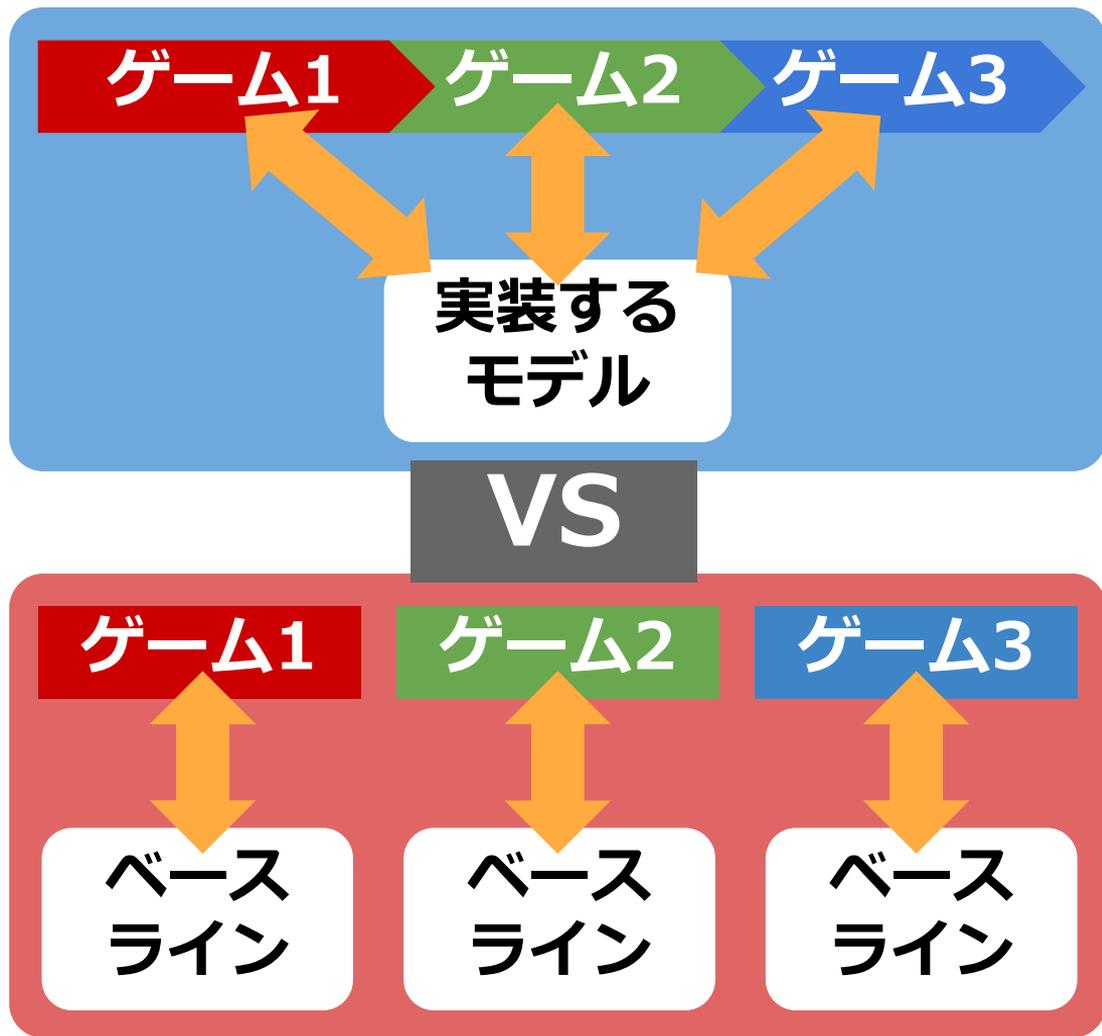


複数のゲームにおける continual learning

慶應大学環境情報学部 野口裕貴

概要

- 複数のゲームを逐次的に学習
- 知識の再利用に注目
- 各ゲームを独立的に学習したベースラインと比較



知識の再利用

汎用人工知能には過去に獲得した知識を再利用する能力が必要である



It is my conviction that no scheme for learning, or for pattern-recognition, can have very general utility unless there are provisions for recursive, or at least hierarchical, use of previous results.

- Marvin Minsky,
Steps Toward Artificial Intelligence (1960)

