https://paperswithcode.com/sota/image-classification-on-imagenet>

# AIモデルの発展

## Notable AI Models

### Training compute (FLOP)

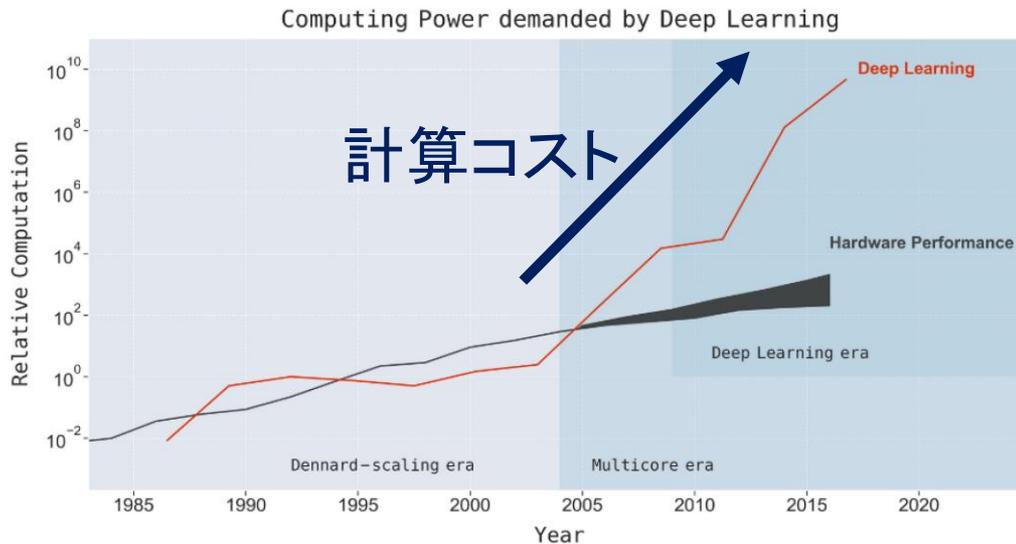


訓練に莫大な計算コストが必要

Epoch AI, 'Data on Notable AI Models'.

<https://epochai.org/data/notable-ai-models> 11

# 機械学習の課題



機械学習による  
複雑な計算の実現の一方で

計算コストの増大  
エネルギー効率に課題

N. C. Thompson et al., Preprint at <https://arxiv.org/abs/2007.05558v1> (2020).

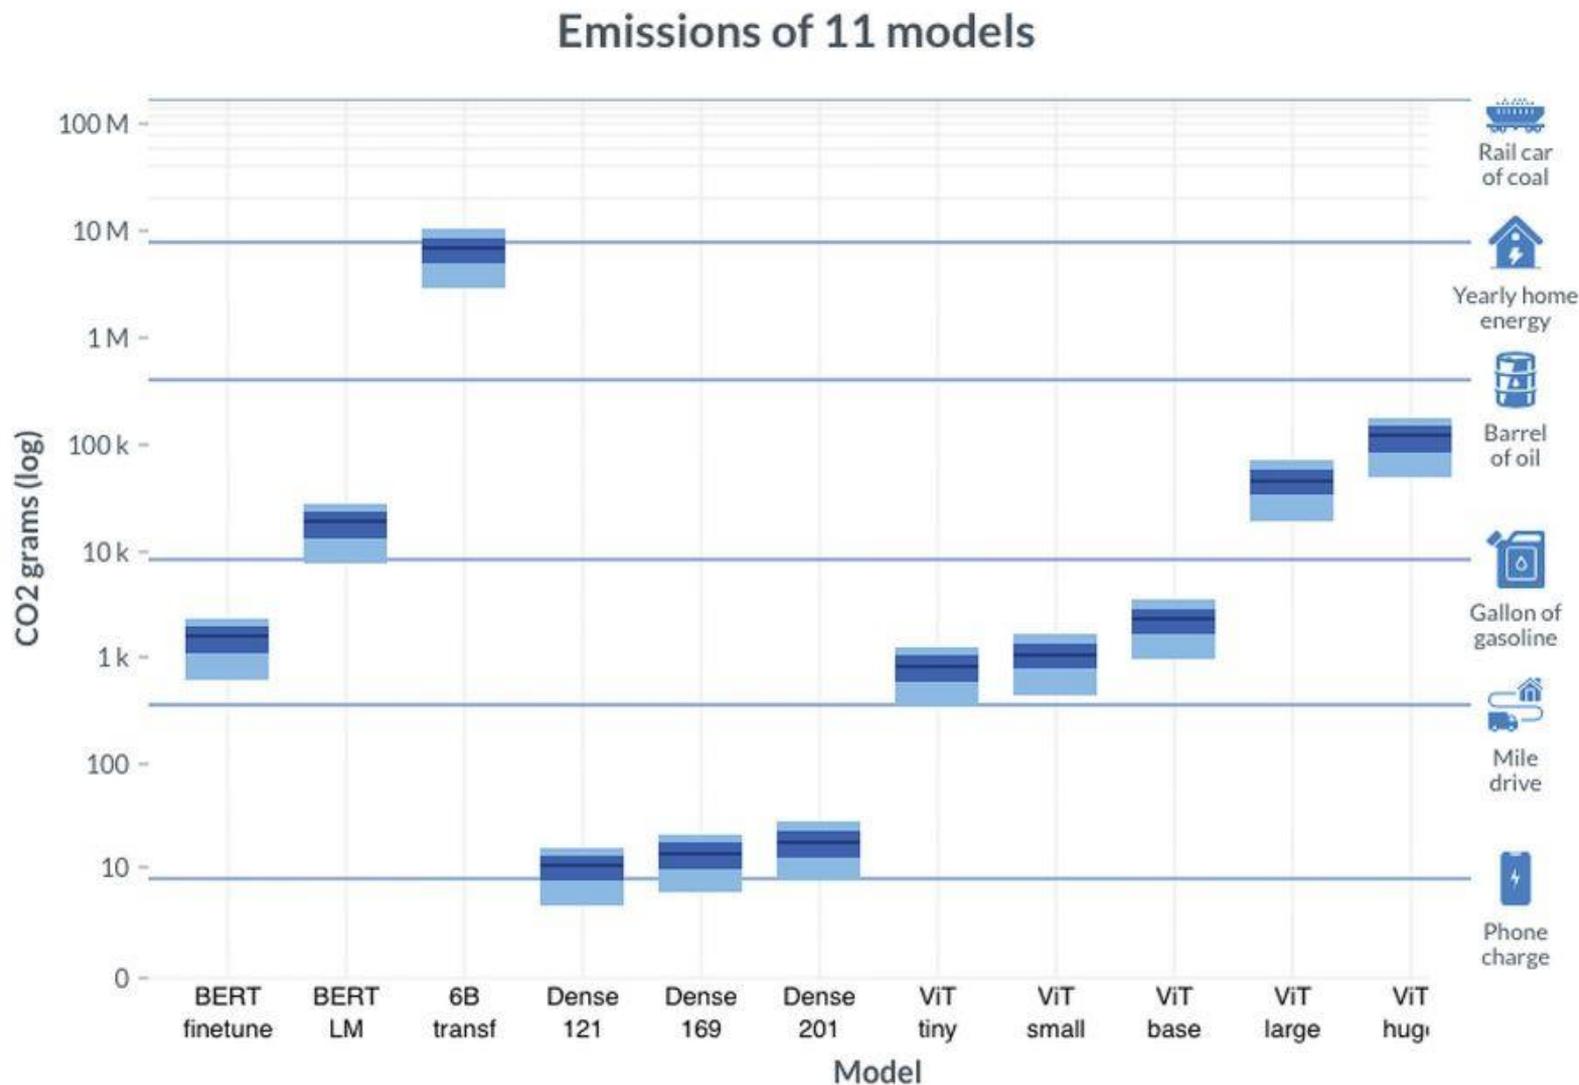
## □ エネルギー効率に大きな課題

- ヒト脳: 140億の神経細胞と50兆のシナプス結合



ヒト脳の消費電力	~20 W
計算機で同等のネットワーク の実現に必要な電力	1200 万 W

# モデル訓練時に排出するCO2量



# 大規模言語モデルGPT-3のコスト

## □ GPT-3 (Chat-GPTに使用される前のモデル)

- パラメータ数: 1750億個

- 学習データ量: 570GB以上 (オリジナルは45TB)

<https://platform.openai.com/docs/model-index-for-researchers>

- 訓練コスト

- 50台のAIサーバ(DGX-2)を36日使用して訓練

- $50 \times 10\text{kW} \times 36\text{days} \times 24\text{hours/day} = 432 \text{ MWh}$

- 排出二酸化炭素: 194トン

<https://blog.inten.to/gpt-3-language-models-are-few-shot-learners-a13d1ae8b1f9>

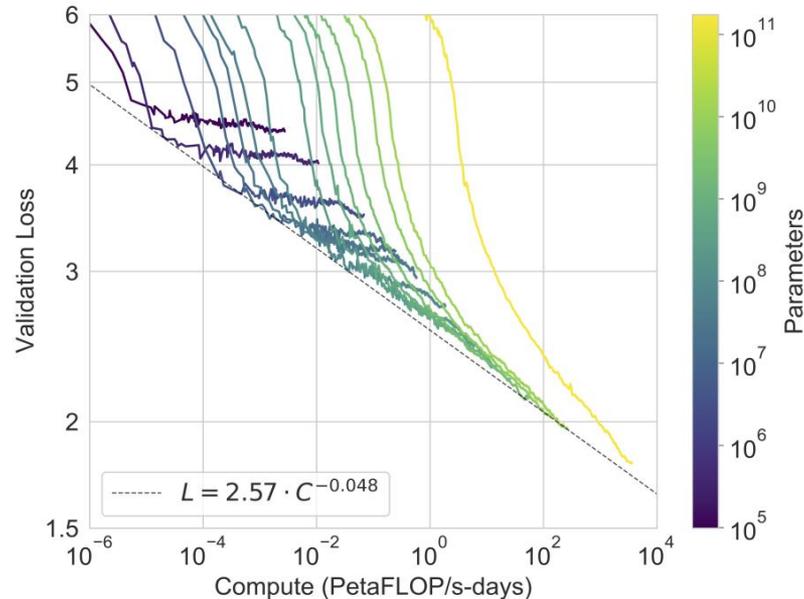
## □ GPT-3.5 (無料版Chat-GPTに使用)

- パラメータ数: 1.75兆個

# パラメータ数と性能 (GPT-3)

## □ パラメータ数を増やすと性能が向上する

Model Name	$n_{\text{params}}$	$n_{\text{layers}}$	$d_{\text{model}}$	$n_{\text{heads}}$	$d_{\text{head}}$	Batch Size	Learning Rate
GPT-3 Small	125M	12	768	12	64	0.5M	$6.0 \times 10^{-4}$
GPT-3 Medium	350M	24	1024	16	64	0.5M	$3.0 \times 10^{-4}$
GPT-3 Large	760M	24	1536	16	96	0.5M	$2.5 \times 10^{-4}$
GPT-3 XL	1.3B	24	2048	24	128	1M	$2.0 \times 10^{-4}$
GPT-3 2.7B	2.7B	32	2560	32	80	1M	$1.6 \times 10^{-4}$
GPT-3 6.7B	6.7B	32	4096	32	128	2M	$1.2 \times 10^{-4}$
GPT-3 13B	13.0B	40	5140	40	128	2M	$1.0 \times 10^{-4}$
GPT-3 175B or “GPT-3”	175.0B	96	12288	96	128	3.2M	$0.6 \times 10^{-4}$



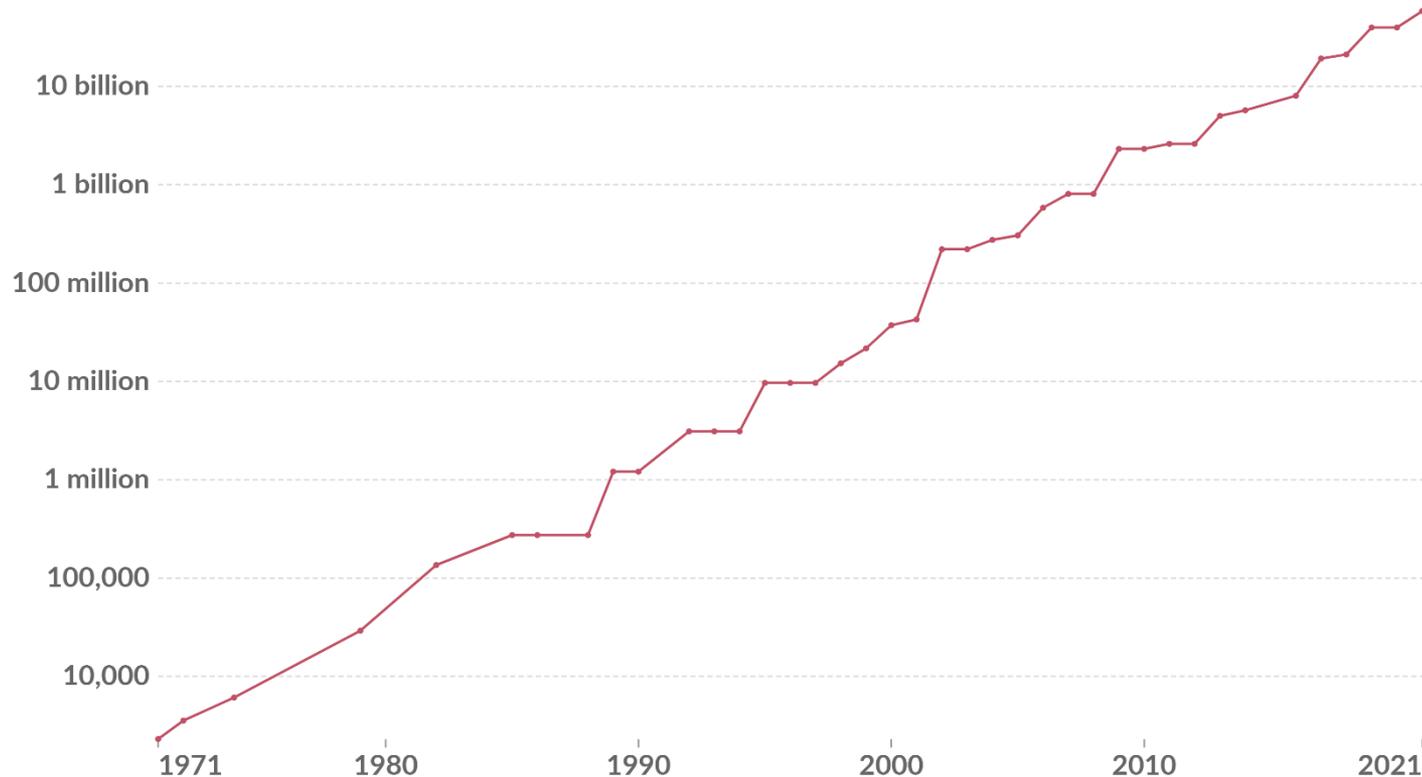
# ムーアの法則

## □ 集積回路のトランジスタ数が2年で2倍になる予測

Moore's law: The number of transistors per microprocessor

The number of transistors that fit into a microprocessor. The observation that the number of transistors on an integrated circuit doubles approximately every two years is called Moore's law<sup>1</sup>.

Our World  
in Data



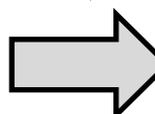
Source: Karl Rupp, Microprocessor Trend Data (2022)

OurWorldInData.org/technological-change • CC BY

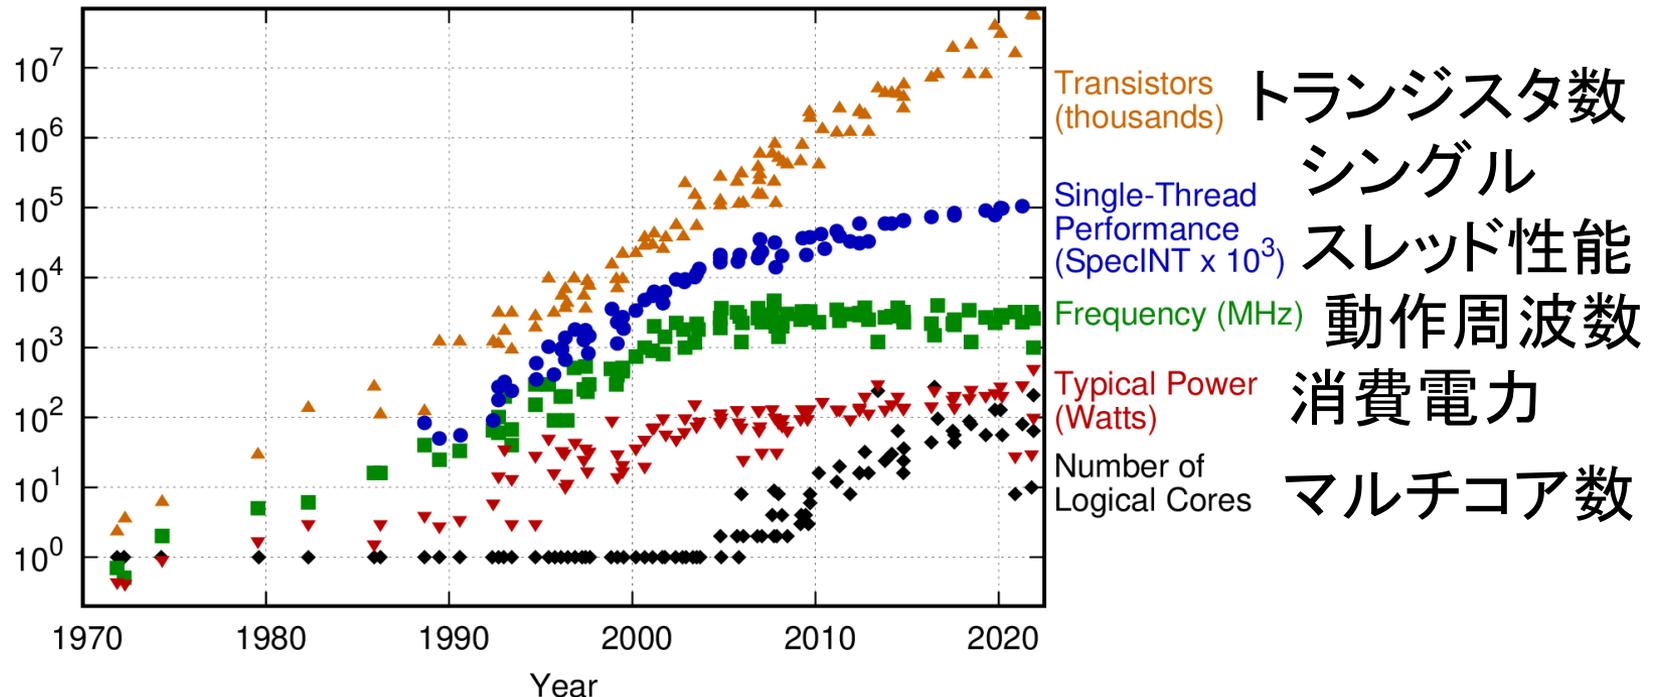
1. Moore's law: Moore's law is the observation that the number of transistors in a dense integrated circuit doubles about every two years, because of improvements in production.

# ムーアの法則の限界？

## □ ムーアの法則のスケールング測

- 半導体の微細化 (1/k) が進むと動作周波数が高速化 (k 倍), 消費電力が減少 (1/k)  限界を迎えてきている

50 Years of Microprocessor Trend Data



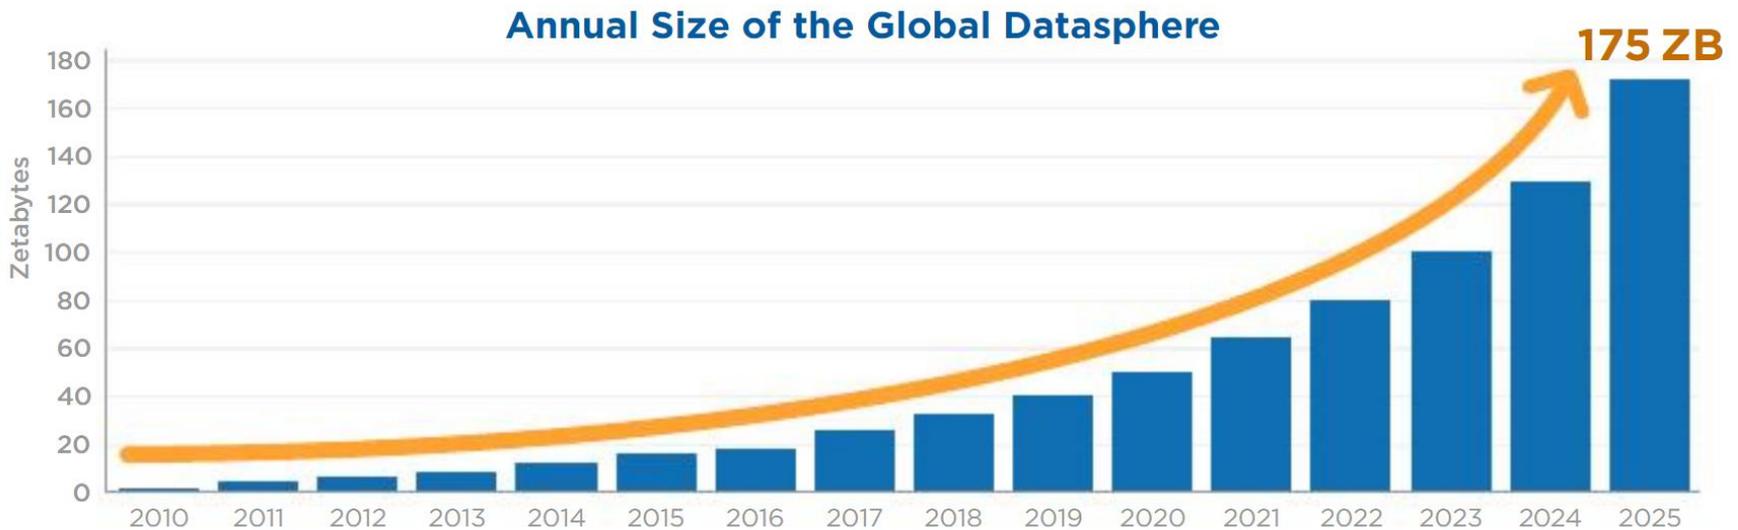
Original data up to the year 2010 collected and plotted by M. Horowitz, F. Labonte, O. Shacham, K. Olukotun, L. Hammond, and C. Batten  
New plot and data collected for 2010-2021 by K. Rupp

<https://github.com/karlrupp/microprocessor-trend-data>

# データ処理需要の増大

## □ 機械学習を含む計算需要の増大

- ムーアの法則ですらカバーできない速度



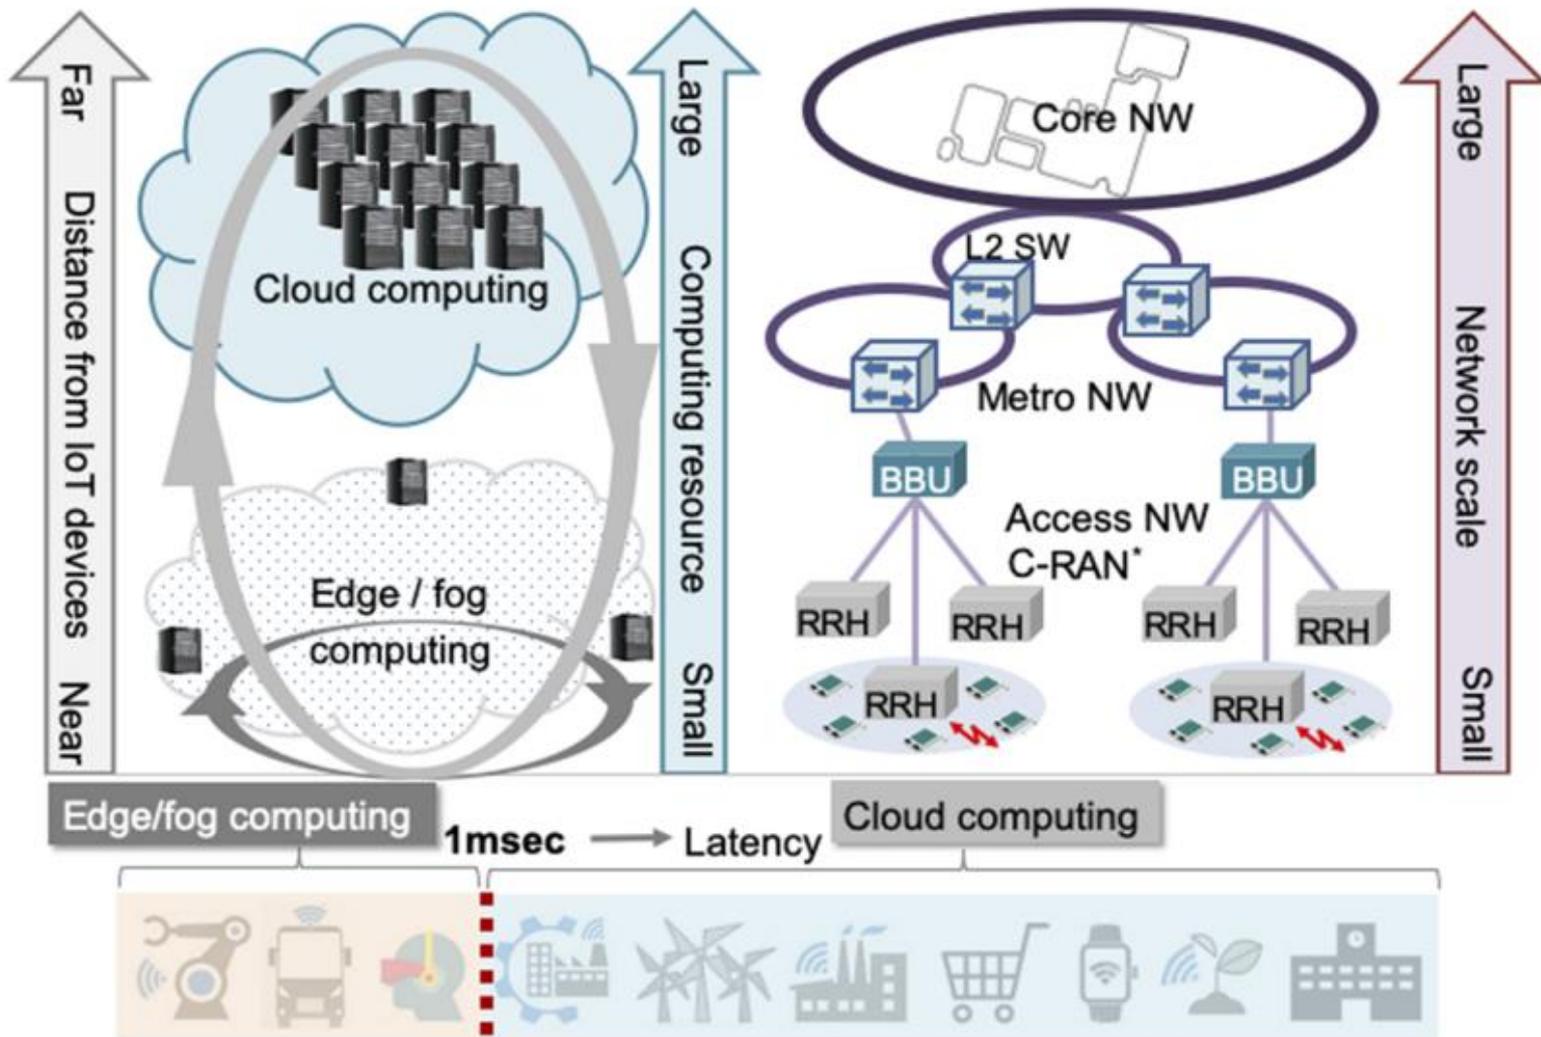
Source: Data Age 2025, sponsored by Seagate with data from IDC Global DataSphere, Nov 2018

[https://www.publickey1.jp/blog/16/qcon\\_tokyo\\_2016\\_3.html](https://www.publickey1.jp/blog/16/qcon_tokyo_2016_3.html)

## □ 集積回路の微細化に陰り

- 消費電力の限界 (100Wを超えると発熱の問題)
- 動作周波数の限界

# クラウドからエッジへ



K. Kitayama, et al., APL Photonics, 4, 090901 (2019).

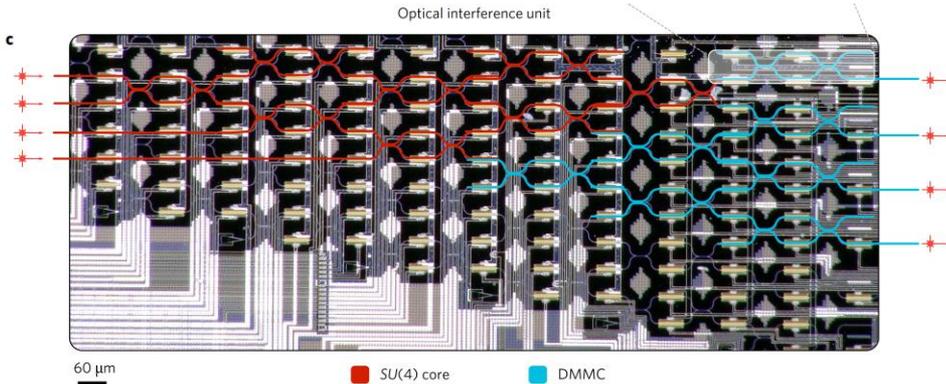
# 目次

---

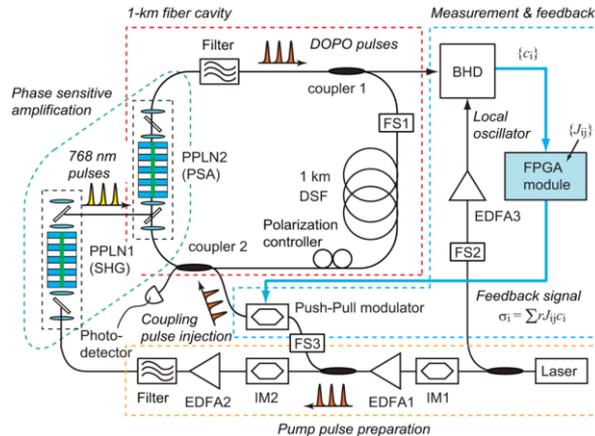
- 機械学習の発展と課題
- 機械学習への光の寄与, 光電融合
- 深層ネットワークの学習方法の基礎
- 物理リザバークンピューティング

# 新しい機械学習光ハードウェア

## ナノフォトニック回路を用いた深層学習



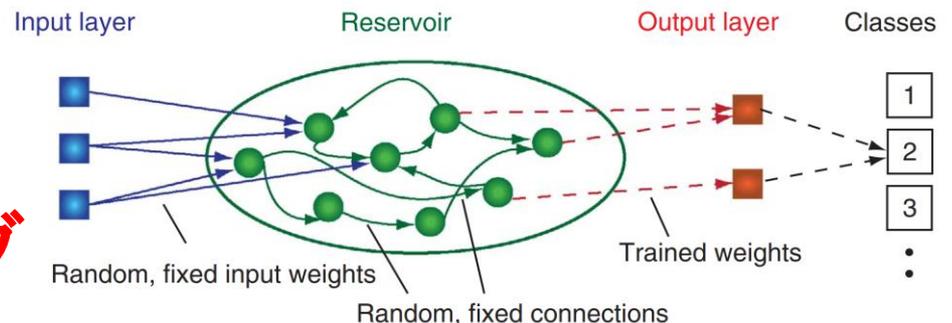
Y. Shen, et. al., Nature Photonics, **11**, 441 (2017).



## コヒーレントイジングマシン

T. Inagaki, et. al., Science, **354**, 603 (2016).

## リザーバコンピューティング

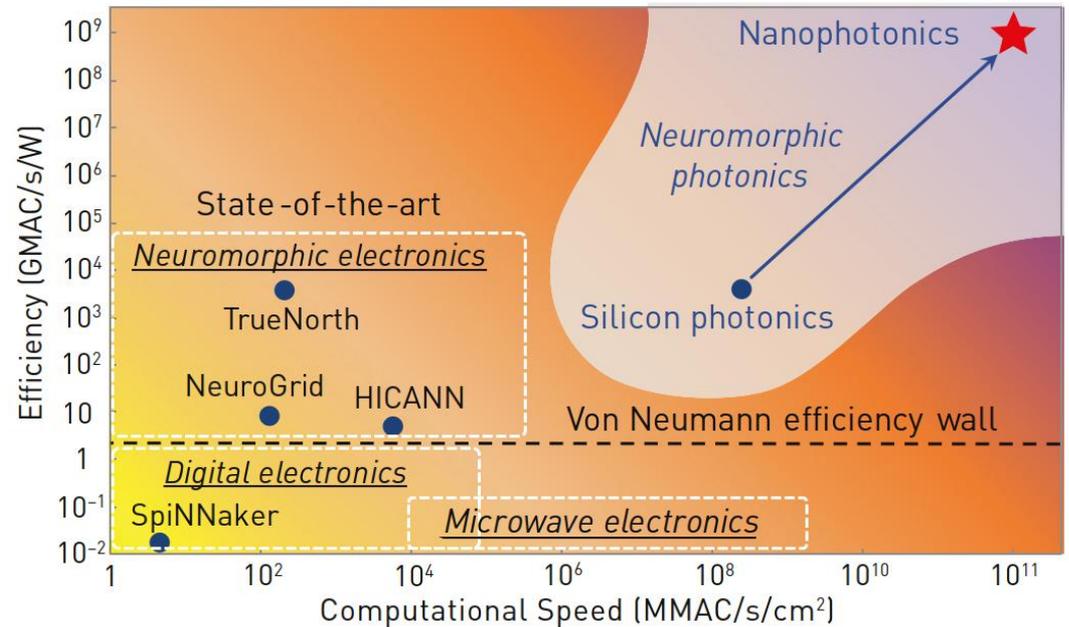


L. Appeltant, et. al., Nature Communications, **2**, 468 (2011).

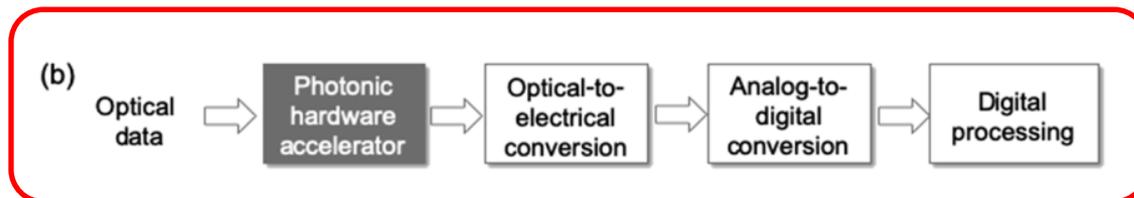
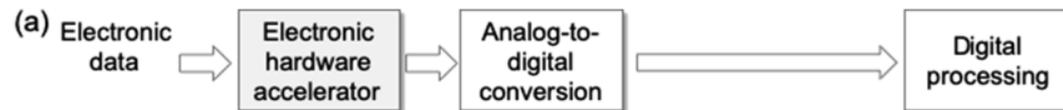
# 情報処理への光の利用と利点

- 広帯域 (~数百THz)
- 高いエネルギー効率
- 並列処理

M. A. Nahmias, et al., Opt. Photon. News, **29**, 34-41 (2018).



- アクセラレータとしての光 (光電融合)

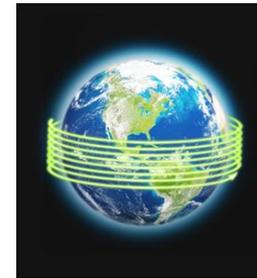
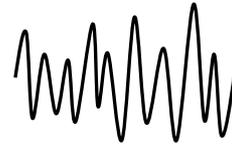


K. Kitayama, et al., APL Photonics, **4**, 090901 (2019).

# 光の利点

## □ 2つの意味で速い

- 進むのが速い(地球を1秒間に7.5周)
- 光の振動が速い



[https://global.canon/ja/technology/kids/mystery/m\\_01\\_03.html](https://global.canon/ja/technology/kids/mystery/m_01_03.html)

## □ 空間的な広がり

- 空間方向に並列に利用できる



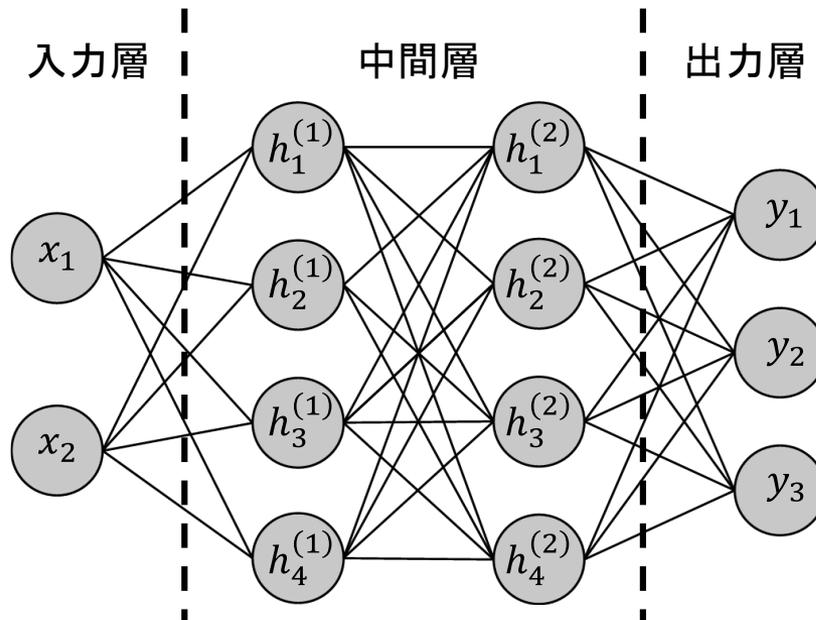
## □ 波長並列性

- 異なる波長の光を同時に利用できる



# ネットワークの計算を光で実装

- 高速かつ効率的な機械学習処理が可能



レーザなどの光技術

光実装

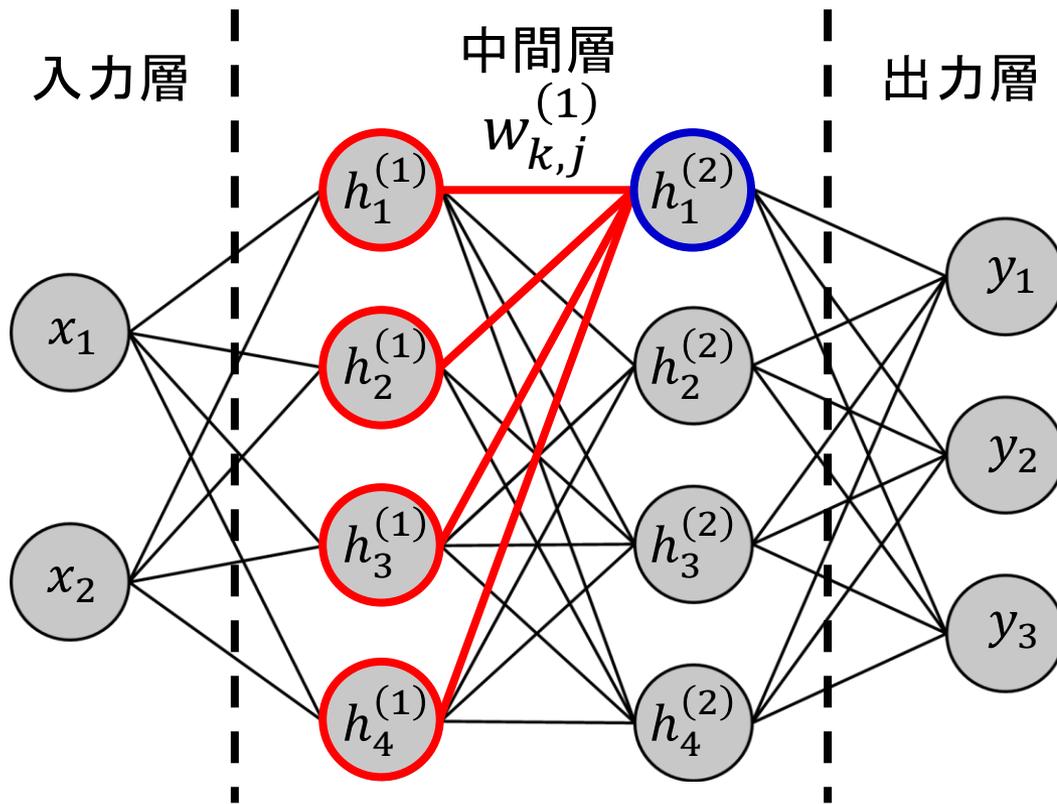


どのような計算を行う必要があるのか？

どのような光技術を用いることができるのか？



# ネットワークの積和演算



$$h_j^{(m)} = f(a_j^{(m)})$$

$a_j^{(m)}$ : ( $m$ )層の内部状態

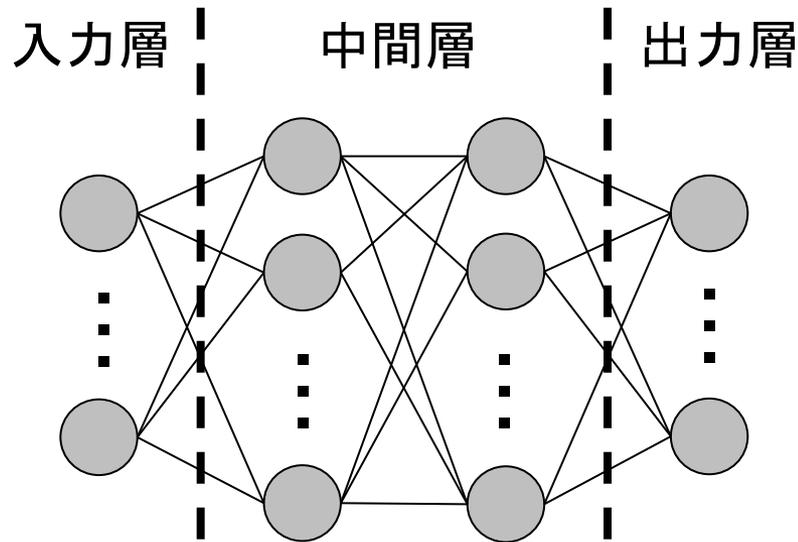
$N^{(m)}$ : ( $m$ )層のノード数

$w_{k,j}^{(m)}$ : 結合重み

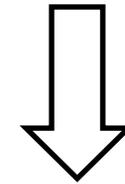
中間層2層目の1番目のノード(青色)への入力(赤色)

$$a_1^{(2)} = w_{1,1}^{(1)} h_1^{(1)} + w_{2,1}^{(1)} h_2^{(1)} + w_{3,1}^{(1)} h_3^{(1)} + w_{4,1}^{(1)} h_4^{(1)}$$