知識の再利用 | 機能要件

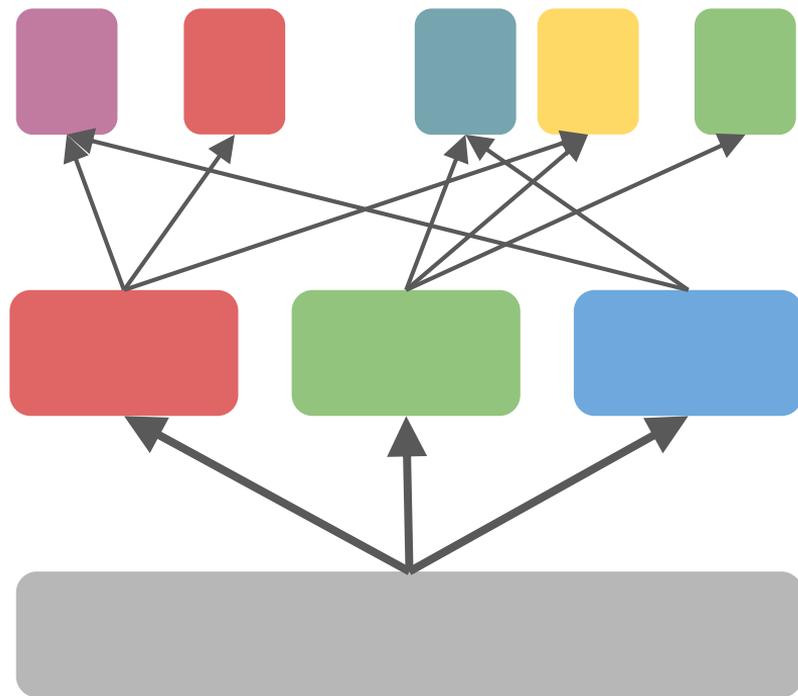
過去に獲得した知識を
保持する

過去に獲得した知識を
新しいタスクに利用する

「continual learning」
「lifelong learning」

理想的な知識構造

タスクに
特化した知識



特定の状況に
利用される

汎用的な知識

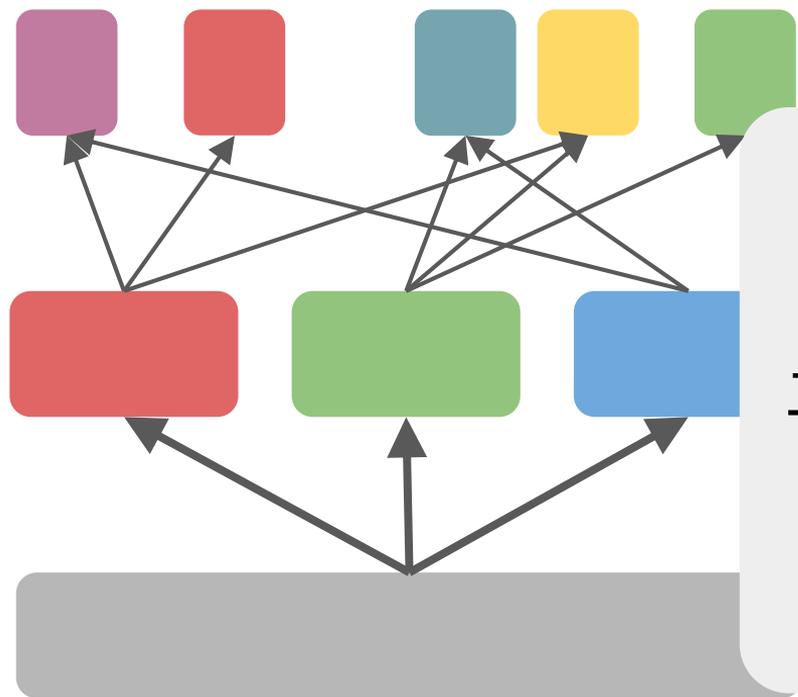
よく(再)利用
される知識

理想的な知識構造

タスクに
特化した知識



汎用的な知識



特定の状況に
利用される

この表現を獲得
するために、
ニューラルネット
の枠組みで
考えてみる

ニューラルネットの性質

典型的なニューラルネットが複数のタスクを学習できるか？

理想