# 結合重みの数



中間層の層数:  $N_L$ 層  
中間層1層のノード数:  $N$ ノード



中間層の  
結合重みの数:  $N^2 \times (N_L - 1)$

中間層の層数:  $N_L = 3$ 層  
中間層のノード数:  $N = 10$ ノード

⇒ 結合パラメータ数: 200

中間層の層数:  $N_L = 3$ 層  
中間層のノード数:  $N = 100$ ノード

⇒ 結合パラメータ数: 20000

# 光を用いた積和演算技術

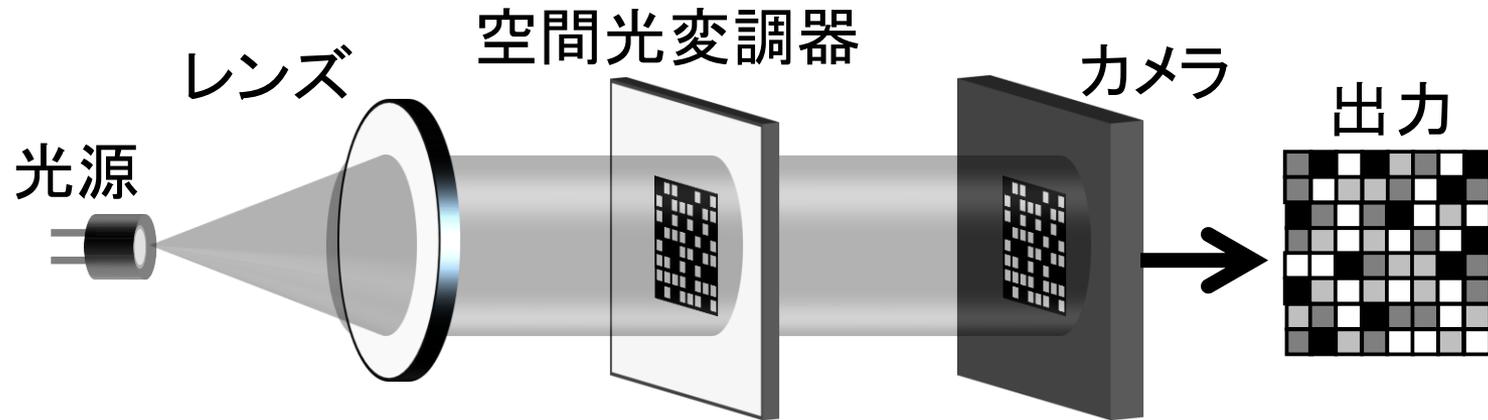
---

- 光の空間並列性を用いる方法
- 光の干渉性を用いる方法
- 光共振器を用いる方法

# 光の空間並列性

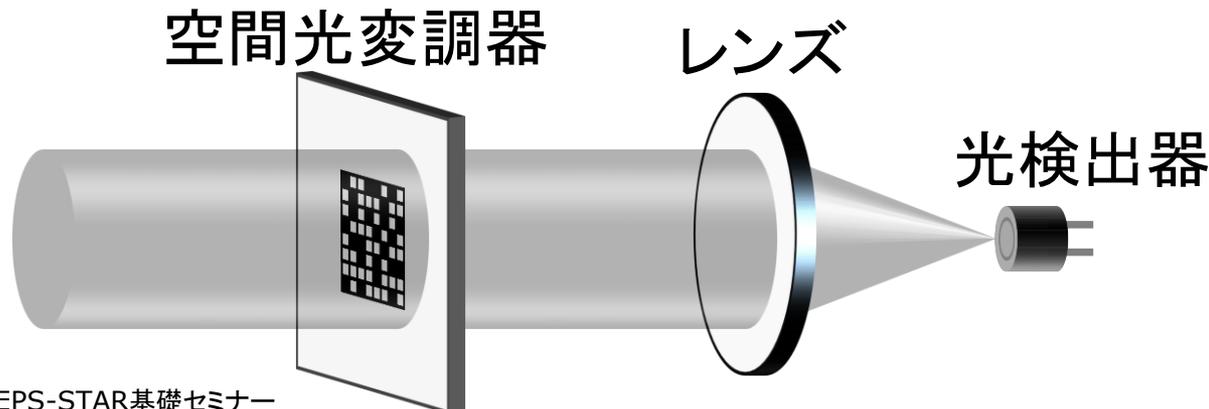
## □ 光はレンズで拡大できる

- 光の空間方向にノードの出力を拡大できる

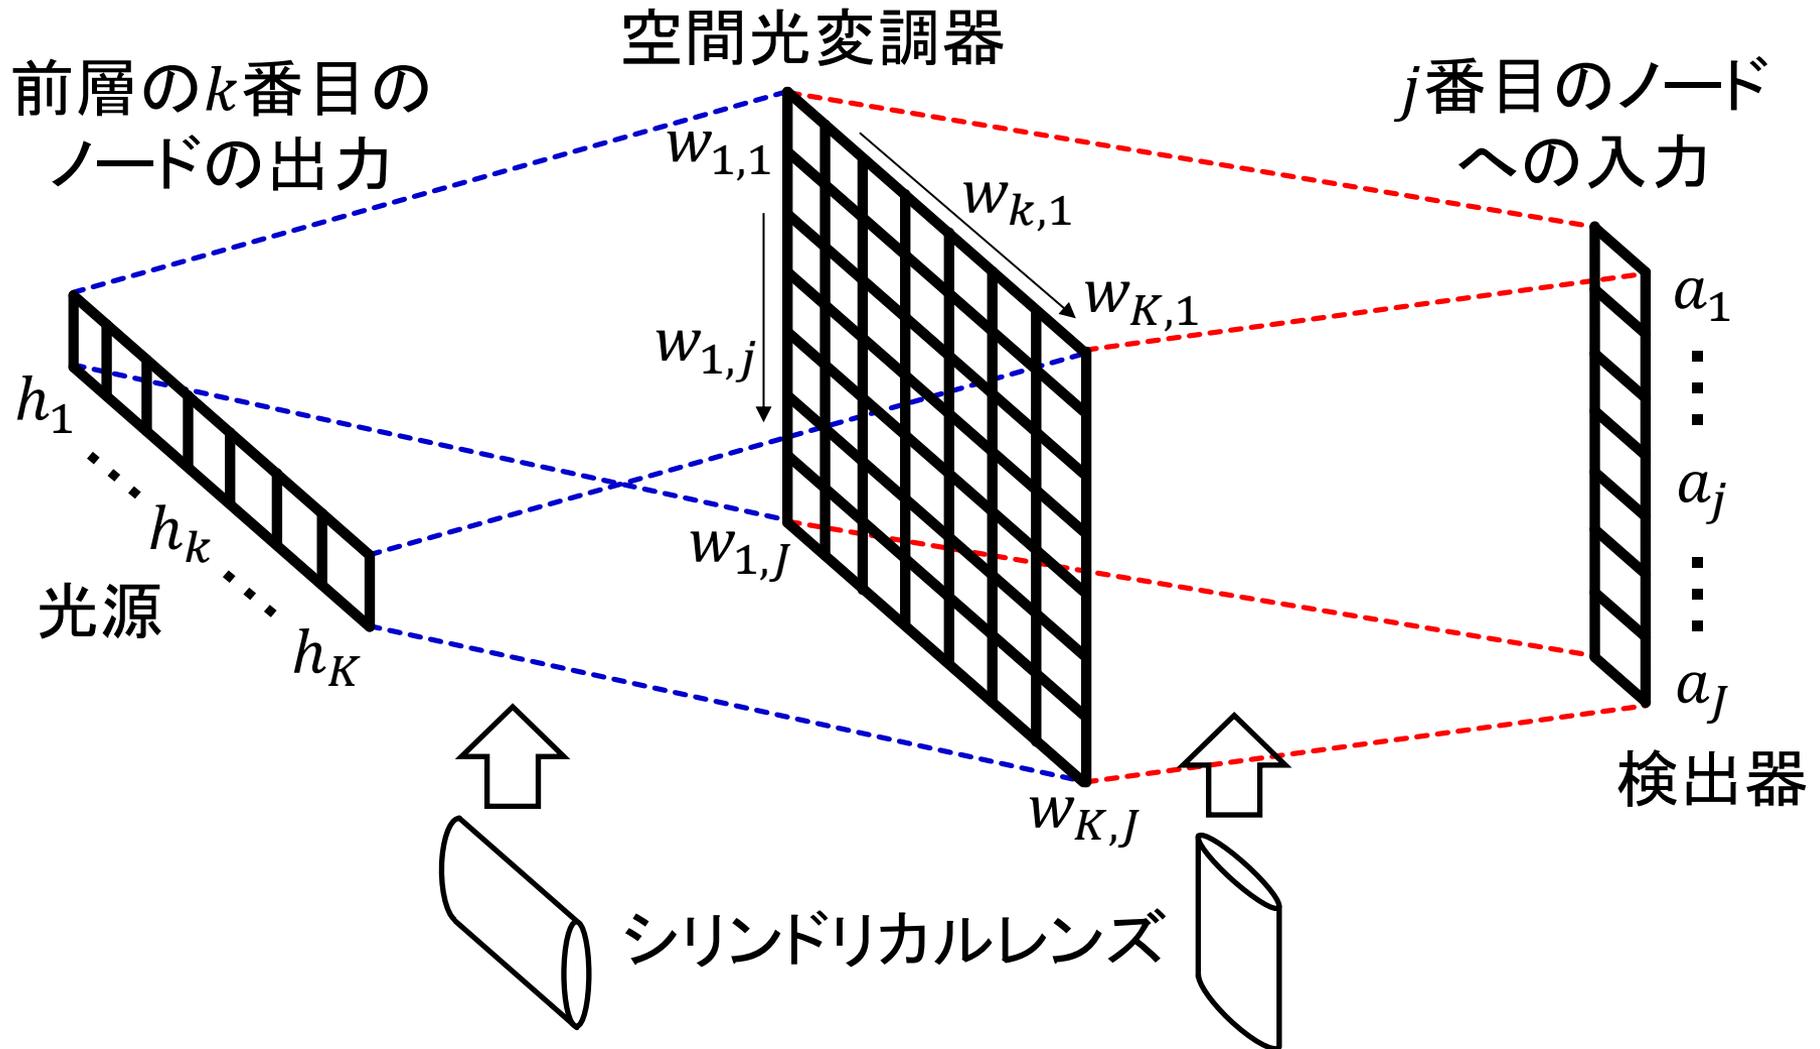


## □ 光はレンズで集光できる

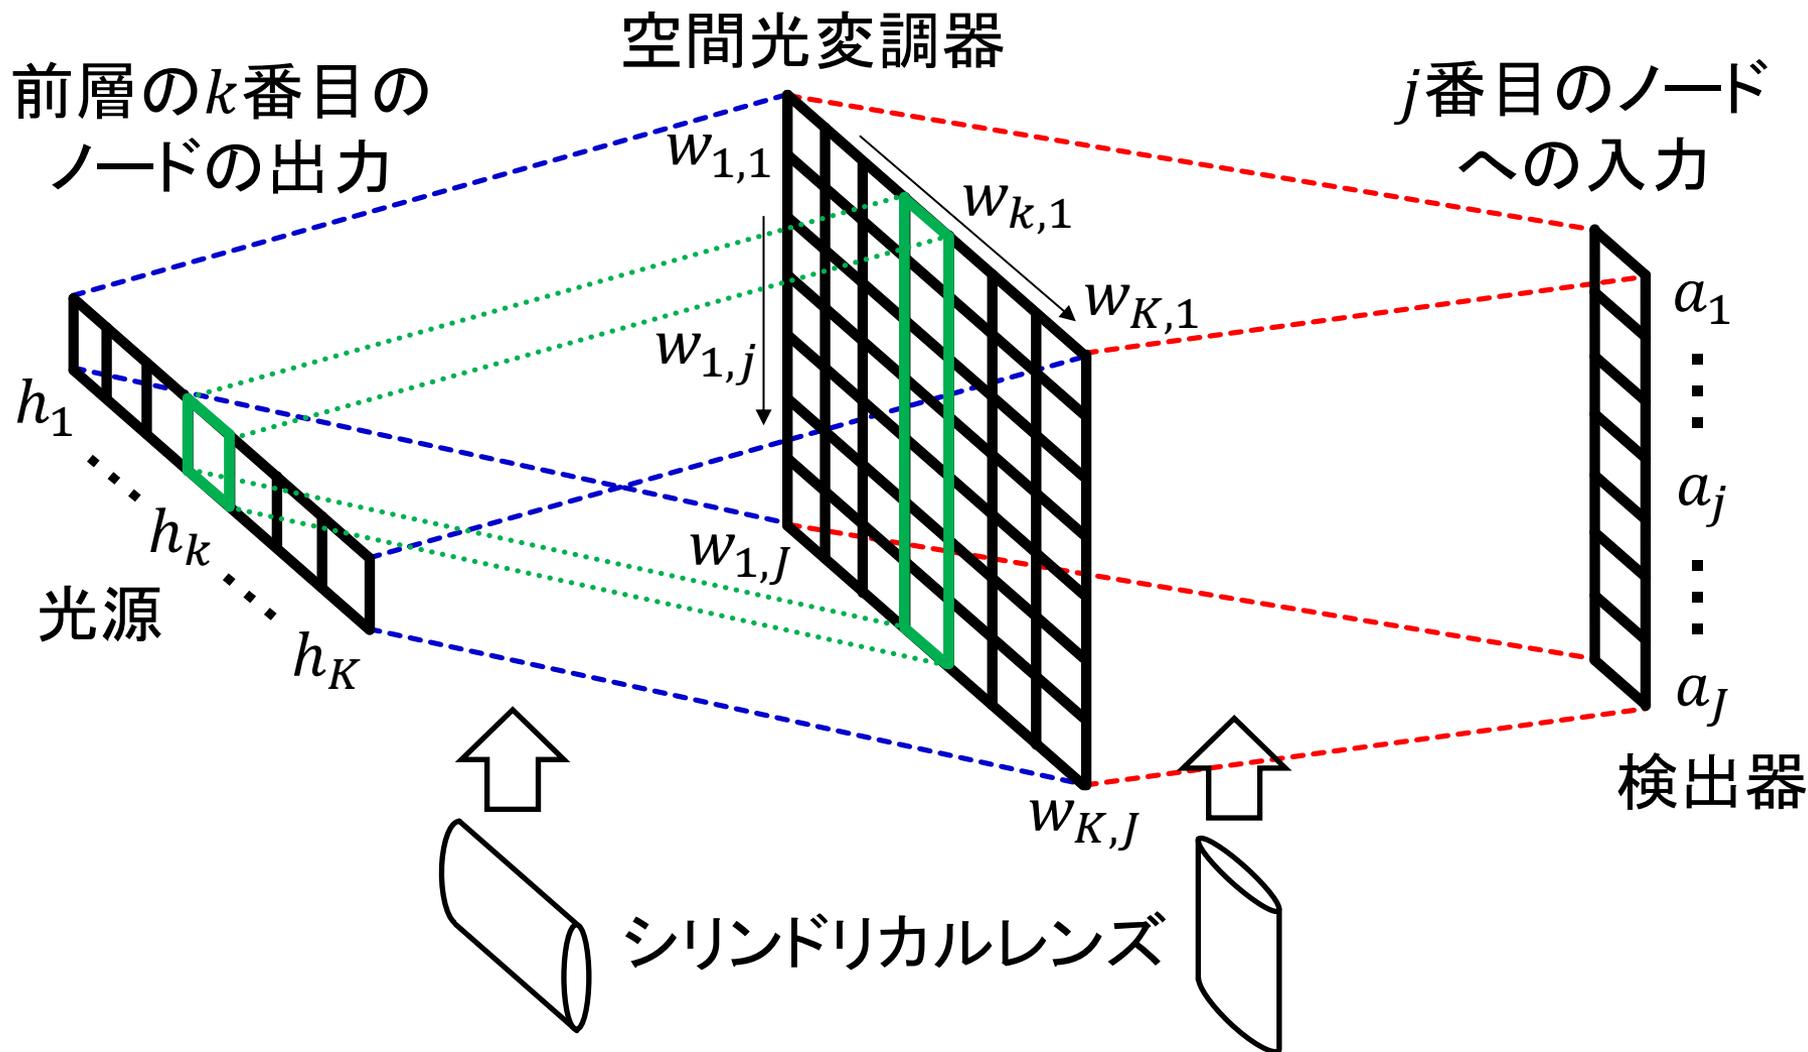
- 光パワーの和を計算できる



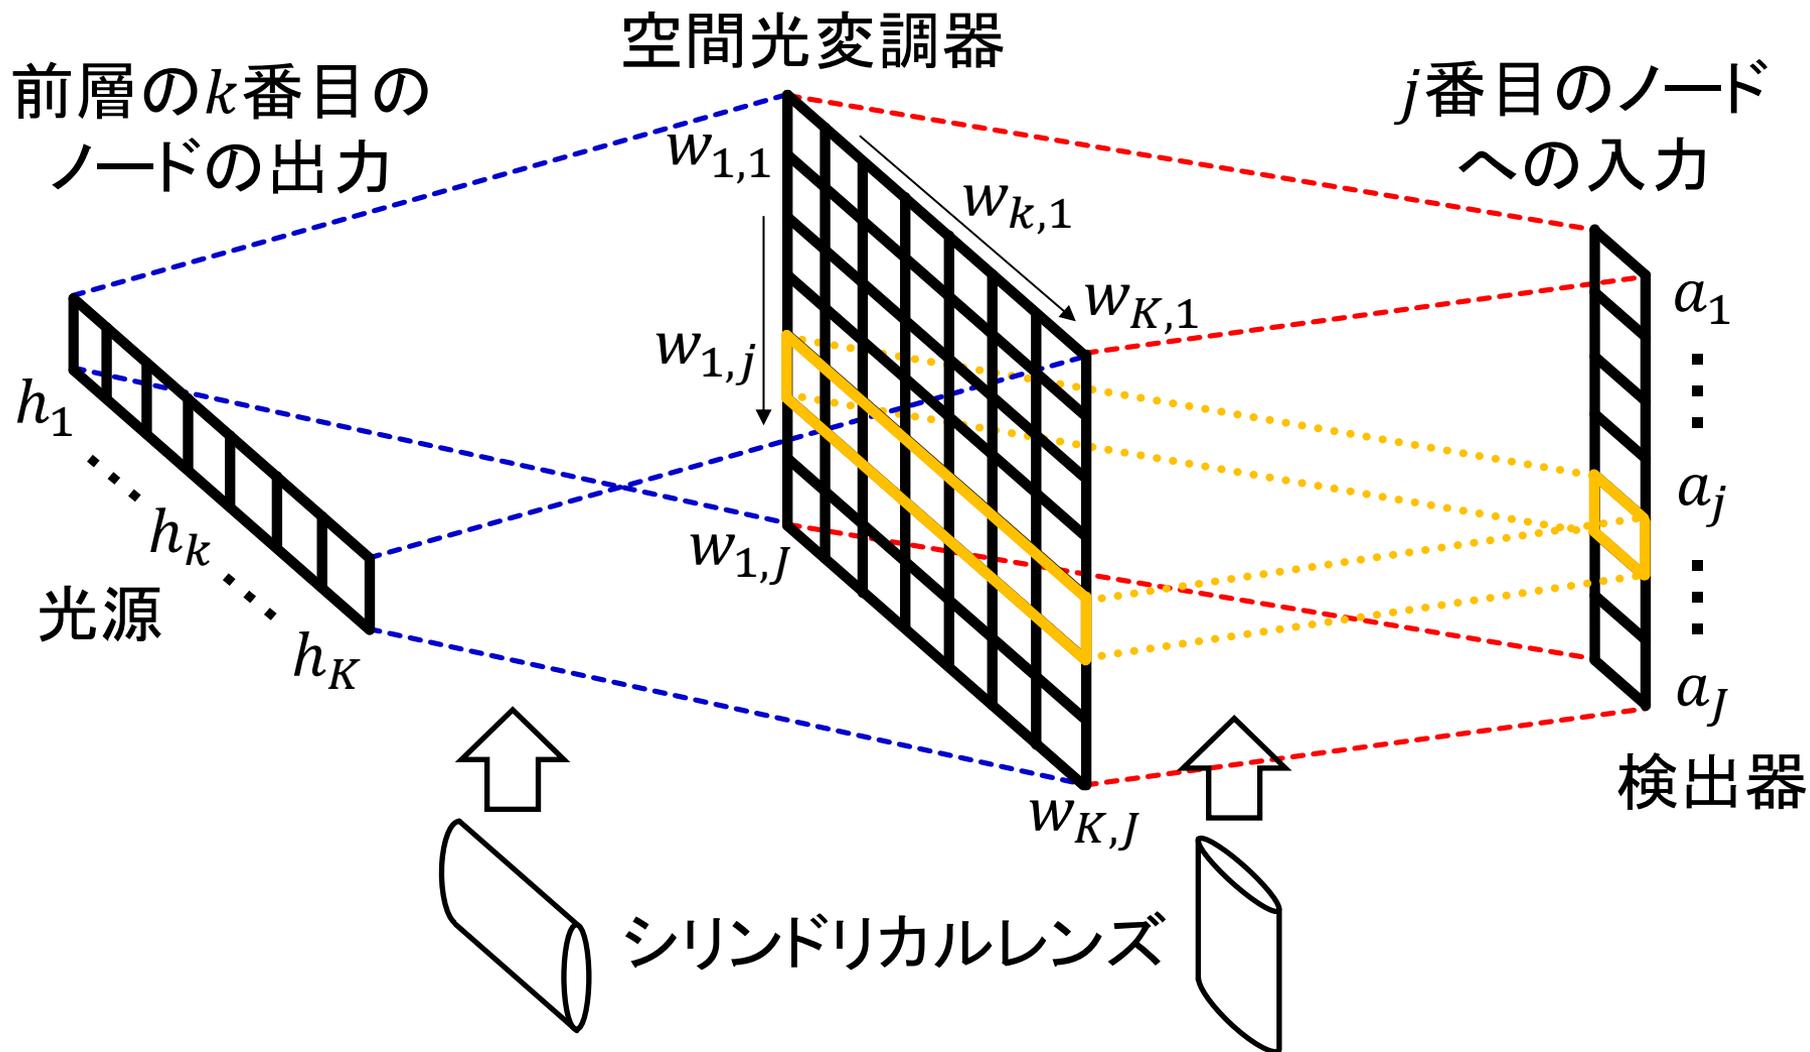
# レンズと空間光変調器による積和演算



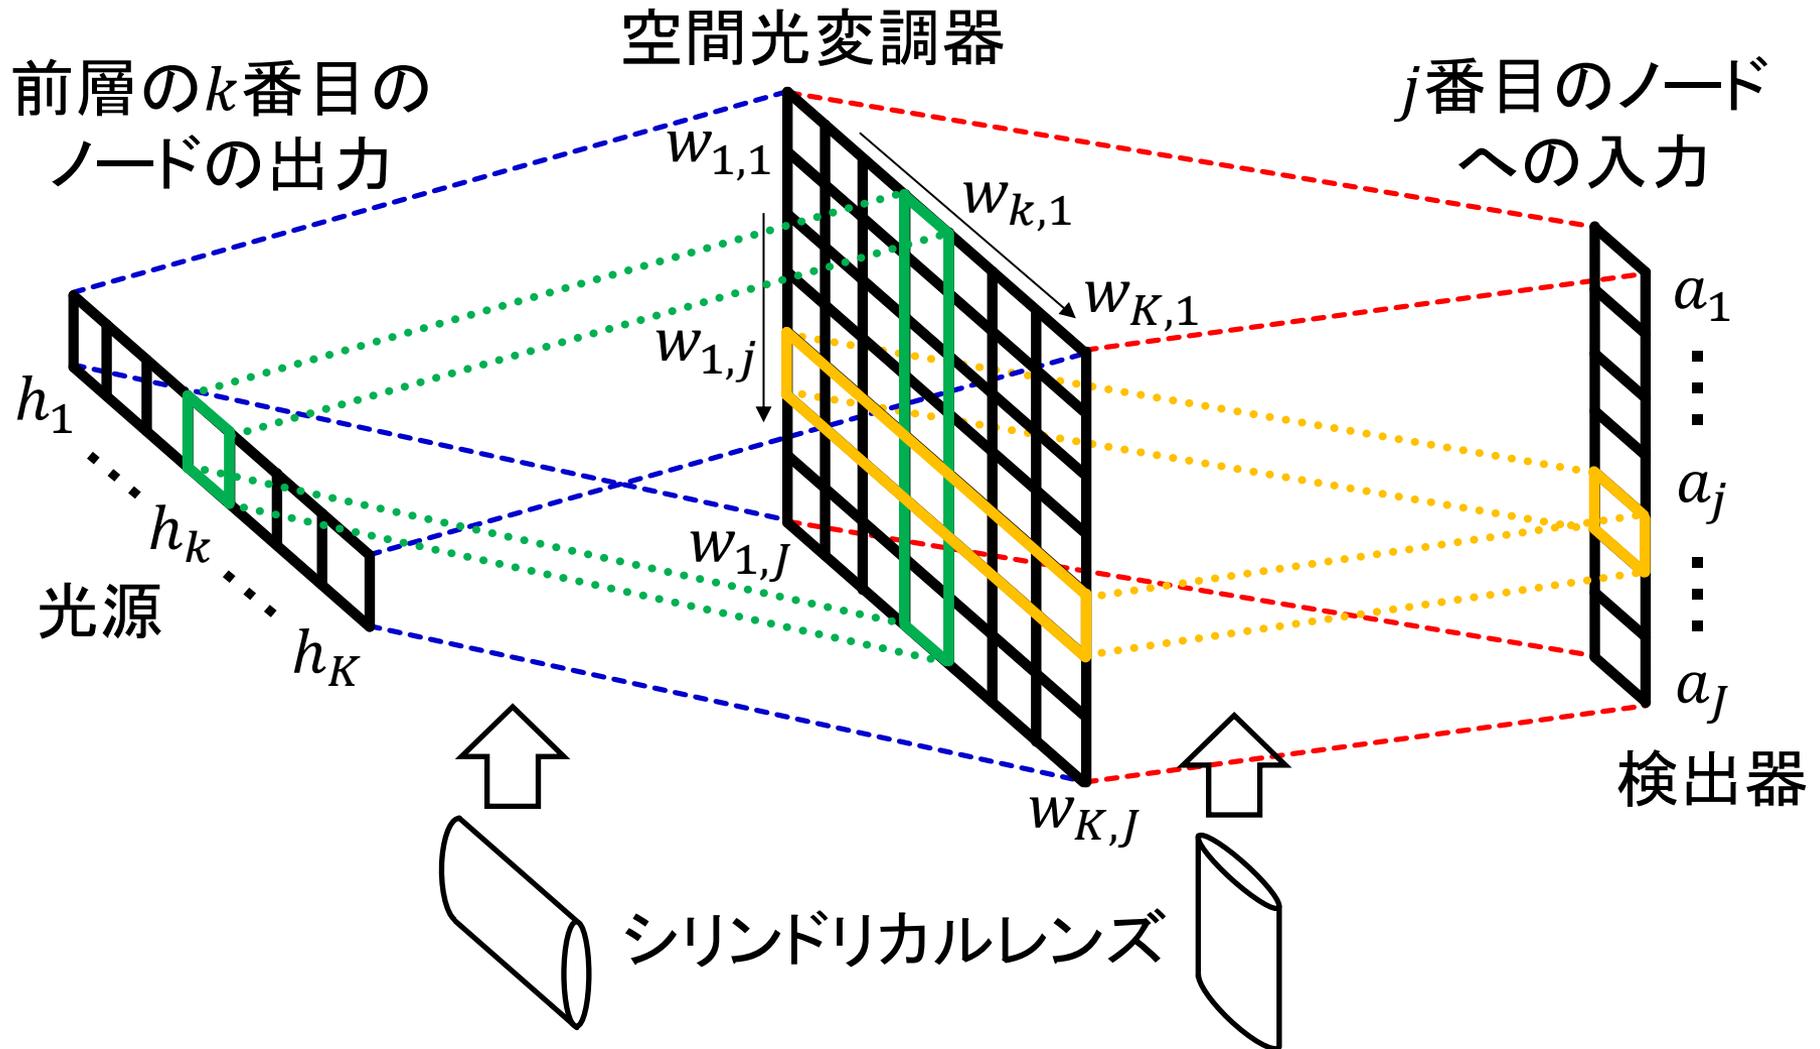
# レンズと空間光変調器による積和演算



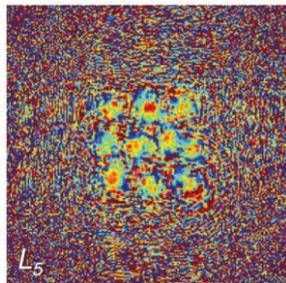
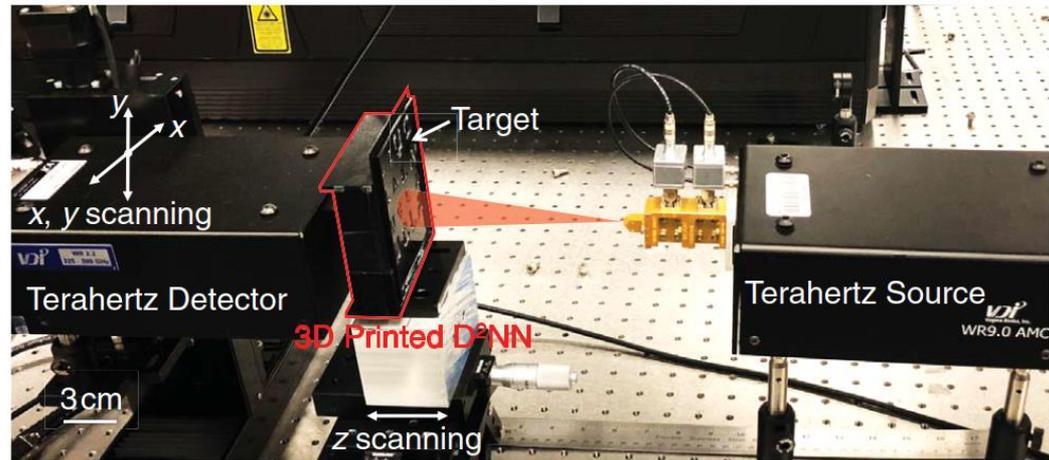
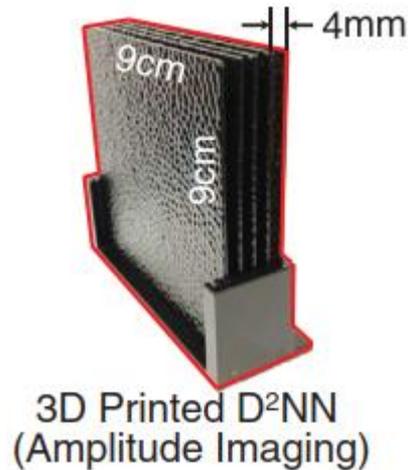
# レンズと空間光変調器による積和演算



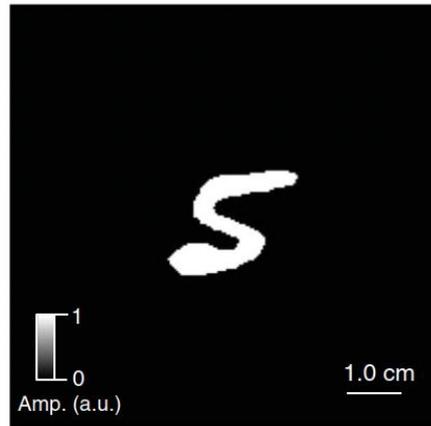
# レンズと空間光変調器による積和演算



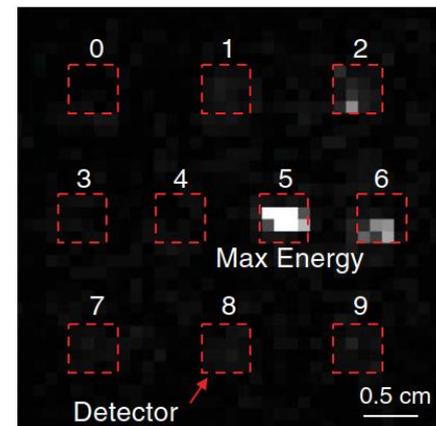
# 空間光散乱を用いた深層学習



A Input Digit (Number 5)



Output Distribution

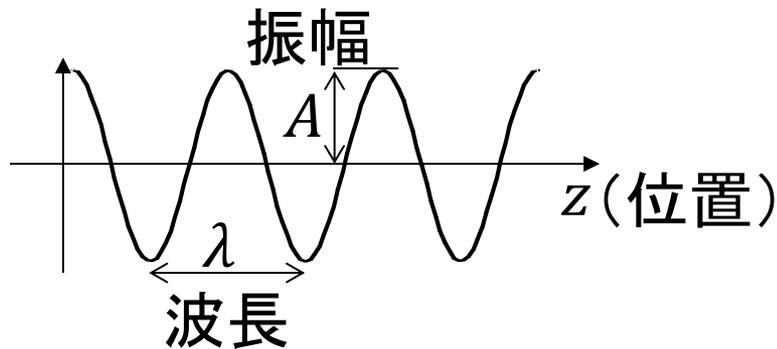


X. Lin et al., "All-optical machine learning using diffractive deep neural networks," *Science*, Vol. 361, pp. 1004-1008 (2018).

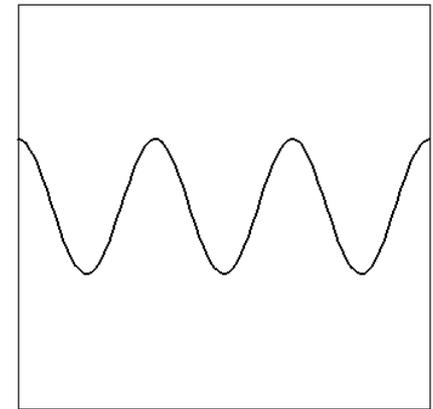
# 光の干渉性を用いる方法

## □ 光波

- 光は波としての性質を持つ



時間  $t$  を変化



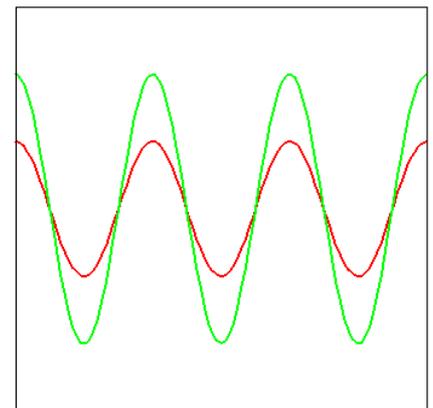
位置  $z$

## □ 光波の干渉

- 複数の波が強め合ったり弱め合う現象

黒線と赤線の波が干渉 → 緑線

時間  $t$  を変化

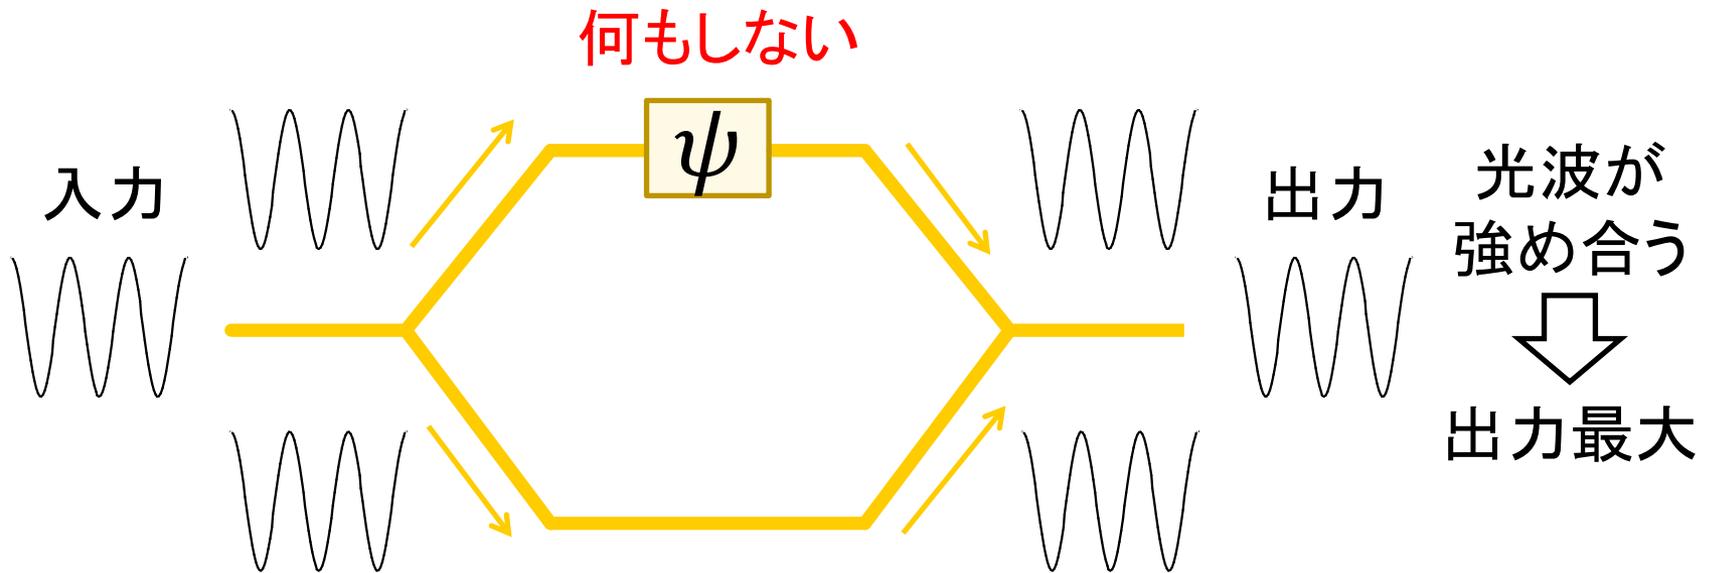


位置  $z$

# 光コンピューティングのための回路

## □ マツハ-ツェンダー干渉回路

- 光の干渉を利用して出力光の強さを変化させる光回路

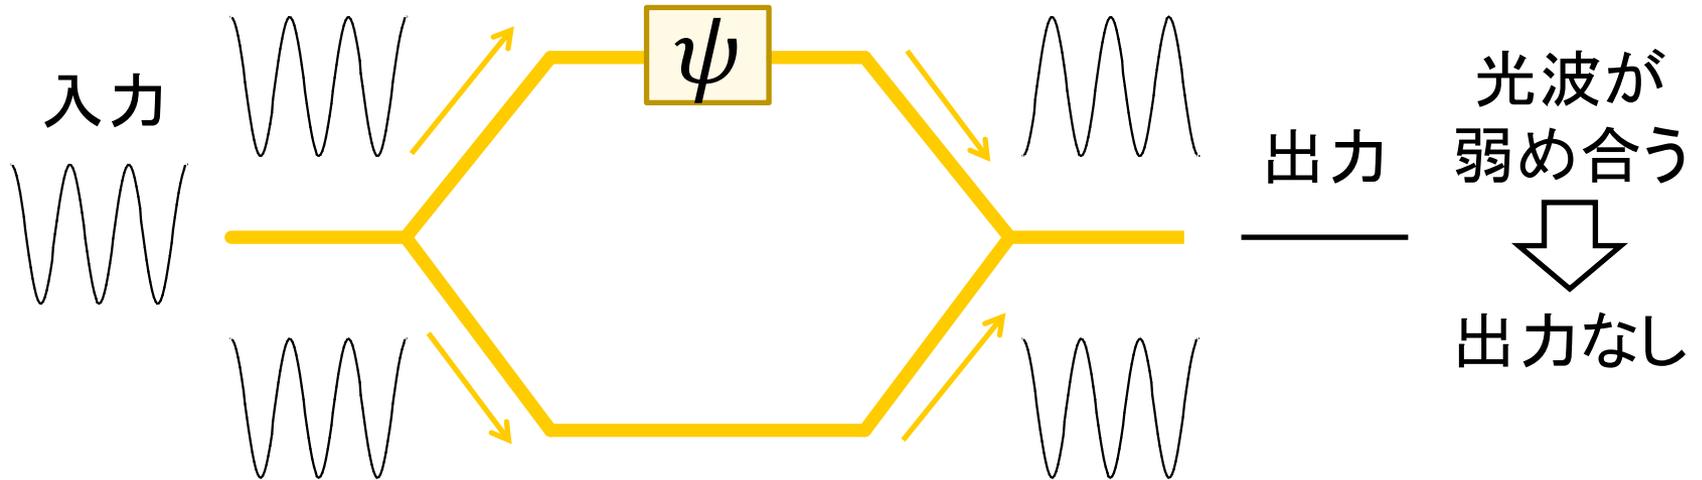


# 光コンピューティングのための回路

## □ マツハ-ツェンダー干渉回路

- 光の干渉を利用して出力光の強さを変化させる光回路

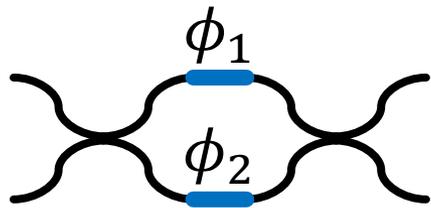
光波のタイミングを変化  
(位相)



光波のタイミング(位相)をずらして光の強さを制御

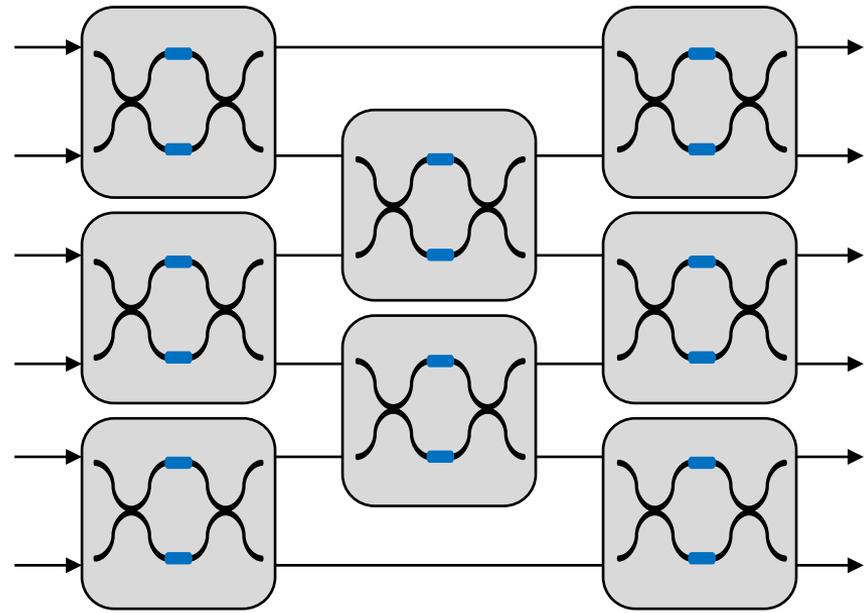
# 積和演算用マツハツェンダ回路

マツハツェンダ干渉回路



多数並べる

マツハツェンダアレイ



光を通過させるだけで  
積和演算を実現

光速演算

# 光共振器を用いる方法

## □ 波長

- 光は波としての性質を持つため、波長(波の長さ)を持つ



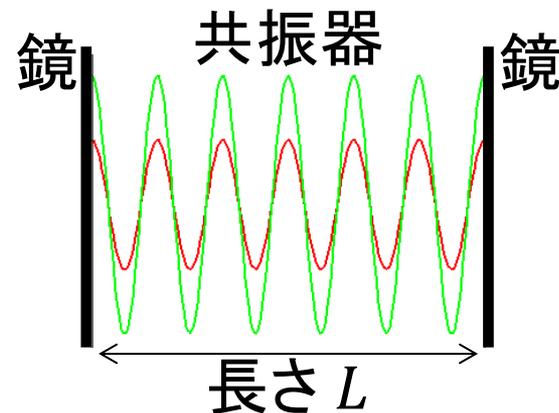
## □ 光共振器

- 光を内部に閉じ込めるような装置
- 共振器の長さ  $L$  と光波長  $\lambda$  が以下の関係を満たす

$$n_{\text{eff}}L = m\lambda$$

$n_{\text{eff}}$ : 屈折率

$m$ : モード(自然数)