Aに特化、
Bに特化、
さらに共有
される知識が
学習される

タスクA用出力層

タスクB用出力層

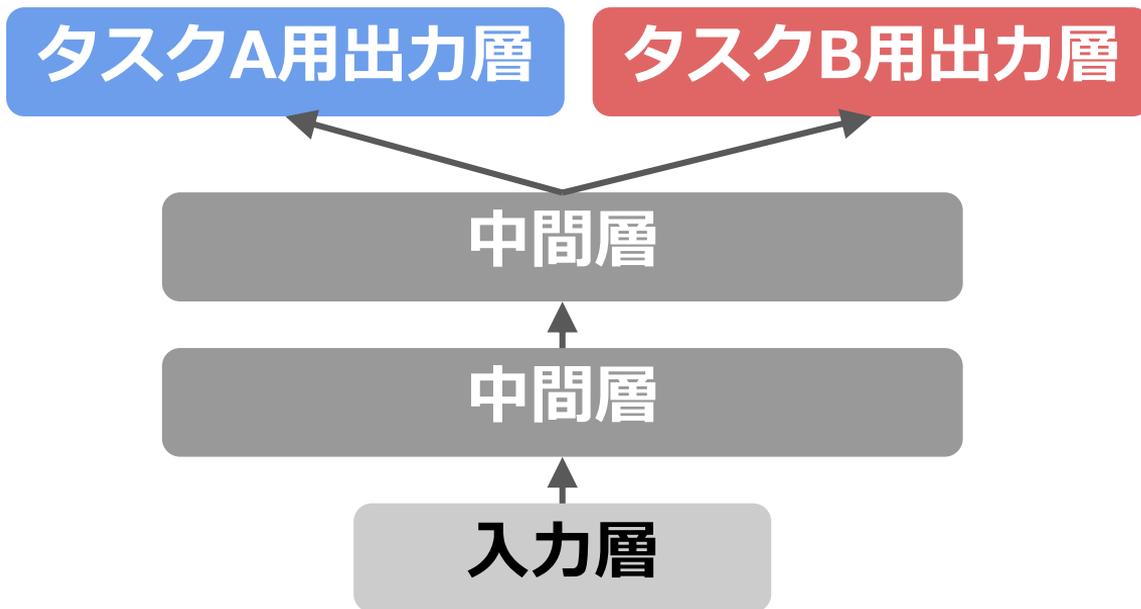


入力層

ニューラルネットの性質

重みに初期値を与える

現実



ニューラルネットの性質

まずタスクAを学習

現実

Aに特化した
知識が学習
される

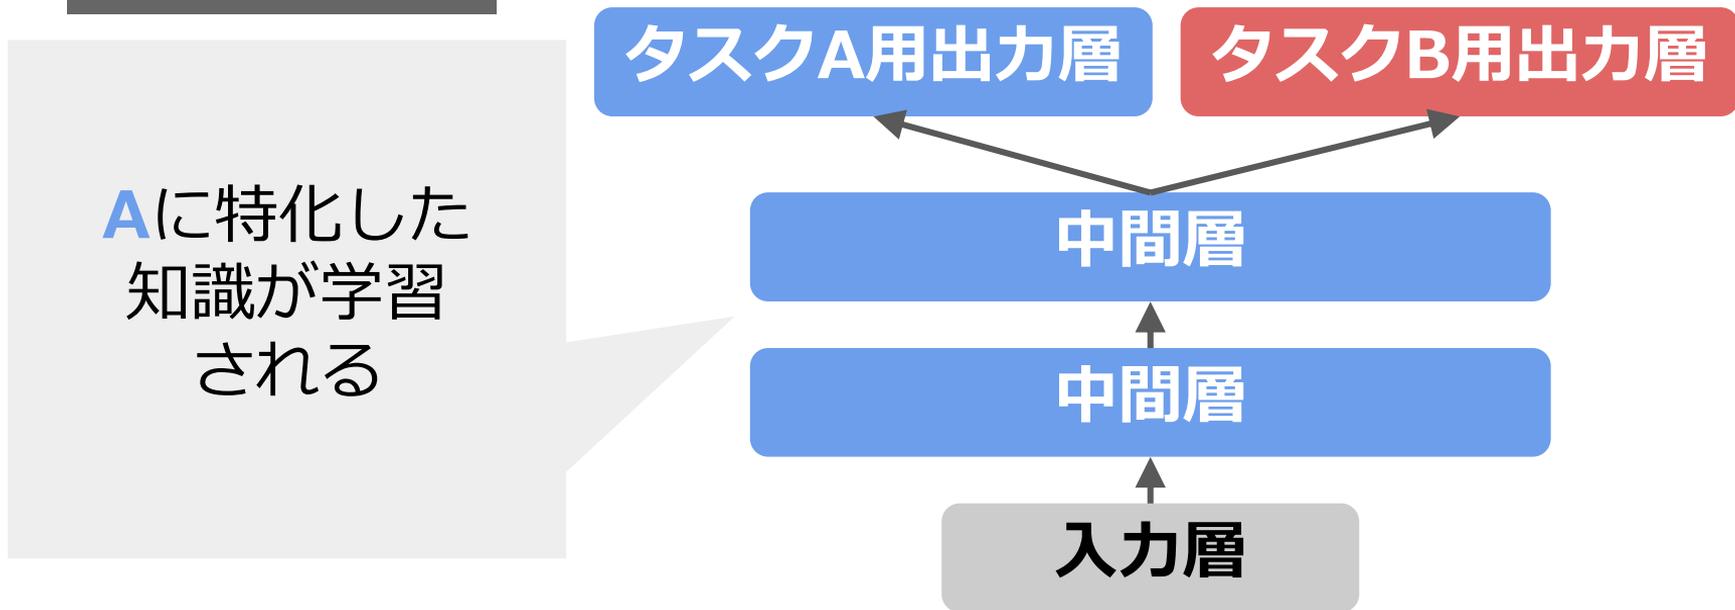
タスクA用出力層

タスクB用出力層

中間層

中間層

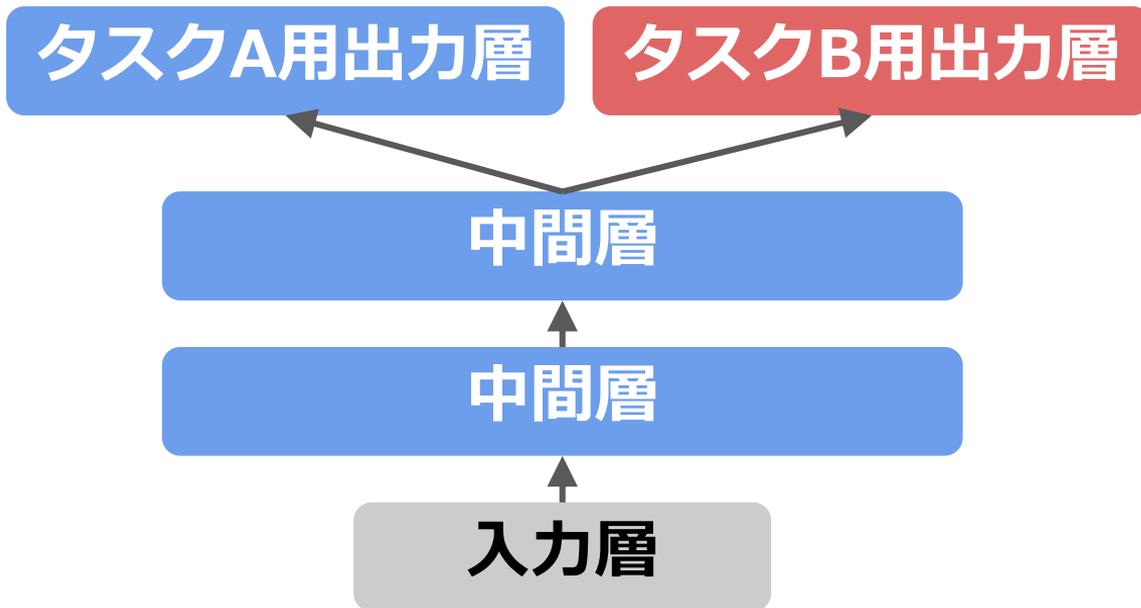
入力層



ニューラルネットの性質

次にタスクBを学習させれば両方できるようになる. . . ?

現実



ニューラルネットの性質

そんなに簡単じゃない. . .