# リング共振器

- ある波長  $\lambda_{\text{res}}$  を持つ光のみを取り出す共振器
  - リングの円周長を共振条件を満たすように設定する

多数の波長を含む光

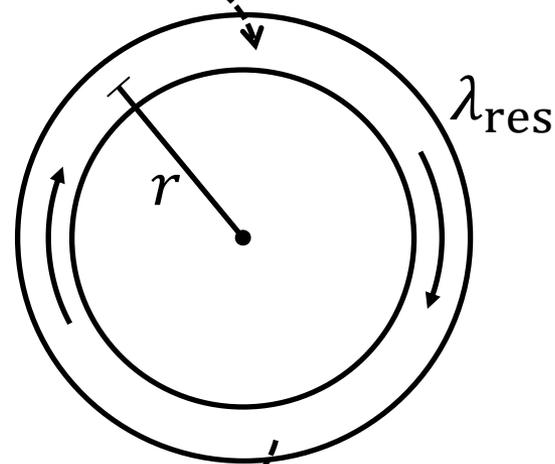


$\lambda_1, \lambda_2, \dots, \lambda_{\text{res}}, \dots$

共振条件

$$2\pi r n_{\text{eff}} = m\lambda_{\text{res}}$$

光カプラ



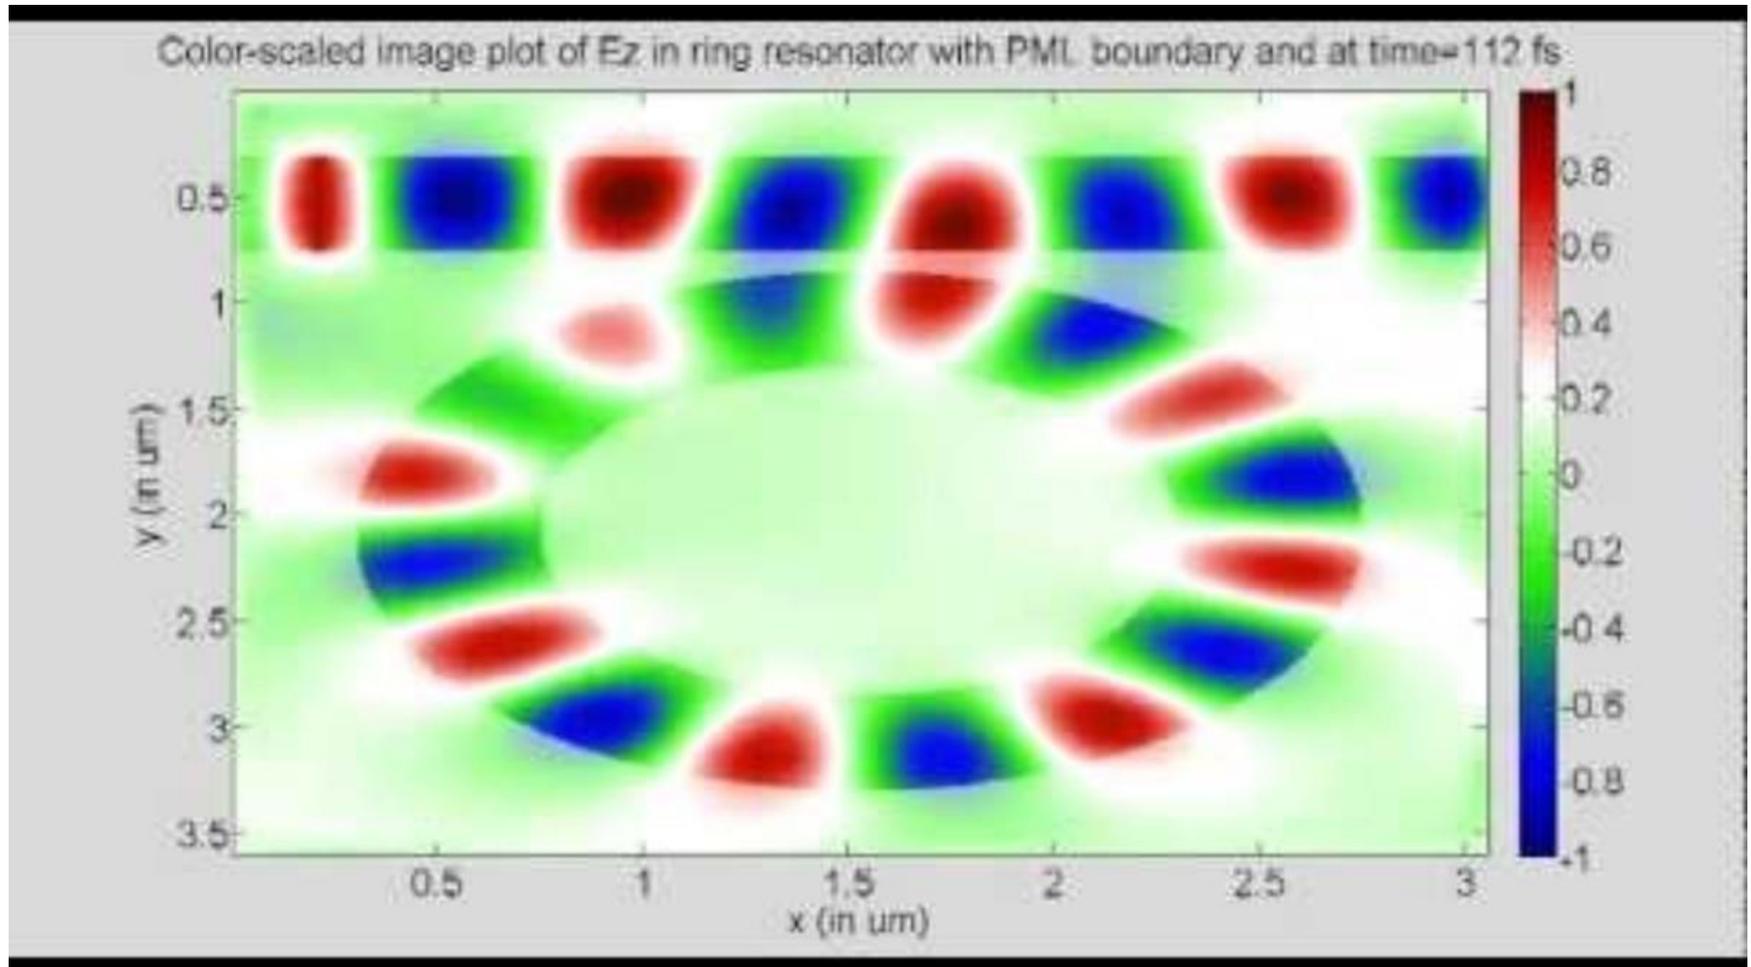
1つの波長の光のみ取り出す

出力  $\lambda_{\text{res}}$



光カプラ

# リング共振器のシミュレーション

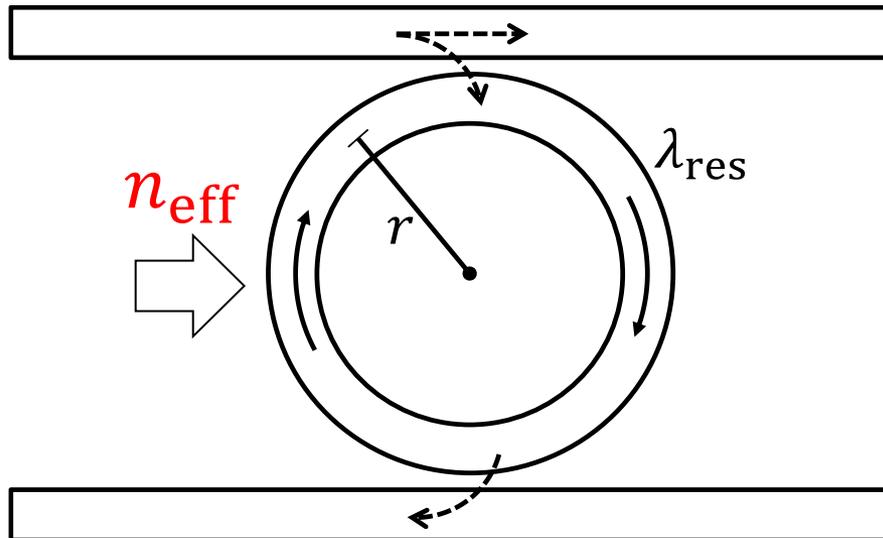


<https://youtu.be/APmGe5RPWSc?si=E62-3kOFUuszKm-Ou>

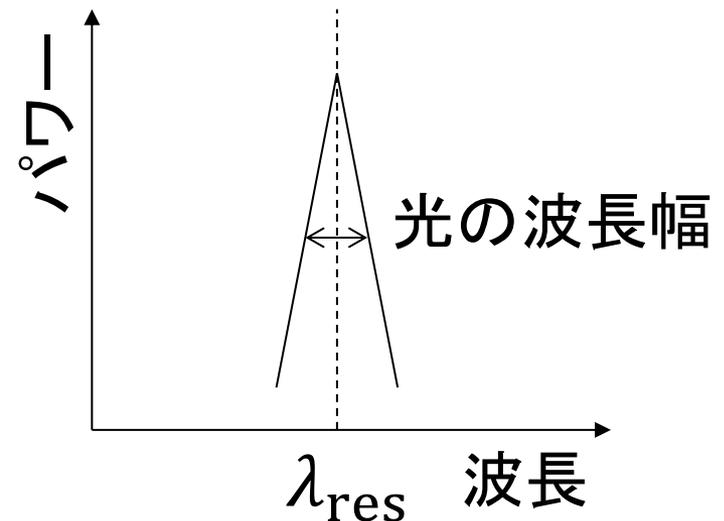
# 屈折率で透過率を制御

- リング部の屈折率  $n_{\text{eff}}$  を変化させることで, 光の透過率を変化可能
  - ネットワークの結合重みを制御することに対応

$$2\pi r n_{\text{eff}} = m\lambda_{\text{res}}$$

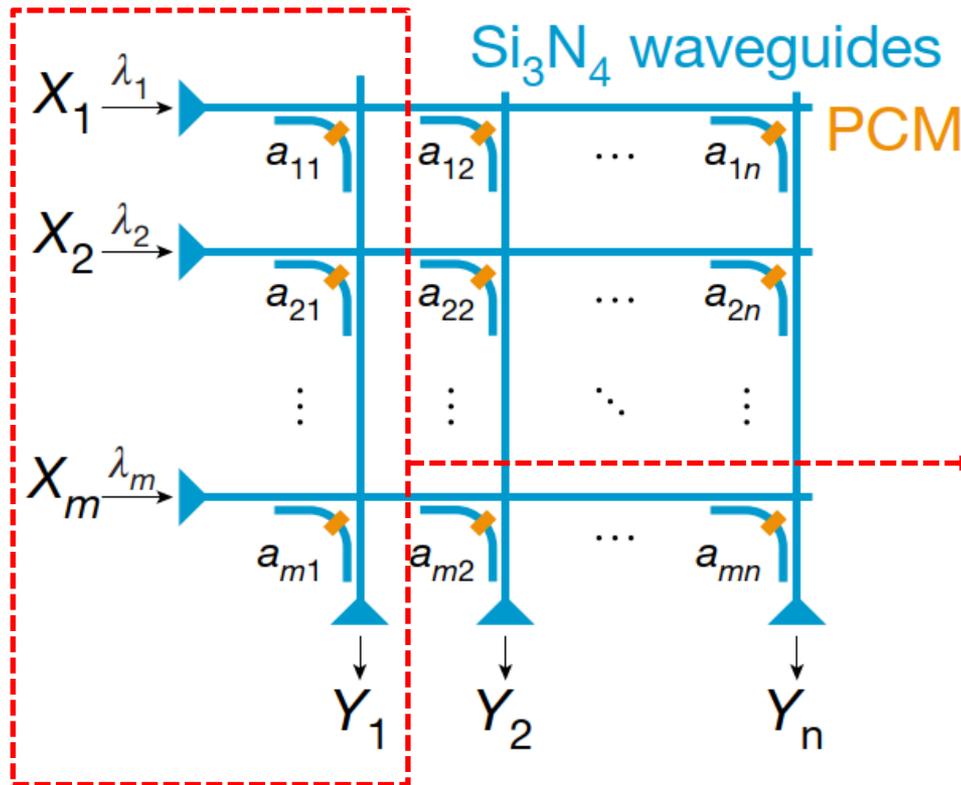


光は波長に幅を持つ



# 多重マイクロリング共振器

- リング共振器を多数並べ、波長ごとに異なる重みを付与する.



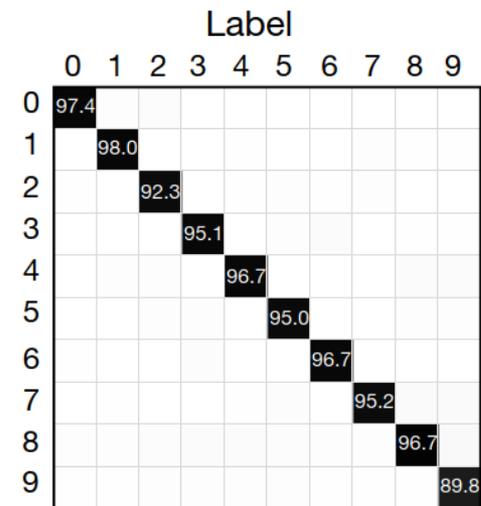
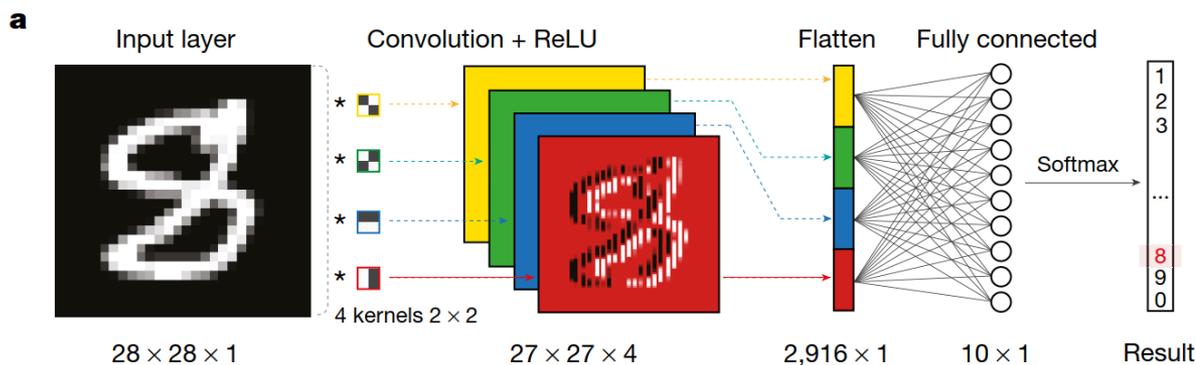
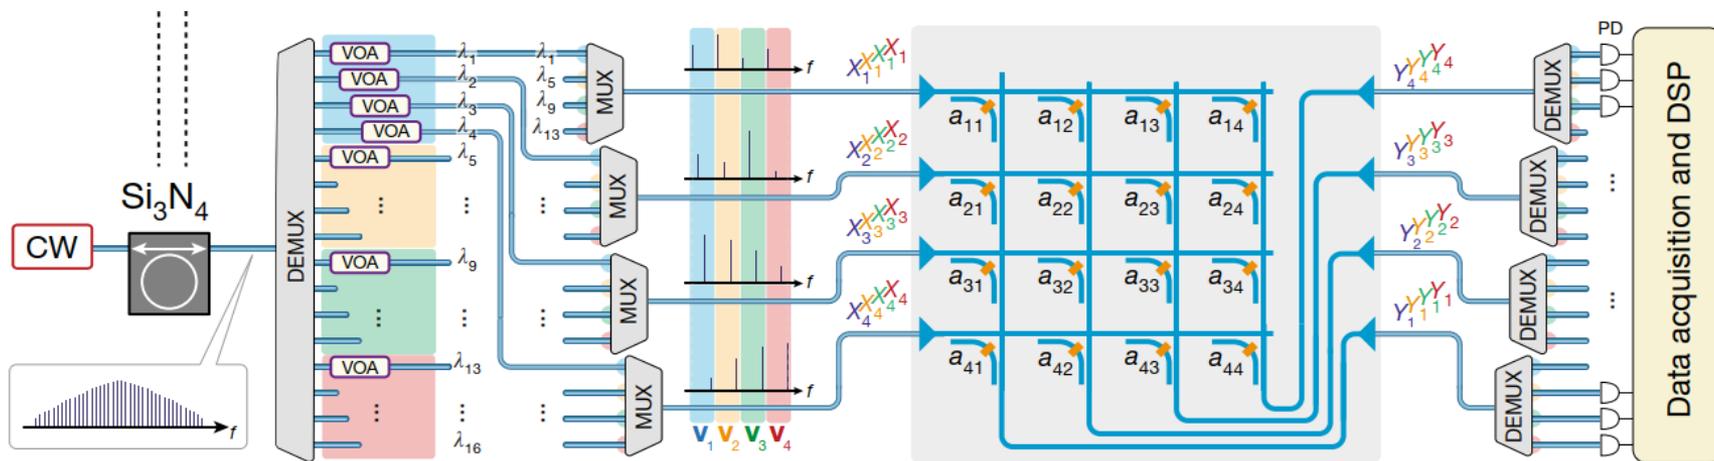
$$Y_n = a_{1n}X_1 + \dots + a_{mn}X_m$$

$n = 1$  のとき

$$Y_1 = a_{11}X_1 + \dots + a_{m1}X_m$$

J. Feldmann et al., "Parallel convolutional processing using an integrated photonic tensor core," Nature, Vol. 589, pp. 52-58 (2021).

# MNIST画像分類



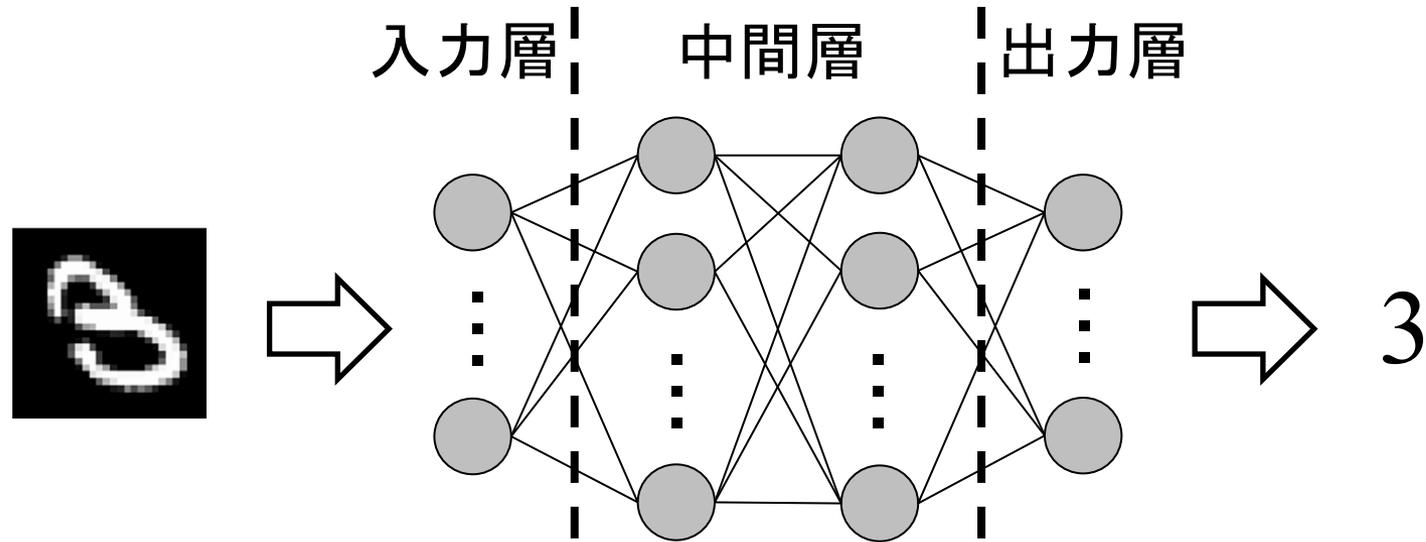
J. Feldmann et al., "Parallel convolutional processing using an integrated photonic tensor core," Nature, Vol. 589, pp. 52-58 (2021).

# 目次

---

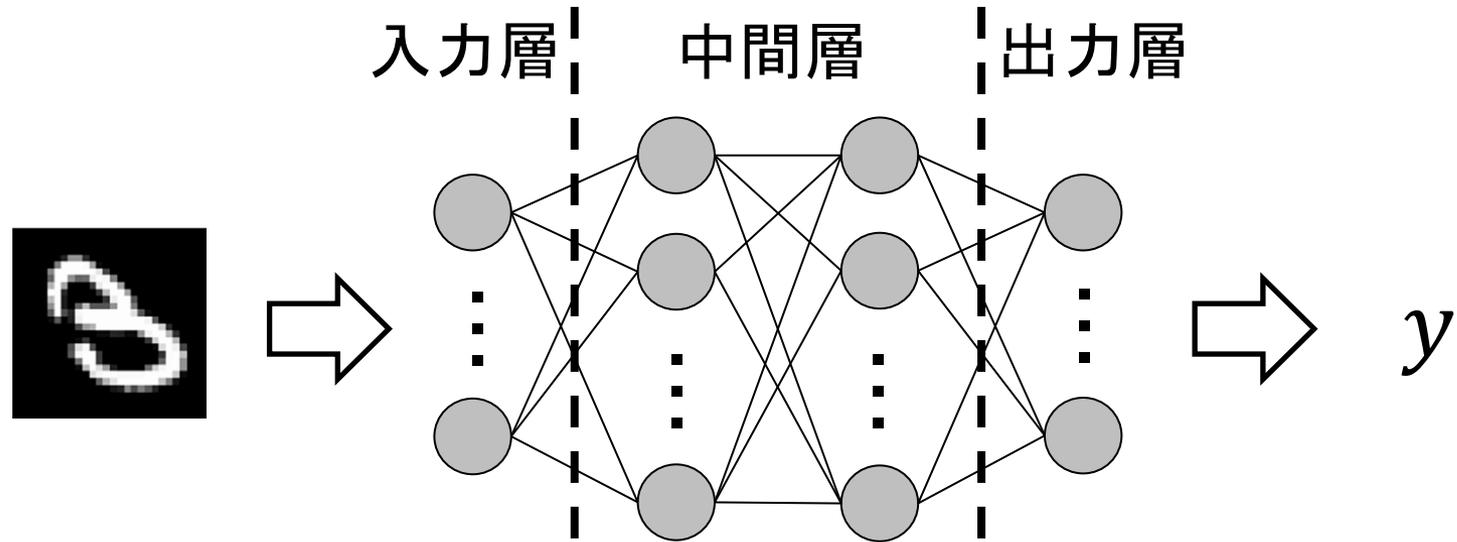
- 機械学習の発展と課題
- 機械学習への光の寄与, 光電融合
- 深層ネットワークの学習方法の基礎
- 物理リザバークンピューティング

# 深層ネットワークの学習

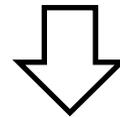


正しい認識のためには結合重みの学習が必要

# 深層ネットワークの学習



深層ネットワークの出力  $y$  が正解に近づけばよい

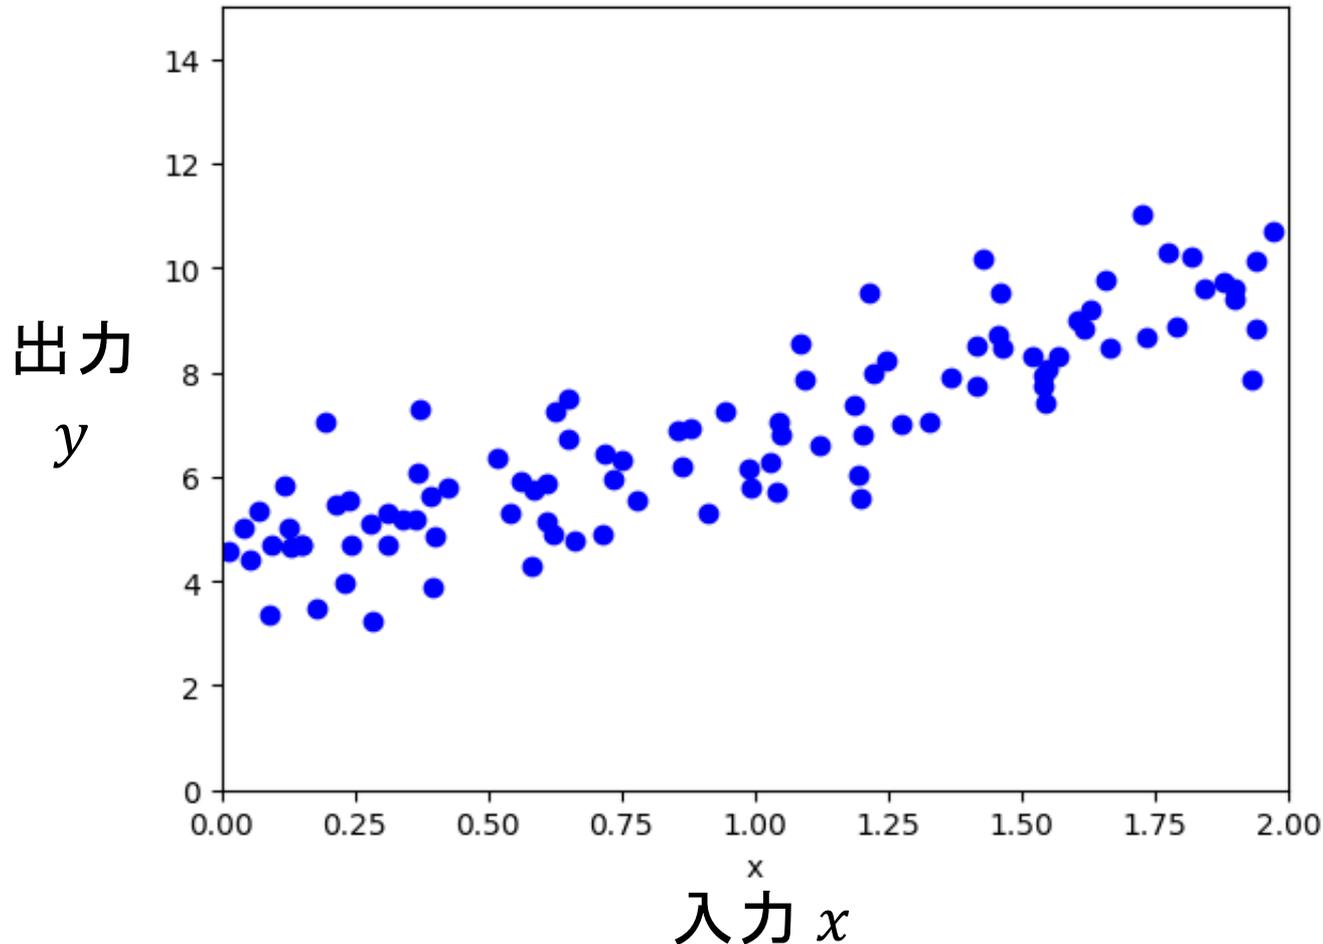


学習するためには正解  $d$  が必要

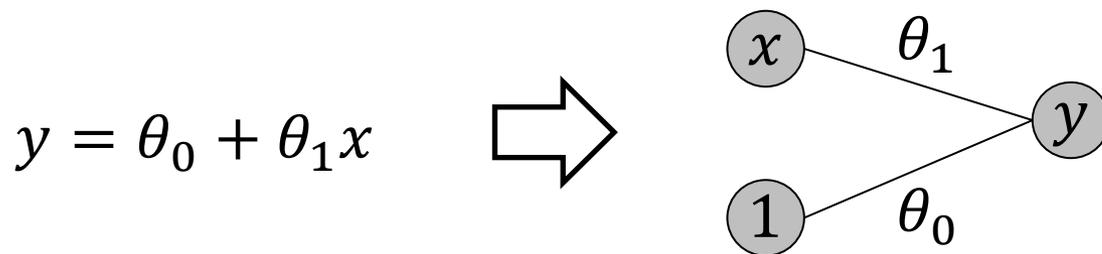
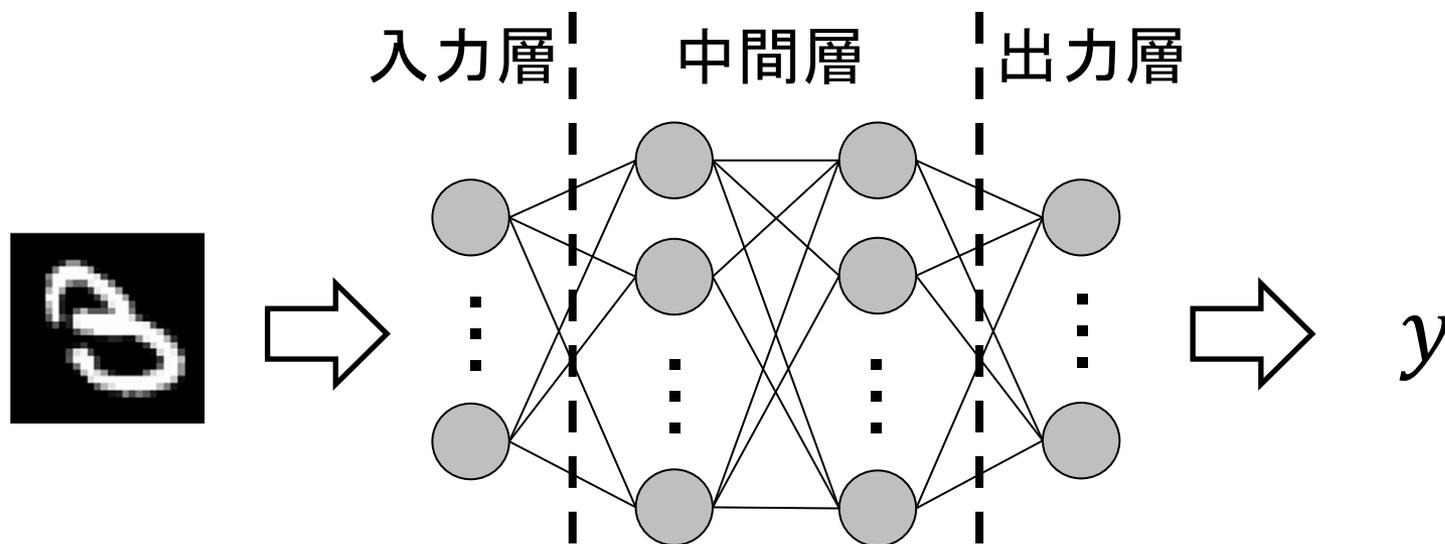
$d - y$  が 0 に近づく  $\rightarrow$  出力  $y$  が正解  $d$  に近づく

# 例：データを直線で近似

- 直線  $y = \theta_0 + \theta_1 x$  で下記のデータを近似する。
  - パラメータ  $\theta_0$  と  $\theta_1$  を学習する。



# ネットワーク的な表現



# 目的関数

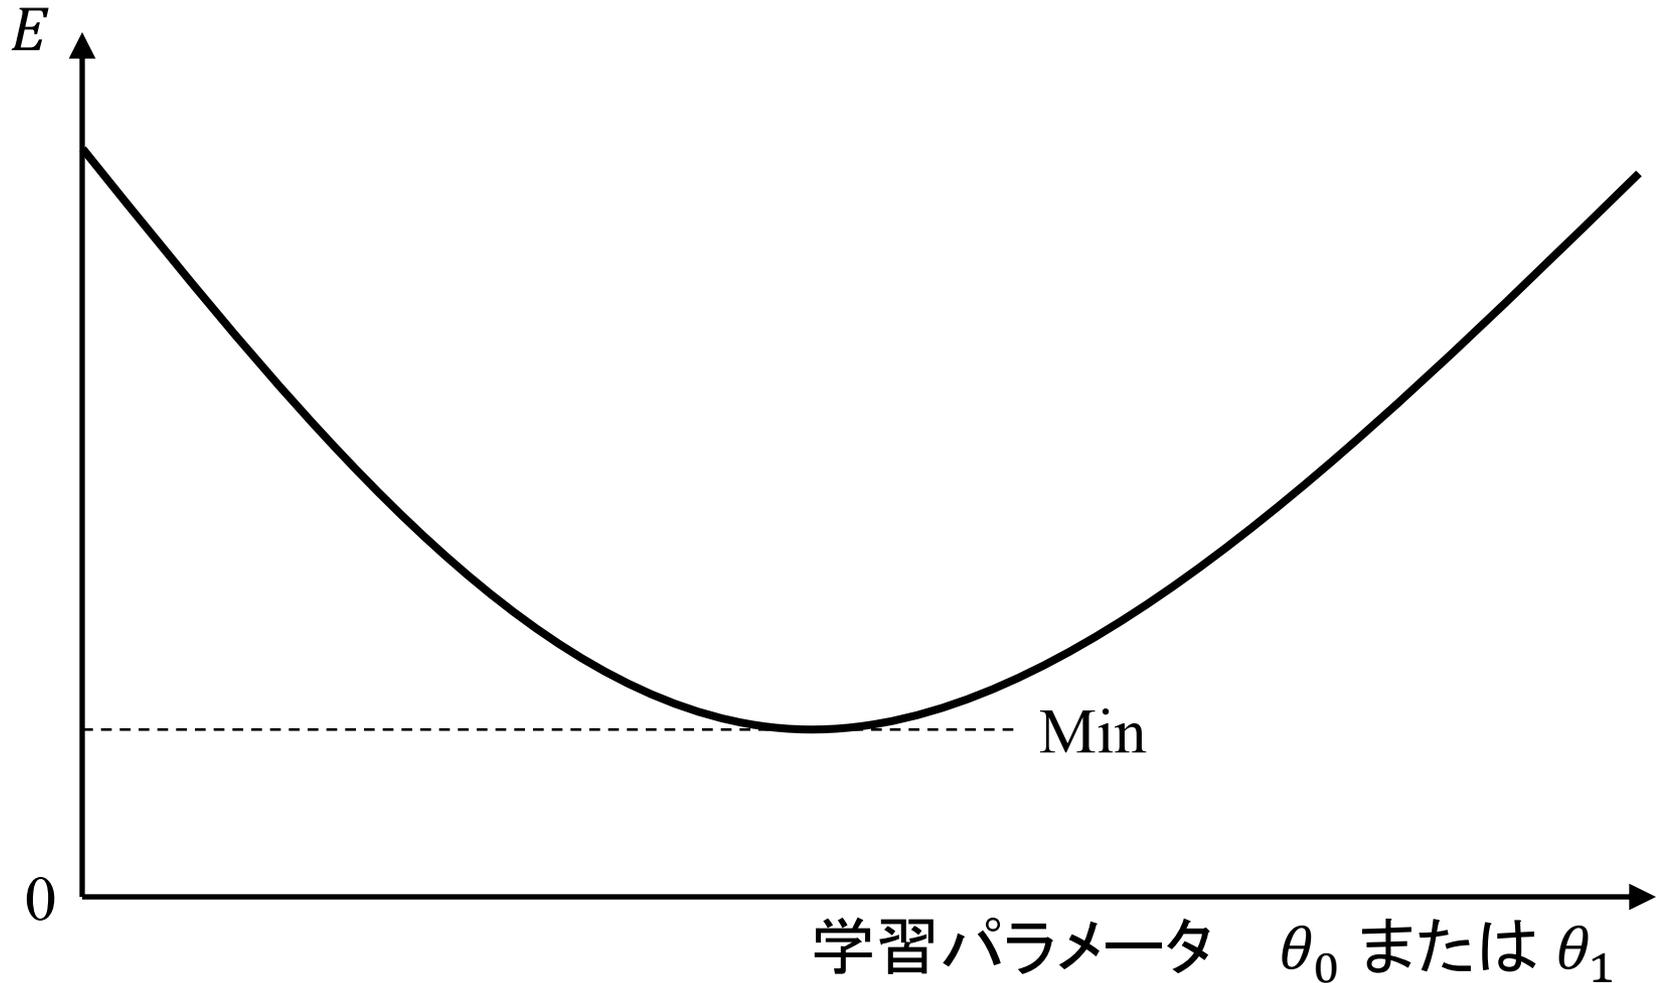
- 深層ネットワークを学習するためには目的が必要
  - 目的関数(誤差関数)を設定
- 深層ネットワークの出力  $y$  を正解  $d$  に近づけたい
  - 目的関数は  $d - y$  とすればよいか？

差の2乗を使用

$$\begin{aligned} E &= (d - y)^2 \\ &= (d - (\theta_0 - x\theta_1))^2 \end{aligned}$$

# 2乗誤差

目的関数



# 勾配法による学習

- 誤差関数  $E$  を最小化するには、結合重み  $\mathbf{W}^{(m)}$  を最適化する最適化問題を解く必要がある。
  - 勾配法を利用
- 勾配法
  - 誤差関数  $E$  の微分に基づいて  $\mathbf{W}^{(m)}$  を逐次的に更新
  - 代表的な手法: 最急降下法
- 最急降下法
  - $E$  の一階微分を用いて最も勾配が急な方向に更新する

更新式

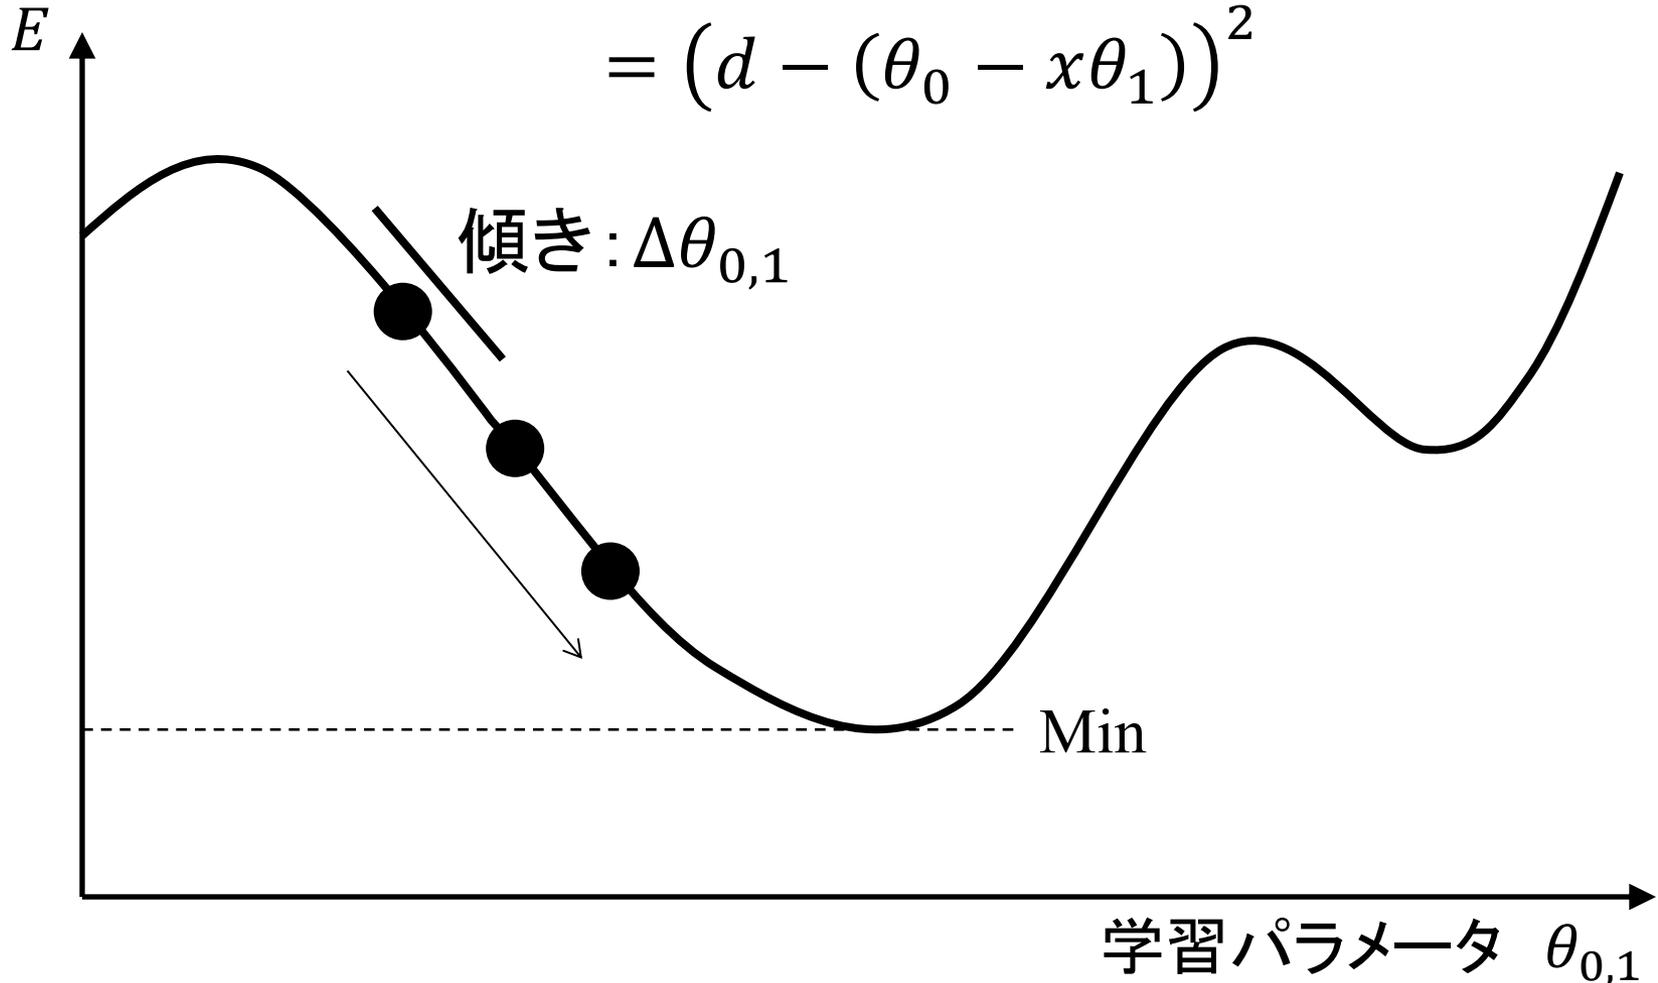
$$\begin{aligned}\theta_0 &\leftarrow \theta_0 - \eta \Delta\theta_0 \\ \theta_1 &\leftarrow \theta_1 - \eta \Delta\theta_1\end{aligned}$$

$\Delta\theta_{0,1}$ : 勾配

# 勾配法の概念図

目的関数

$$E = (d - y)^2$$
$$= (d - (\theta_0 - x\theta_1))^2$$



# 直線近似のための条件条件

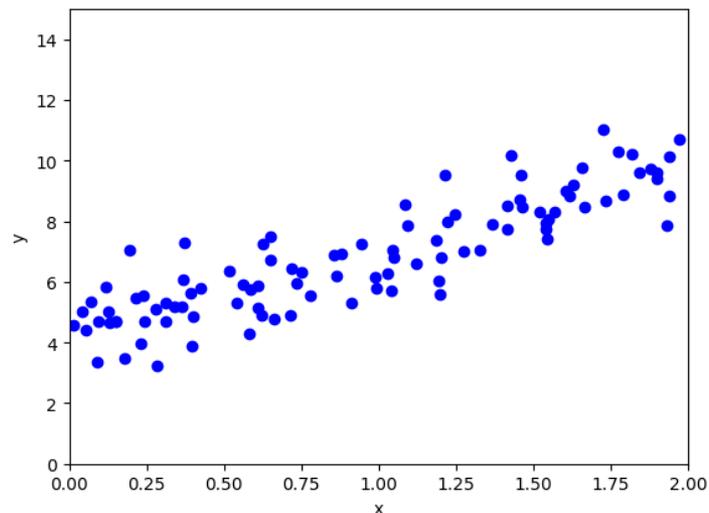
- 学習パラメータ数を2個とする.
  - データを直線で近似することに相当する.

$$y = \theta_0 + \theta_1 x$$

- 学習データセットを以下の式で生成する.
  - $\xi$  はガウス分布から生成される乱数(ノイズとして加える)
  - 学習データ数を  $K = 100$  とする.