現実

Aに特化した知識が
「**上書き**」
され、Bに特化してしまふ

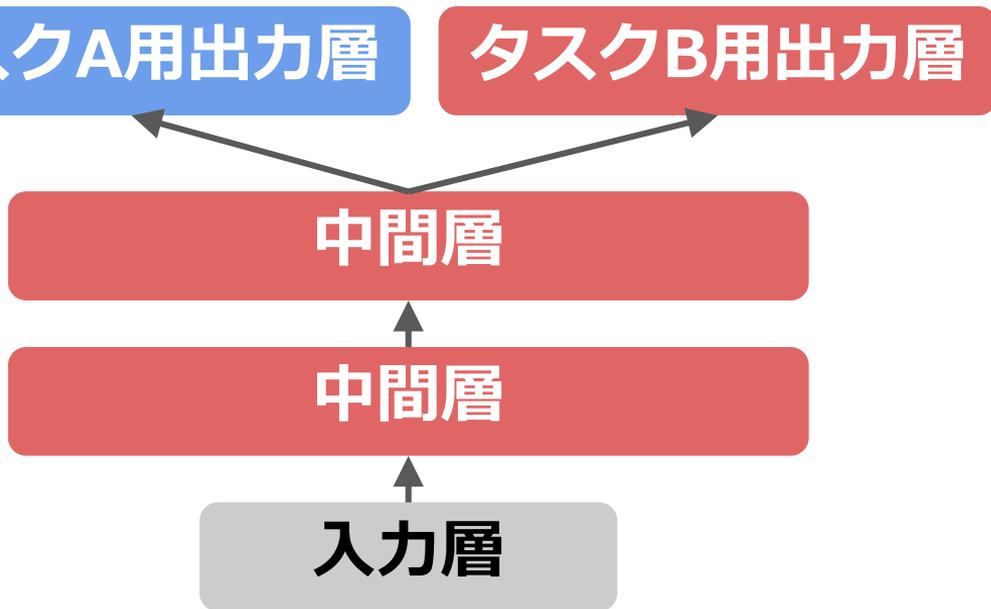
タスクA用出力層

タスクB用出力層

中間層

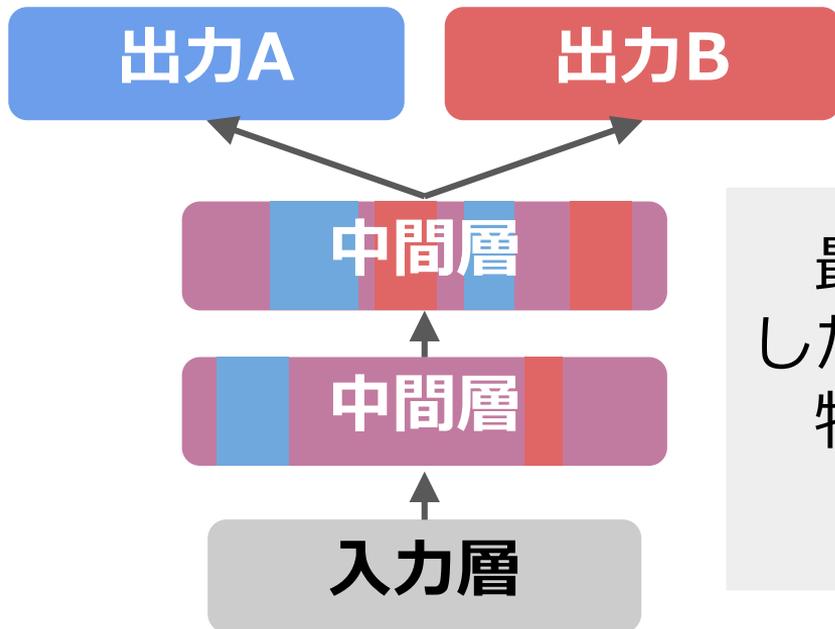
中間層

入力層



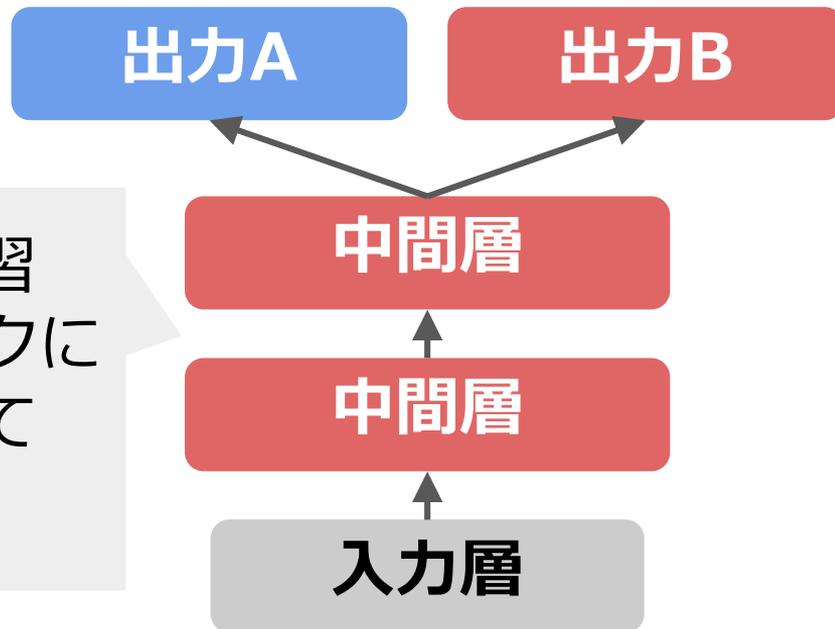
ニューラルネットの性質

理想



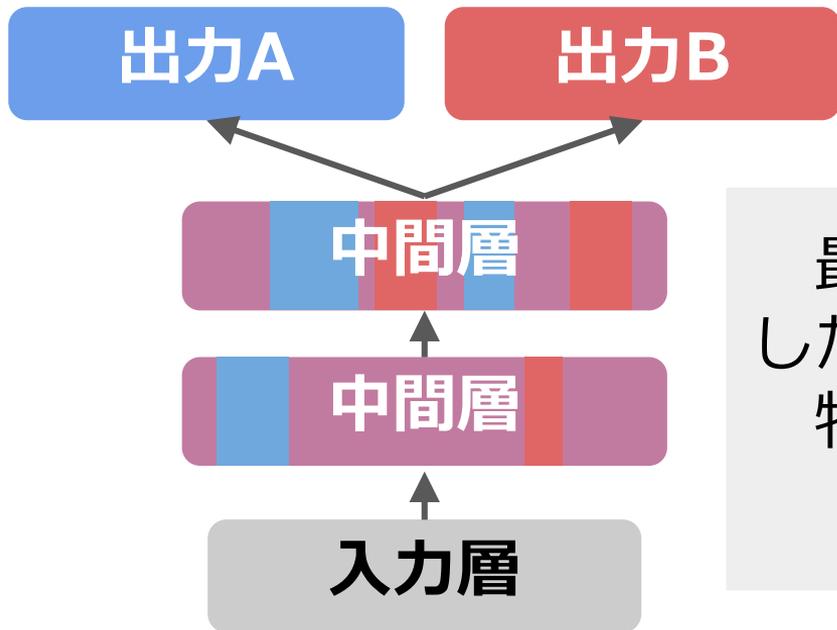
現実

最後学習したタスクに特化してしまう

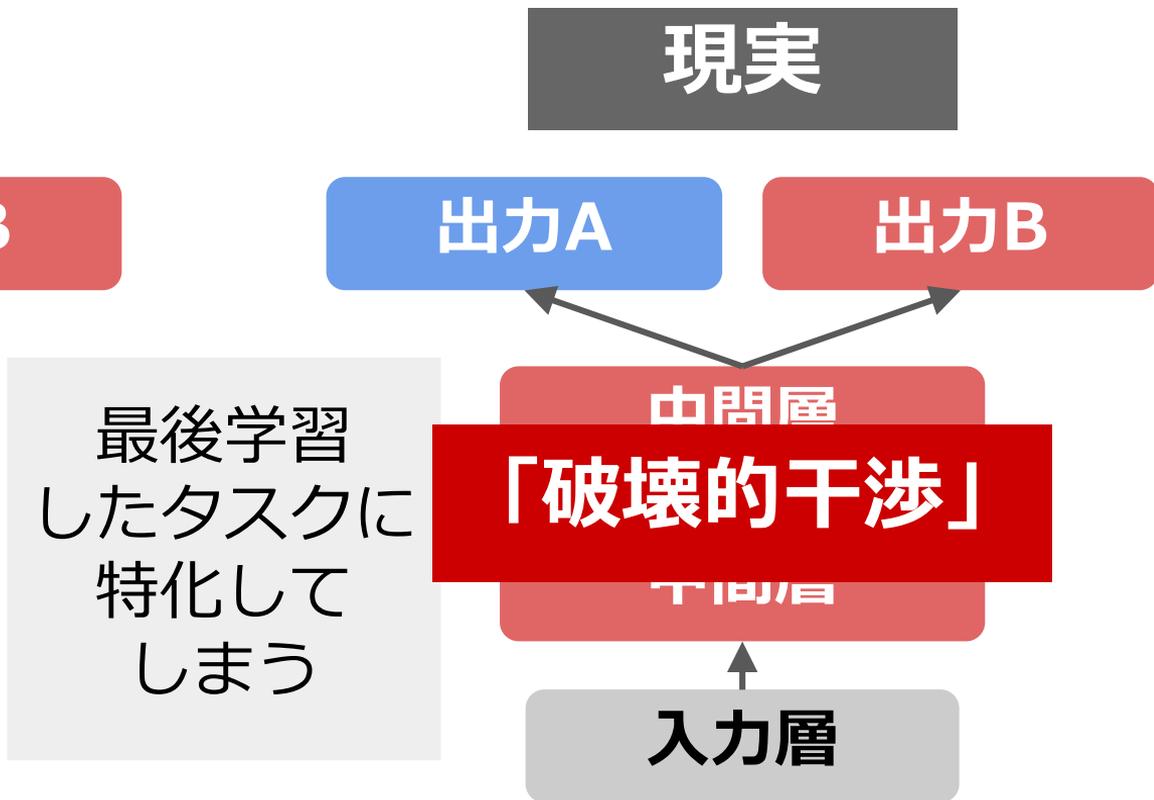


ニューラルネットの性質

理想



現実



破壞的干涉 (catastrophic interference)

ニューラルネットの大きな問題

ディープやシャロー、教師あり、教師なしや強化学習
構わず影響される



人間の場合

人間は大事な知識や記憶をある程度忘れない

新たな情報を既存の知識と結びつけることができ、
それにより学習が速くなる（転移学習）



> -3
 ≈ 3.14
 $+ 2 \cdot 3$
 $(1 - 2) + 3$
 $1_2 = 5_{10}$

∞ $+$ $-$
 \times \div
 5^2



人間と汎用人工知能

① 「破壊的干渉」を避ける
過去に獲得した知識を
保持する

② 「転移学習」を行う
過去に獲得した知識を
新しいタスクに利用する

	①	②
人間	○	○
汎用人工知能	○	○
流行りのNN	×	△

今ハッカソンの目標

Lisを利用し、仮想環境で複数のゲームを遊ばせる
(強化学習)

知識の再利用を行う特殊なモデルを利用する

それとベースラインの学習の速さを比較する

比較と観察を通し、continual learningの有効性を示す

モデル

強化学習のモデル : A3C[1]

continual learningを行う手法 : Progressive Neural Networks[2]

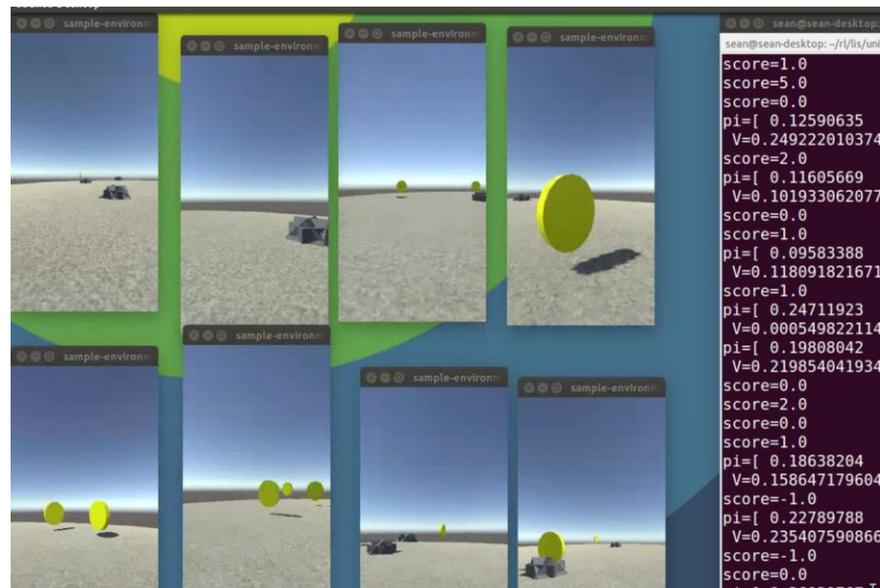
A3C (Asynchronous Advantage Actor Critic)

Actor-Critic法で、複数のエージェントを並列に動かして学習

experience replayが必要なくなる

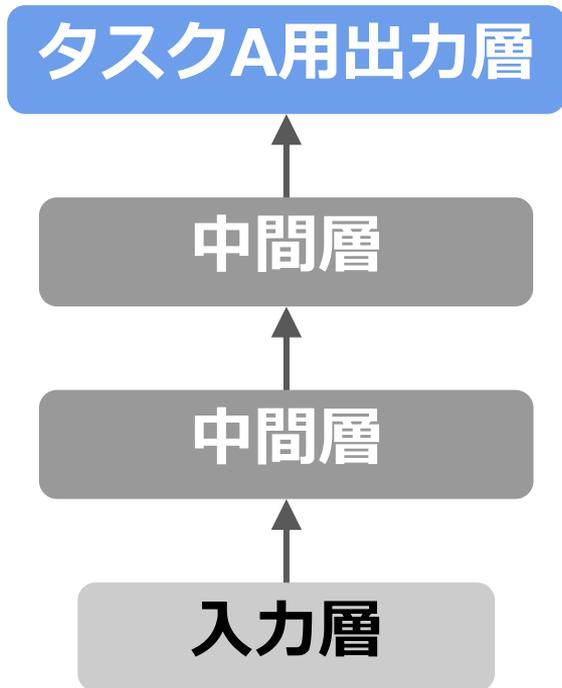
DQNより良い結果が出ている

今回は8個のエージェントを
並列に回した



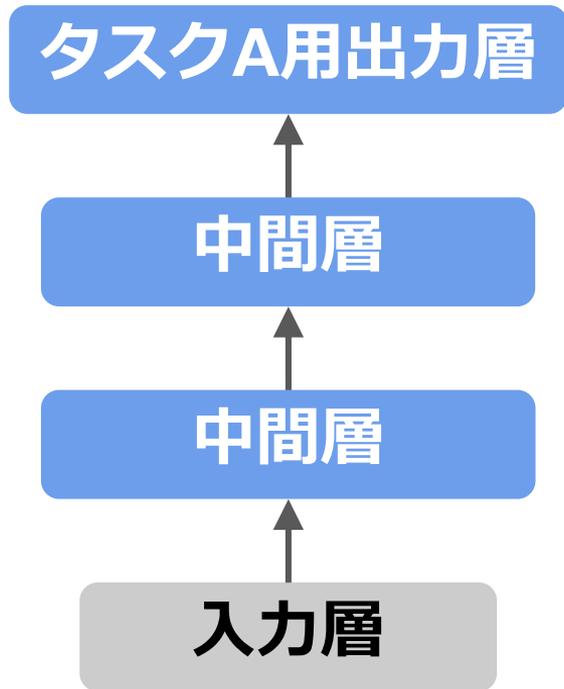
Progressive Neural Networks (PNN)