$x \in [0,2]$  は一様分布乱数

学習データ:  $t = 4 + 3x + \xi$

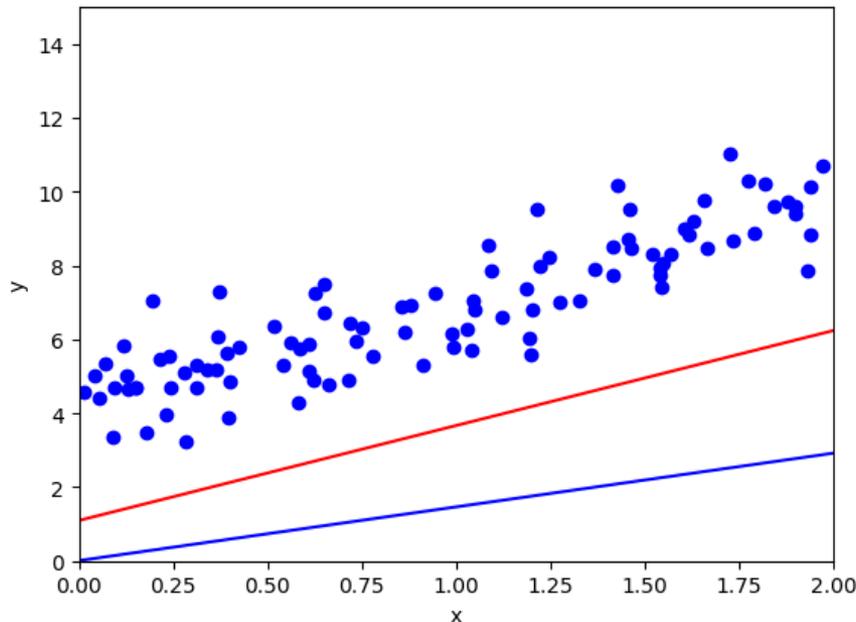


# 1回の更新結果

- 学習パラメータにランダムに初期値を設定
  - $\theta_0 = 0.013, \theta_1 = 1.45$
- 100 データを用いて勾配を計算し、パラメータ更新
  - 学習率  $\eta = 0.1$

$$\theta_0 \leftarrow \theta_0 + \eta \Delta \theta_0$$

$$\theta_1 \leftarrow \theta_1 + \eta \Delta \theta_1$$

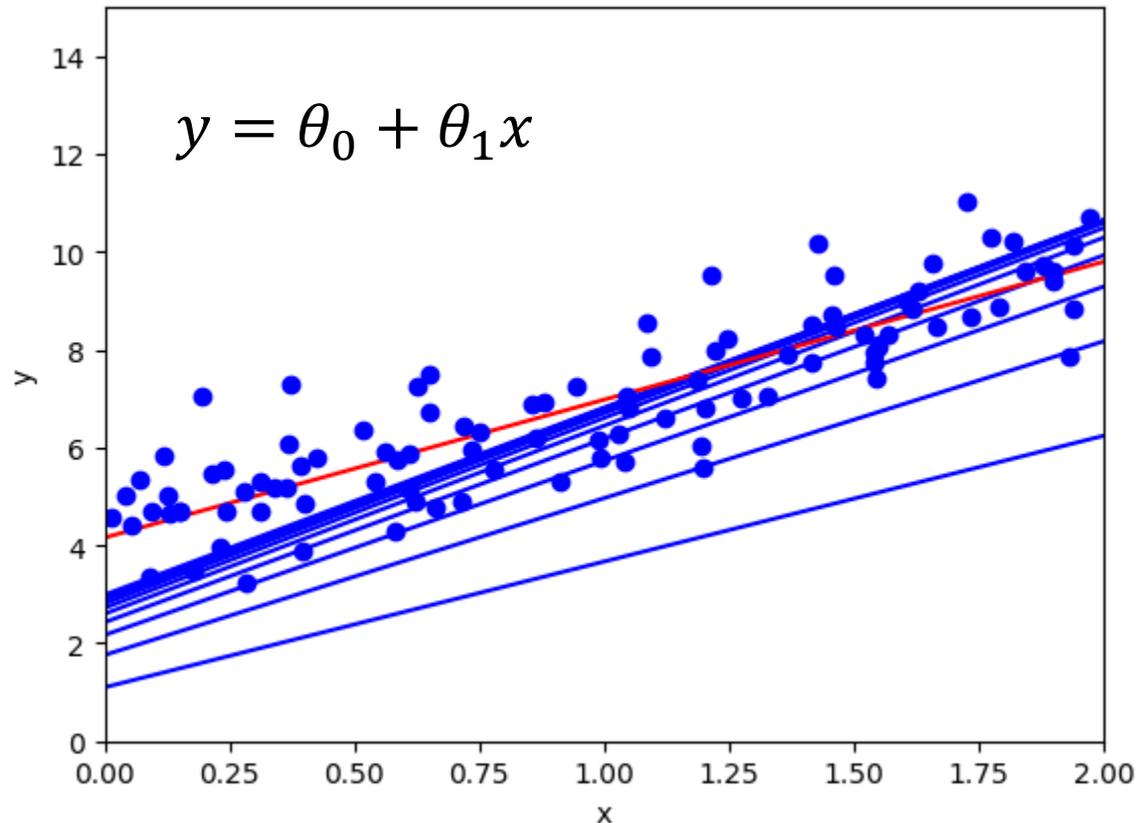


更新後  $\theta_0 = 1.10, \theta_1 = 2.57$

更新前  $\theta_0 = 0.013, \theta_1 = 1.45$

# 100回更新

- 更新回数を100に設定(100エポック)



赤線のパラメータ:  $\theta_0 = 4.16$ ,  $\theta_1 = 2.82$

# Google Colab によるデモ

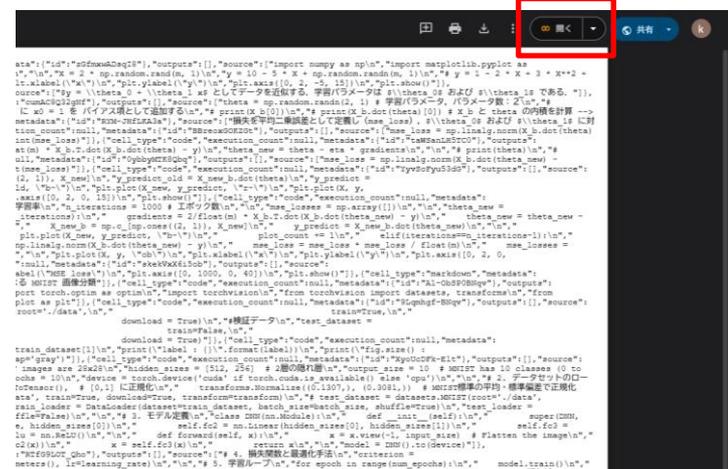
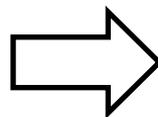
## Google が提供する python プログラミング環境

- プログラミング環境を用意する必要がない
- 深層学習なども実行可能
- Google アカウントが必要

## Google Colab Notebook ファイル

### 演習用プログラム

「開く」をクリック

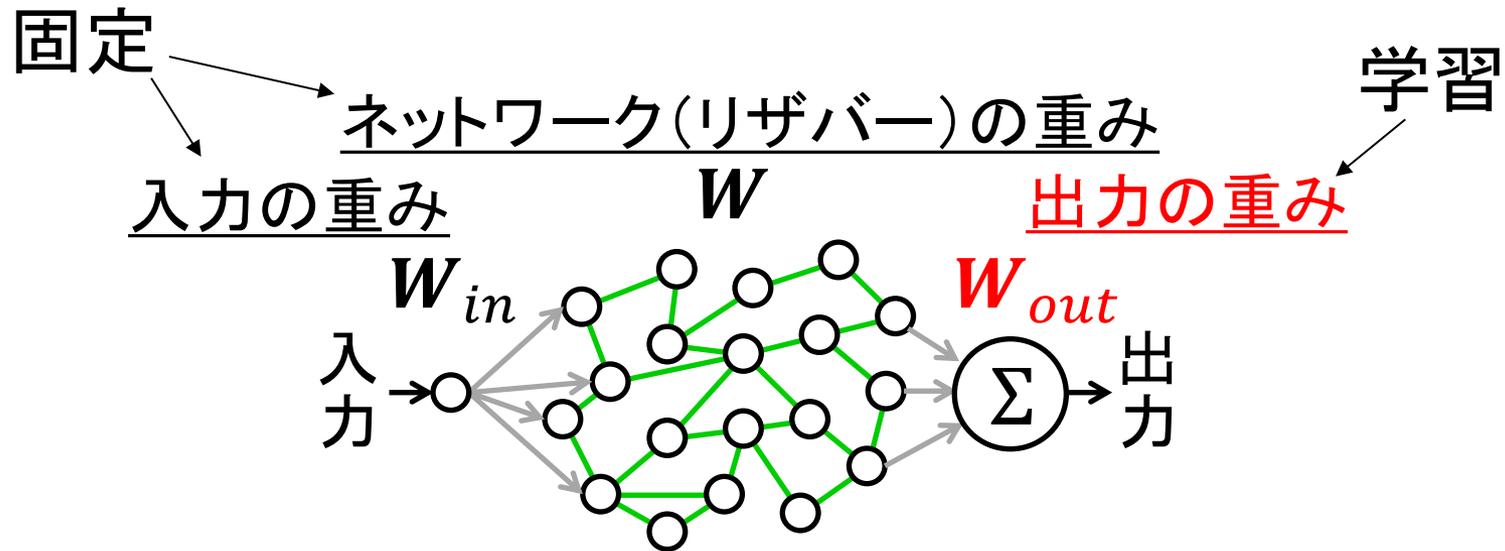


# 目次

---

- 機械学習の発展と課題
- 機械学習への光の寄与, 光電融合
- 深層ネットワークの学習方法の基礎
- 物理リザバークンピューティング

# リザーバーコンピューティング



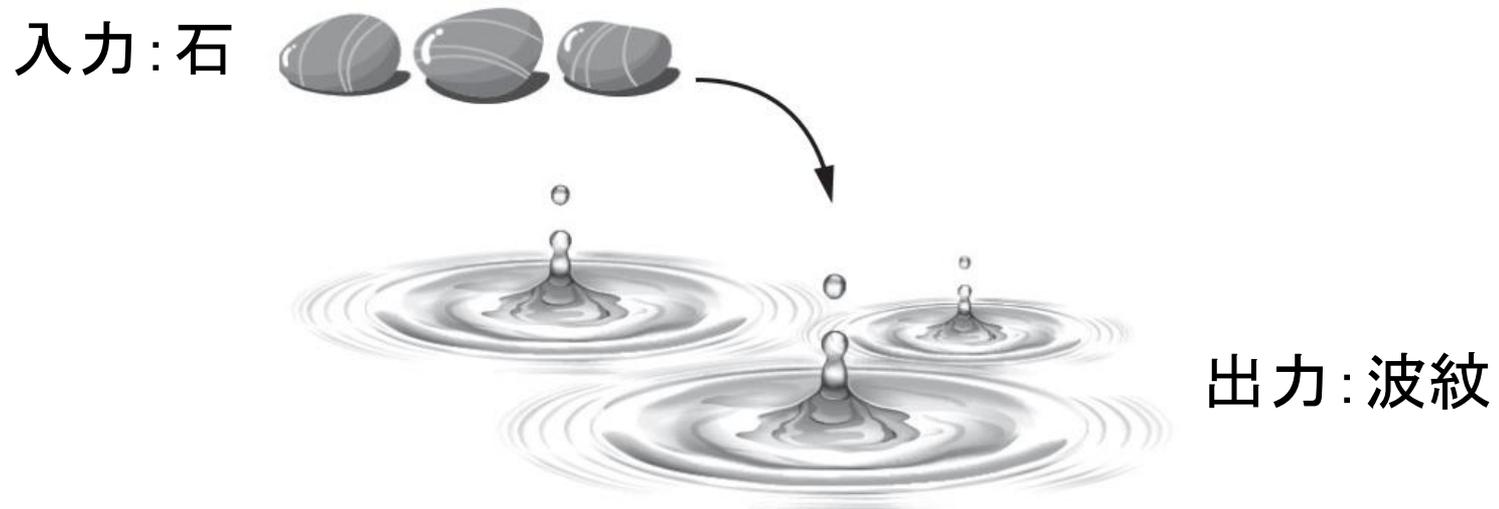
## 出力の重み $W_{out}$ のみを学習

### 特徴

- 学習に必要な時間が少ない
- 学習に必要なデータ量が比較的少なくて済む
- 記憶を必要とする処理が可能

# リザーバーコンピューティングの概念

リザーバーコンピューティング: Reservoir Computing  
貯水池, ダム



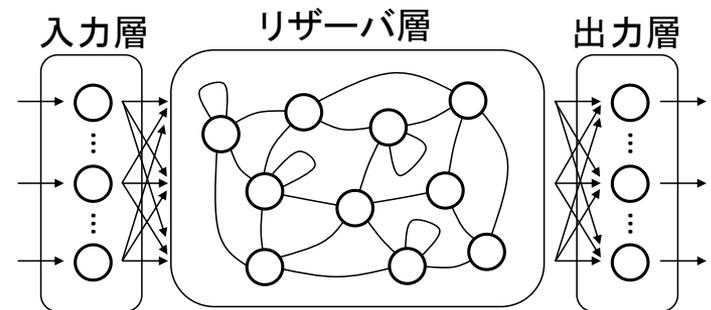
波の反射や干渉により複雑な波紋を生成

田中ら, 電子情報通信学会誌, Vol. 102, No. 2 (2019)

# RC と DL の違い

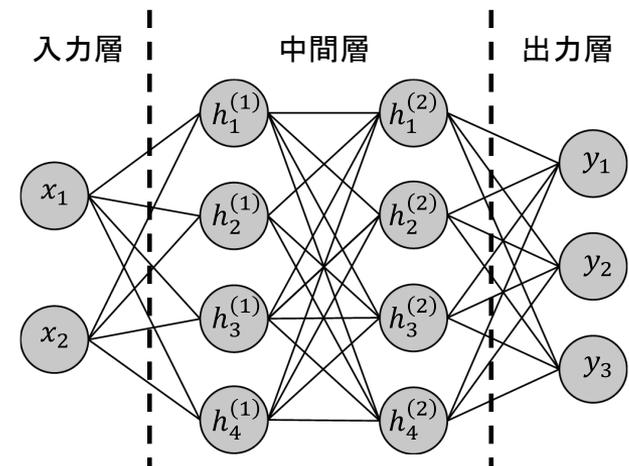
## □ リザーバーコンピューティング (RC)

- 出力結合重み (出力層) のみ学習
- 学習が一度で完了する
- リザーバがフィードバックを持つ

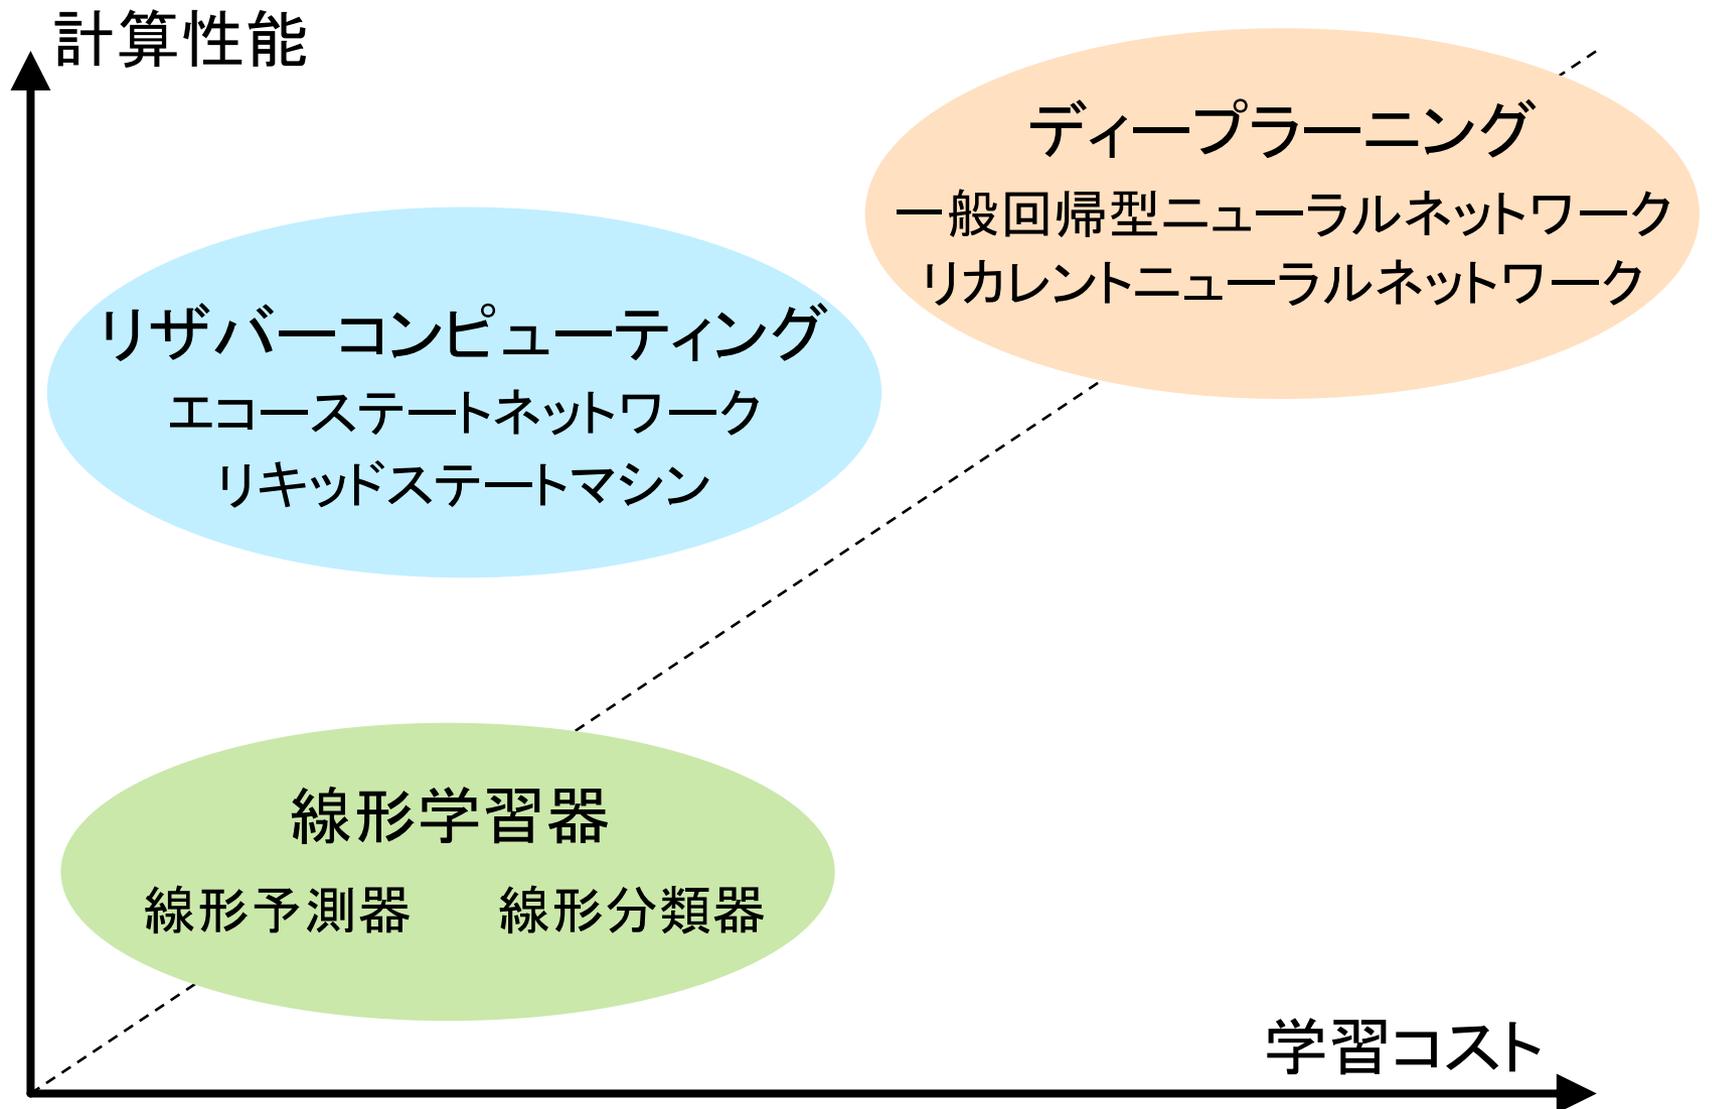


## □ ディープラーニング (DL)

- 全ての結合 (入力層, 中間層, 結合層) を学習
- 層が多いため繰り返し学習を行う
- ネットワークが一方向に結合



# RCの位置付け



# リザーバコンピューティングの応用

カテゴリー	対象
生物・医療	EEG, fMRI, ECG, EMG, 心拍, バイオマーカ, 眼球運動, マンモグラム, 肺画像
画像	手書き文字画像, 動画画像
音声	発話, 音響, 音楽, 鳥の鳴き声
機械	車両, ロボット, センサ, モータ, 圧縮器, 制御器, アクチュエータ
工業	発電所, 送電線, 再生可能エネルギー, エンジン, 燃料電池, バッテリー, ガスフロー, ディーゼル油, 炭鉱, 油圧掘削機, ボイラ, 穀物粉碎機, 歩道橋, エアコン
通信	電波, 電話, インターネット通信
環境	風力・風向, オゾン濃度, PM2.5, 廃水, 降雨, 地震
安全	暗号
経済・金融	株価, 株価指数, 為替
社会	言語, 文法, 構文, スマートフォン

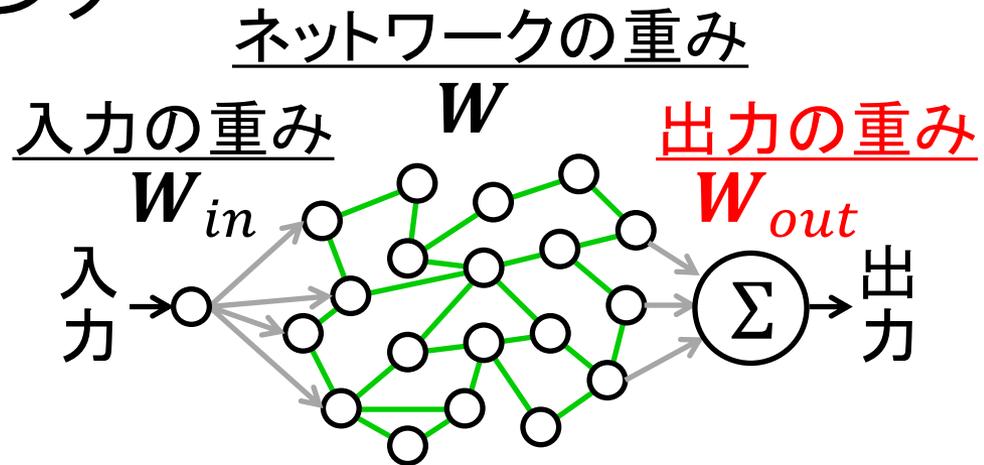
電子情報通信学会誌, Vol. 102, No. 2 (2019)