1. ニューラルネットを用意



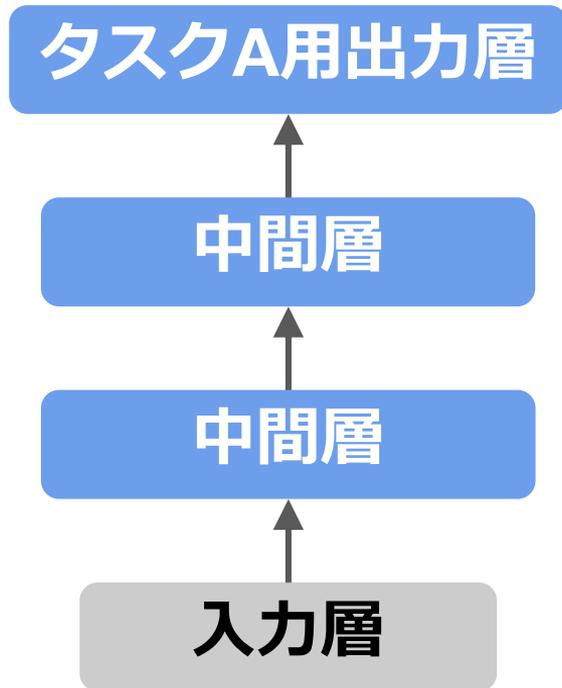
Progressive Neural Networks

2. タスクAを学習



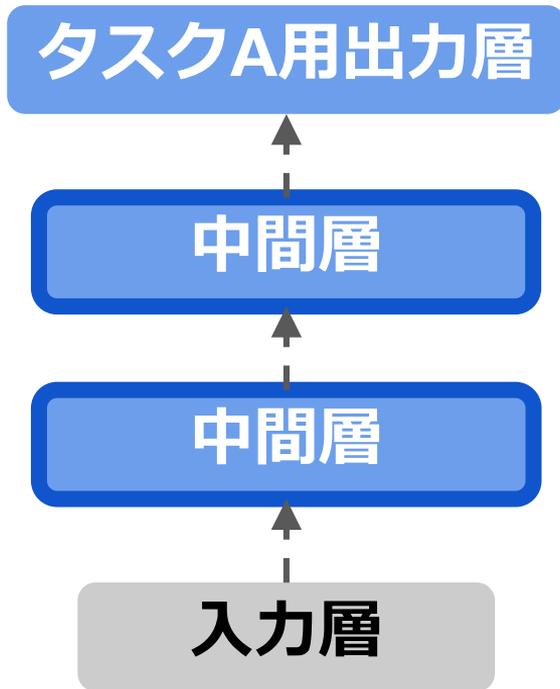
Progressive Neural Networks

ここからどうやって破壊的干渉を避けるのか？



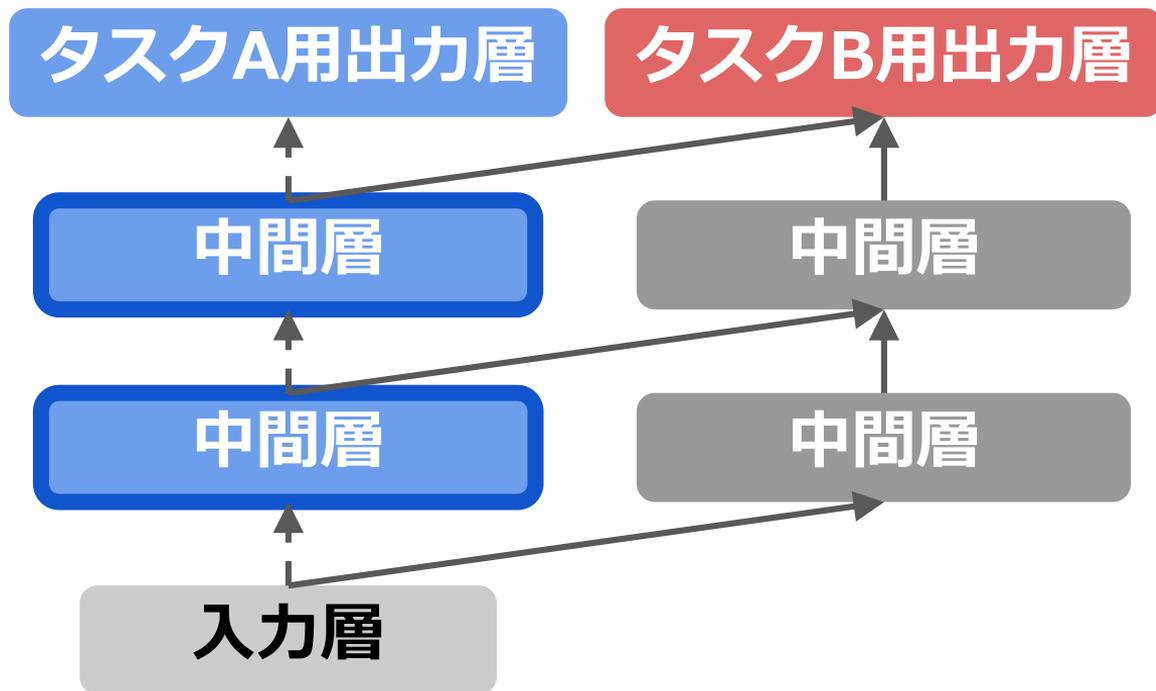
Progressive Neural Networks

4. 重み（パラメータ）を固定



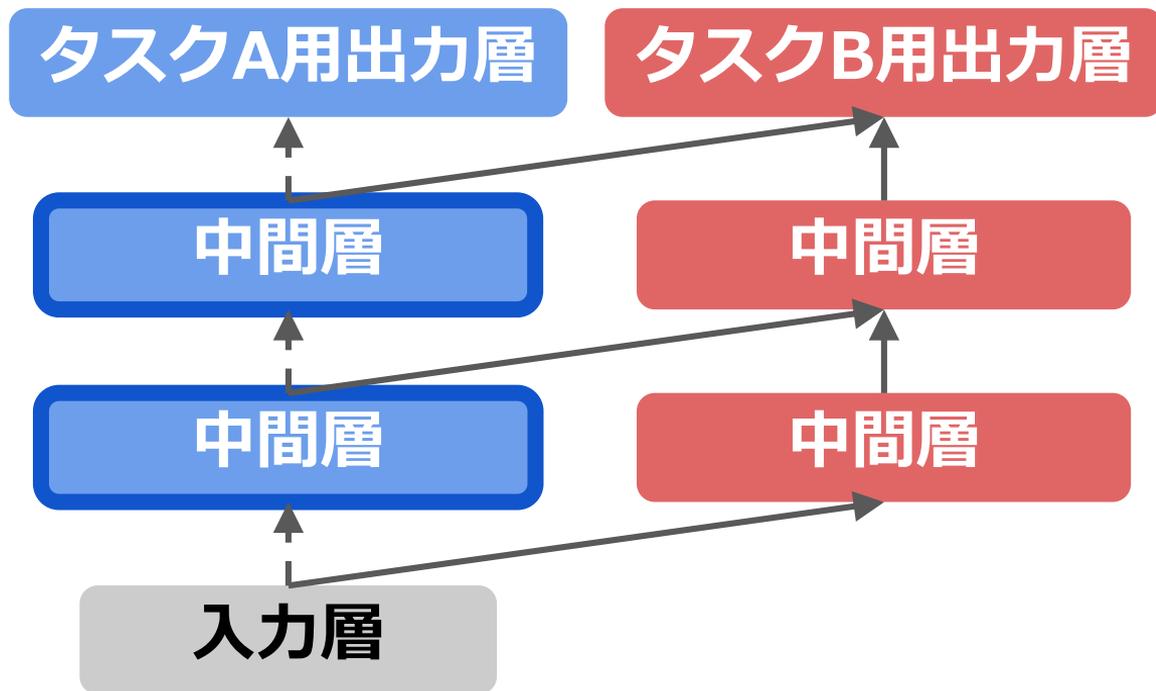
Progressive Neural Networks

3. 新しい「カラム」を追加