# 物理リザーバーコンピューティング

## □ リザーバーコンピューティング

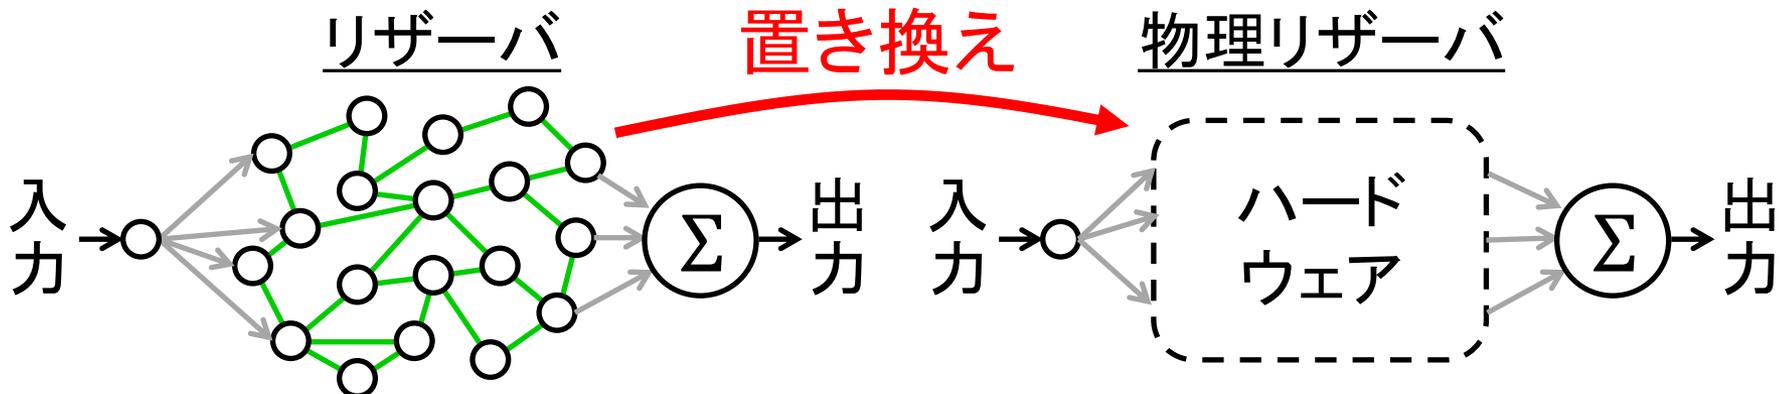
### 出力の重みのみ学習 (低学習コスト)

H. Jaeger and H. Haas, Science, **304**, 78 (2004).



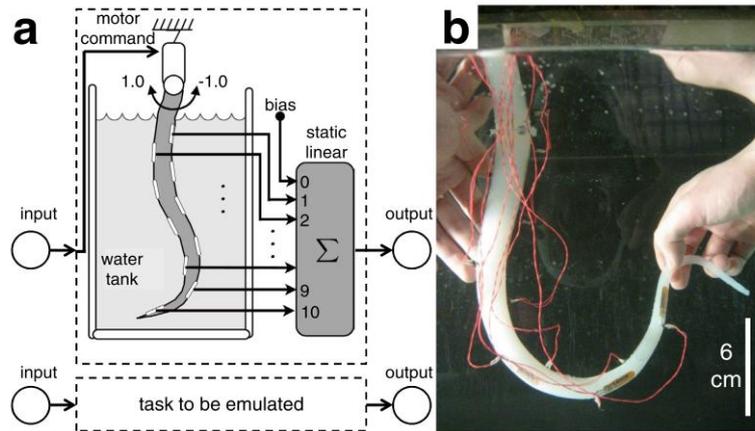
## □ 物理リザーバーコンピューティング

入力を複雑な応答に変換できる **ハードウェア** に置き換える



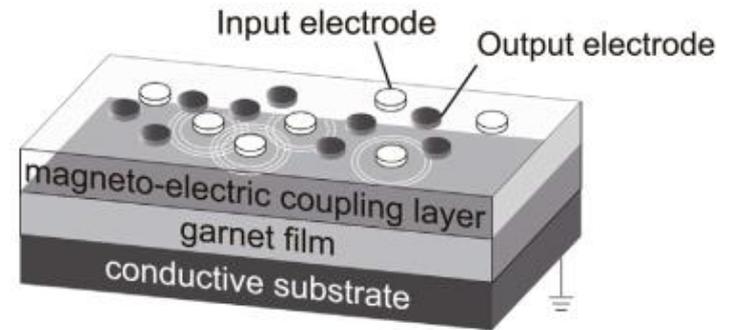
# 様々なハードウェアによる実装

リザーバーコンピューティングの **ハードウェア実装** が近年流行  
ソフトロボット



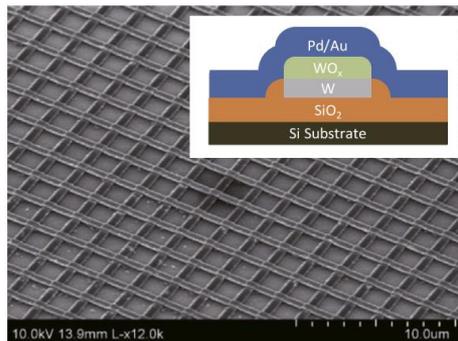
K. Nakajima, et al., Sci. Rep., **5**, 10487 (2015).

## スピントルク振動子



R. Nakane, et al., IEEE Access, **6**, 4462 (2018).

## メモリストタ回路



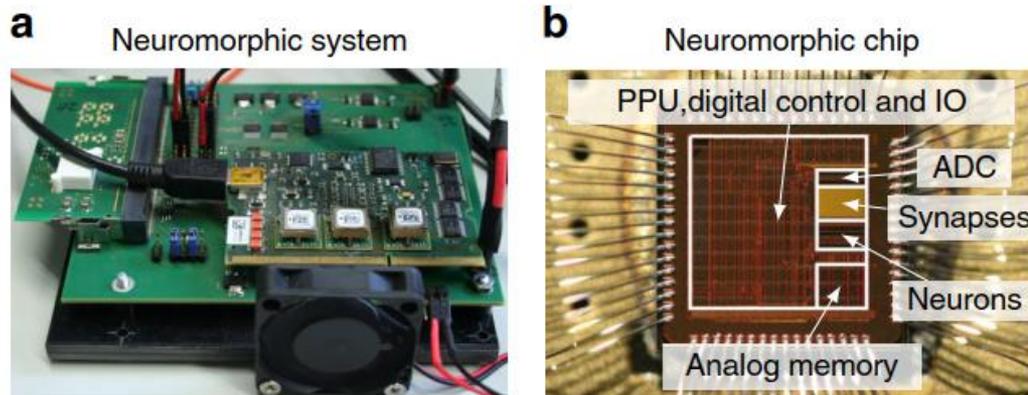
C. Du, et al., Nat. Commun., **8**, 2204 (2017).

カテゴリー	例
力学系モデル	遅延力学系, セルオートマトン, 結合振動子系
電気・電子系	ASIC, FPGA, VLSI, アナログ回路, 神経模倣回路, メモリストタ回路
光学系	半導体光増幅器, 光電子系, レーザキャビティ, 光導波路
スピン系	スピントルク振動子, スピン波, スキルミオン
機械系	ばね質点系, テンセグリティロボット, ソフトロボット
生物系	脳部位, 培養細胞
その他	ナノスケール材料, 量子系

G. Tanaka, et al., Neural Networks, **115**, 100 (2019). 65

# モチベーション

- 学習コストが低く，高速な情報処理デバイスの開発
  - 物理システムを利用するため高速
  - ネットワークを訓練する必要が無いため学習コストが低い
  - 専用ハードウェアによる実装のため低消費電力
  
- ニューロモルフィック・ハードウェアなどとも呼ばれる

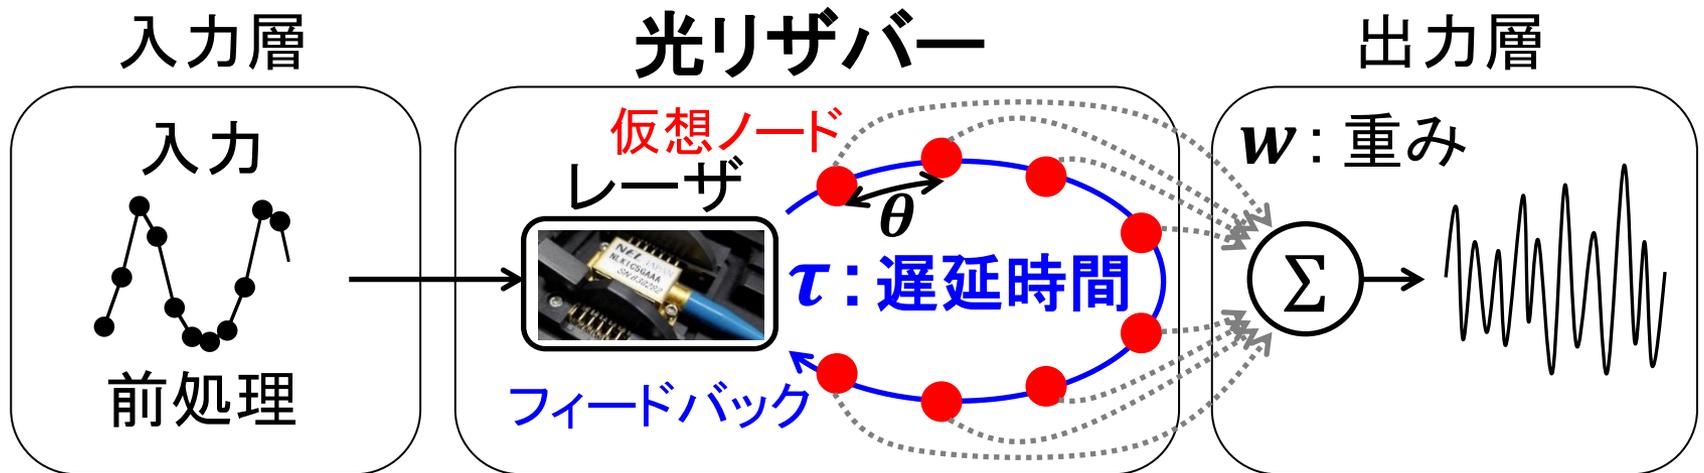


# 物理リザバの種類

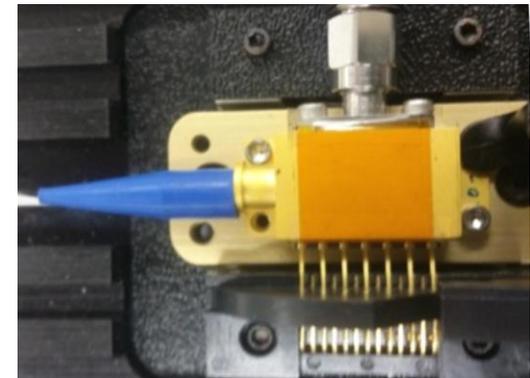
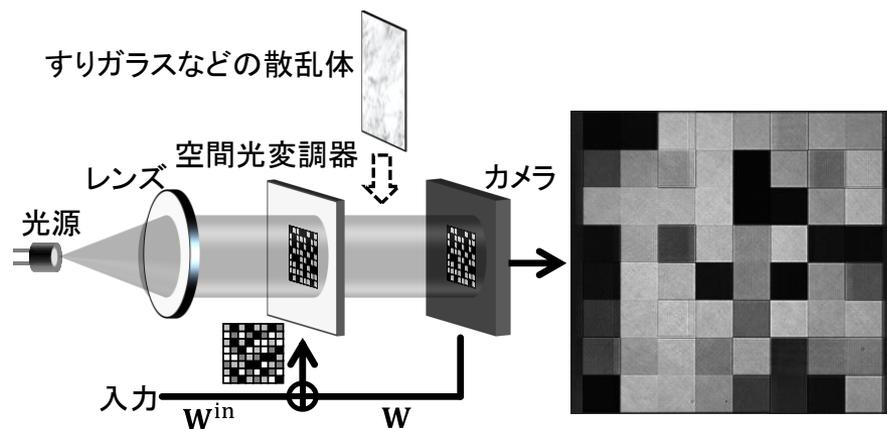
種類	非線形性
電気・電子系	集積回路, アナログ・デジタル回路, FPGA, ニューロモルフィック回路, 抵抗変化素子・メモリスタ
光系	光増幅器, 光変調器, 光共振器
スピン系	磁気トンネル接合・スピントルク発振器, スピン波
機械系	非線形バネ-質点系, 微小電気機械システム, ソフトロボット
その他	水・液体, ナノスケール材料, 電子ビット, 化学反応

# 光リザバーコンピューティング

□ ネットワークを **光システム** に置き換える

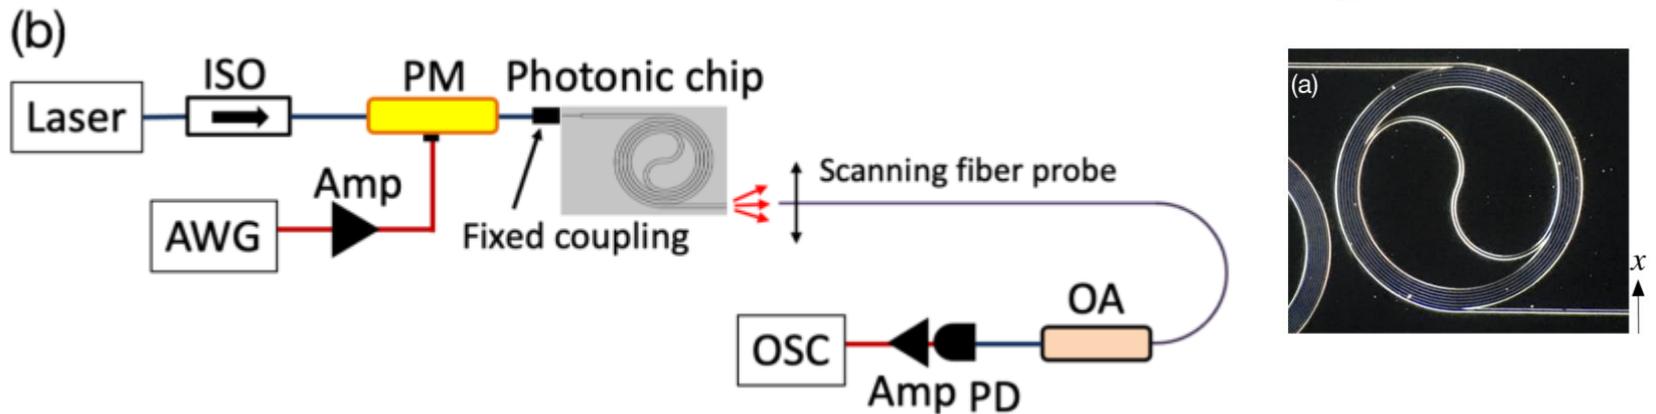
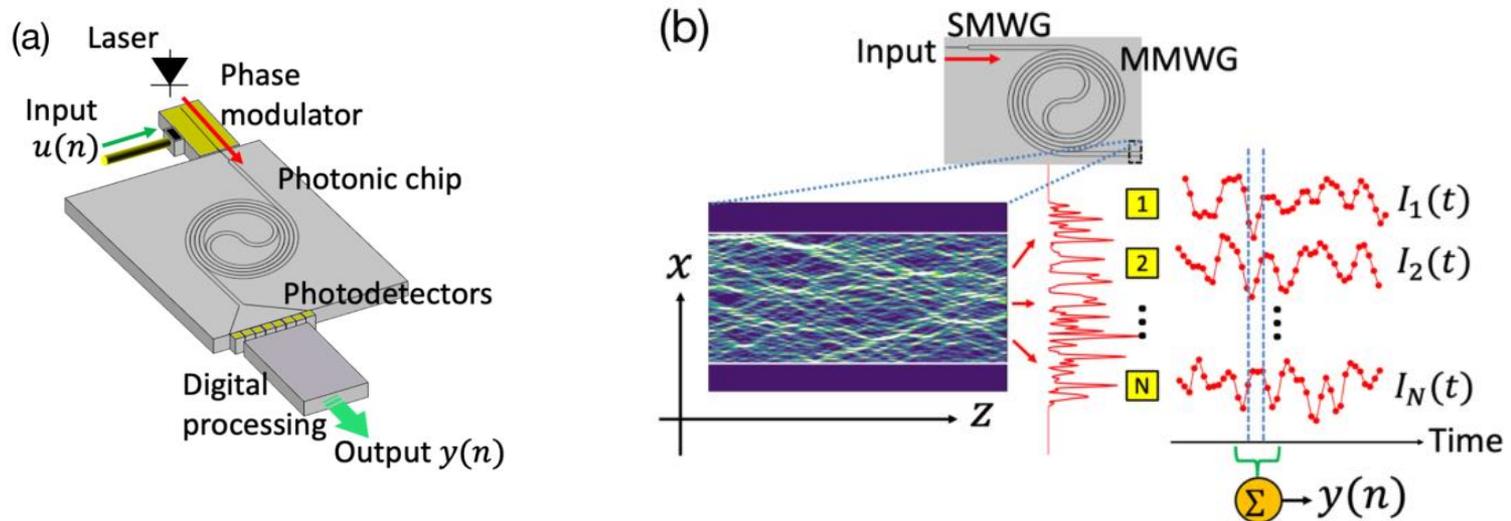


D. Brunner et al., Nat. Commun., **4**, 1364 (2013).



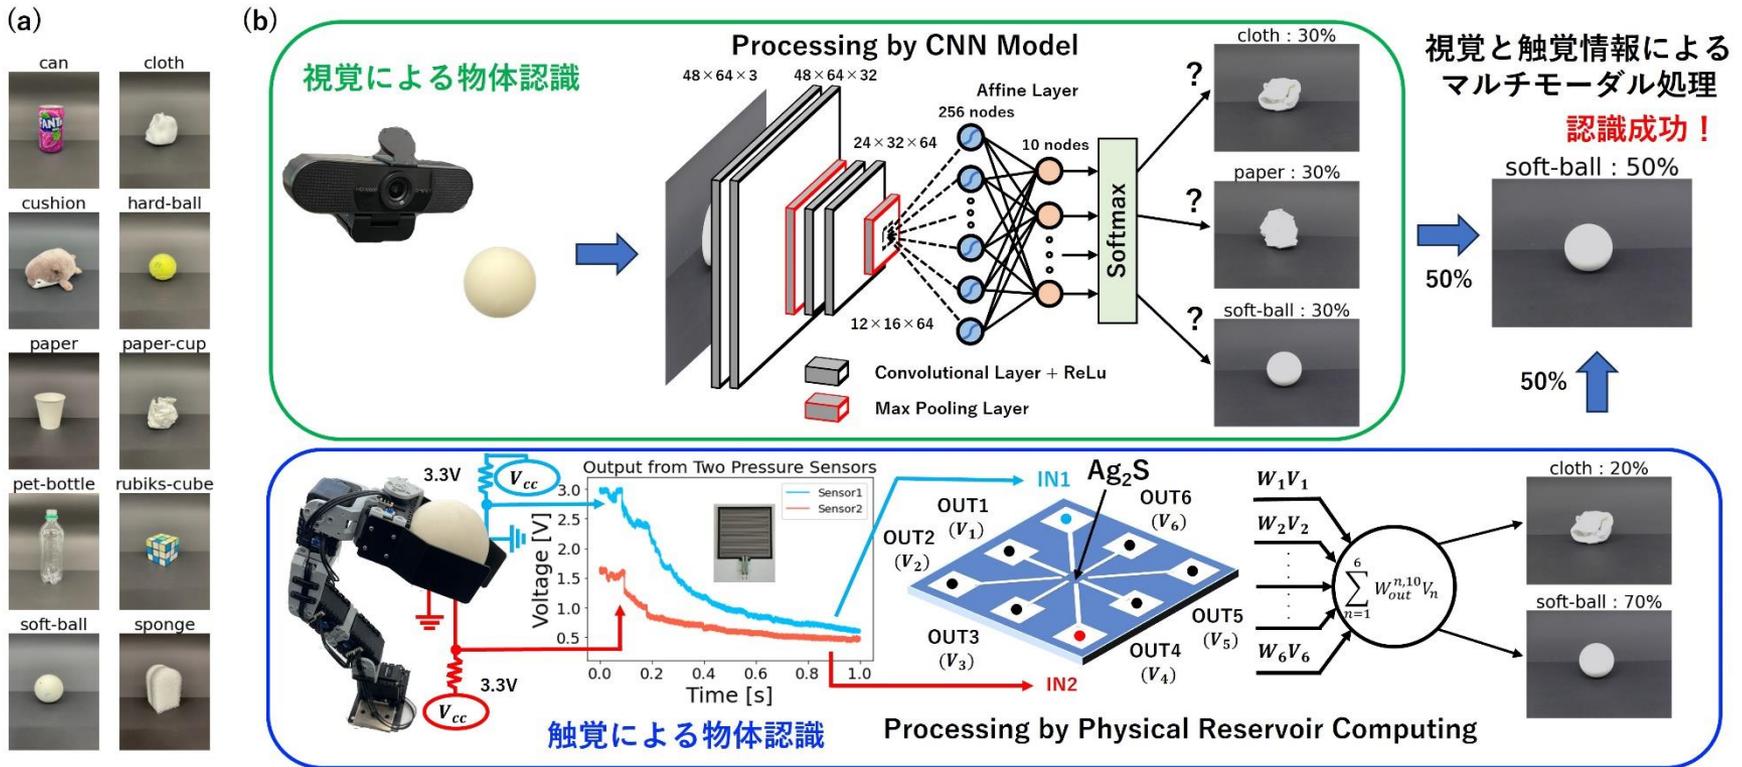
# 光集積回路化

## □ マルチモードファイバリザバーの光集積回路化



# 触覚信号による異常検知

視覚(画像)から深層ネットワークを用いて認識



触覚信号から物理リザーバーを用いて認識

<https://www.jsap.or.jp/pressrelease/pr20240912/lecture-15>

# まとめ

- 機械学習に必要な積和演算を光で実現する技術について紹介した.
  - 光の空間並列性を用いる手法
  - 光の干渉性を用いる手法
  - 光共振器を用いる手法
  
- 物理リザーバコンピューティングについて紹介した.
  - リザーバコンピューティングモデルの一つとしてエコーステートネットワークについて概説した.
  - 光を用いたリザーバコンピューティングについて紹介した.