Progressive Neural Networks

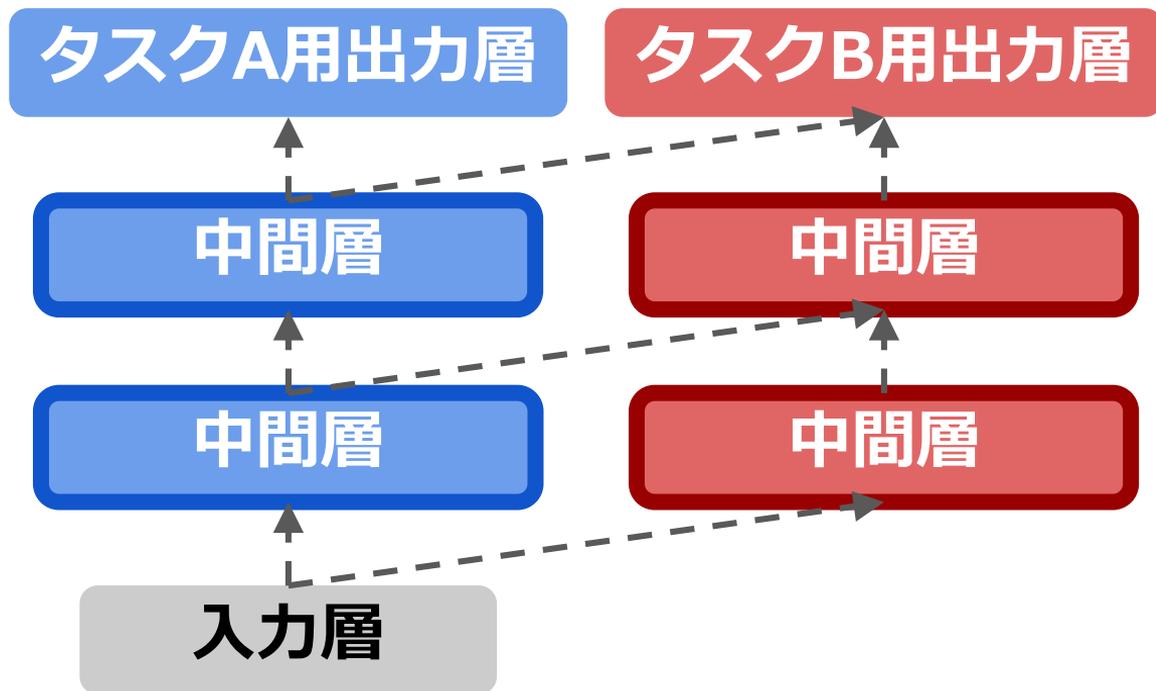
4. カラム2でタスクBを学習



カラム1の重みは固定されているから、タスクBの学習に影響されない

Progressive Neural Networks

5. カラム2のパラメータも固定



Progressive Neural Networks

6. タスクが増えるほどカラムを追加していけばいい



Progressive Neural Networks

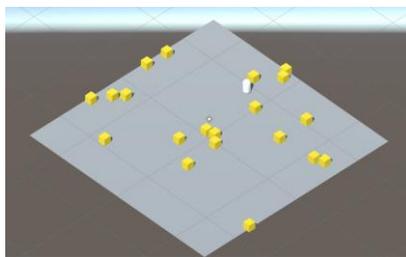
- 過去に学習した知識が失われない
(破壊的干渉を完璧に避ける)
- 過去に学習した知識を新しいタスクに使える
(転移学習)

- タスクが増えるほどパラメータが増える
- カラムを追加するタイミングが決まっている

学習させるゲーム

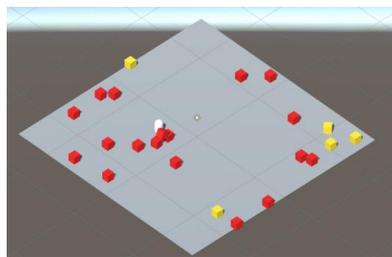
①

報酬のみ
のゲーム



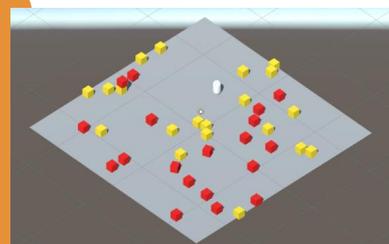
②

ほとんど罰
のゲーム



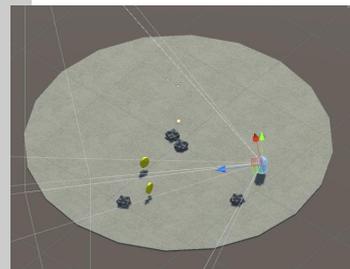
③

報酬と罰
のゲーム

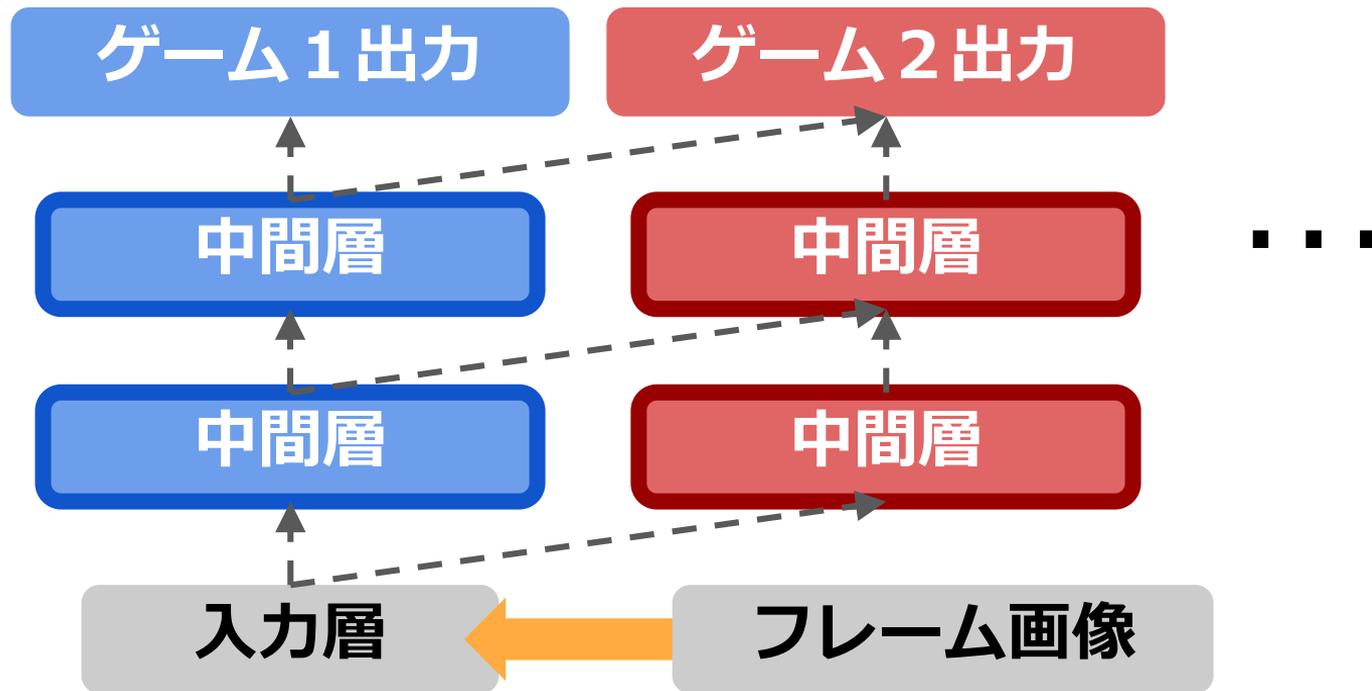


④

アイテムの
外見が違う
ゲーム

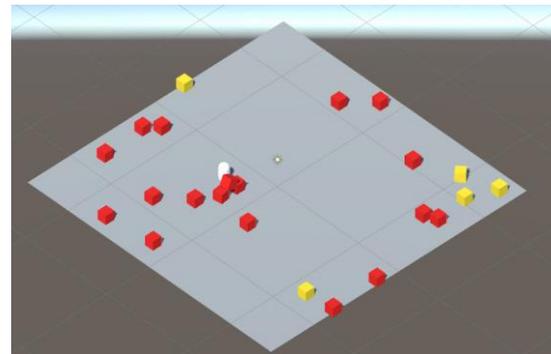
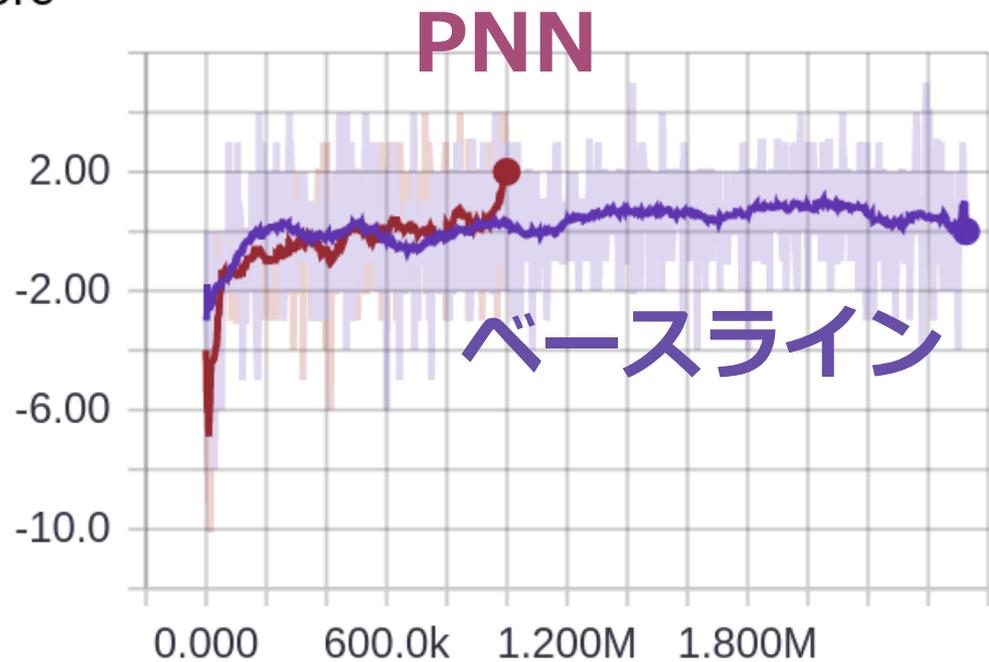


今回の場合



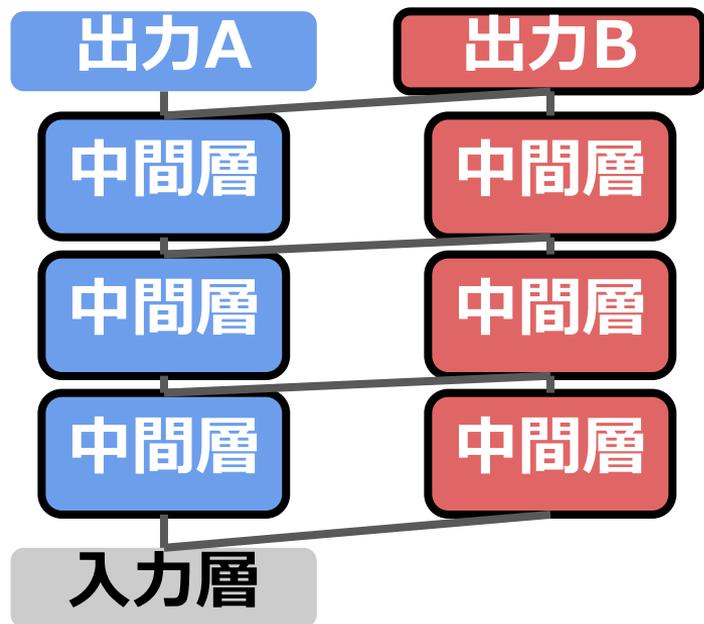
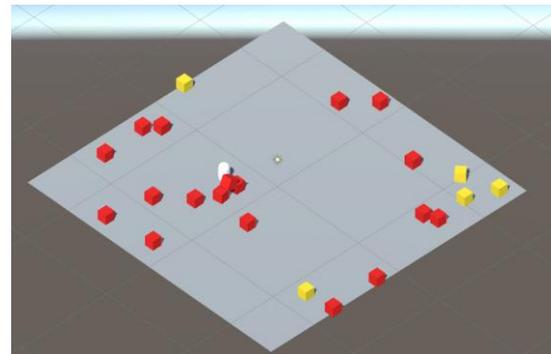
結果 | ゲーム② | 学習

score



結果 | ゲーム② | 転移

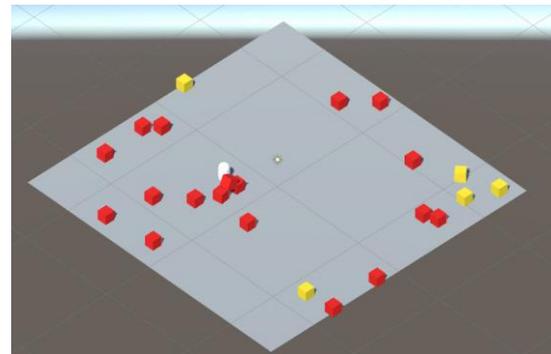
偏微分で、各層の活性が出力に与える
影響力を計算



0.27	0.75
0.46	0.54
0.73	0.27

結果 | ゲーム② | 転移

偏微分で、各層の活性が出力に与える
影響力を計算



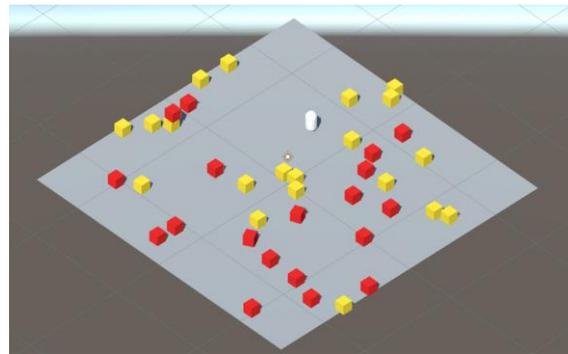
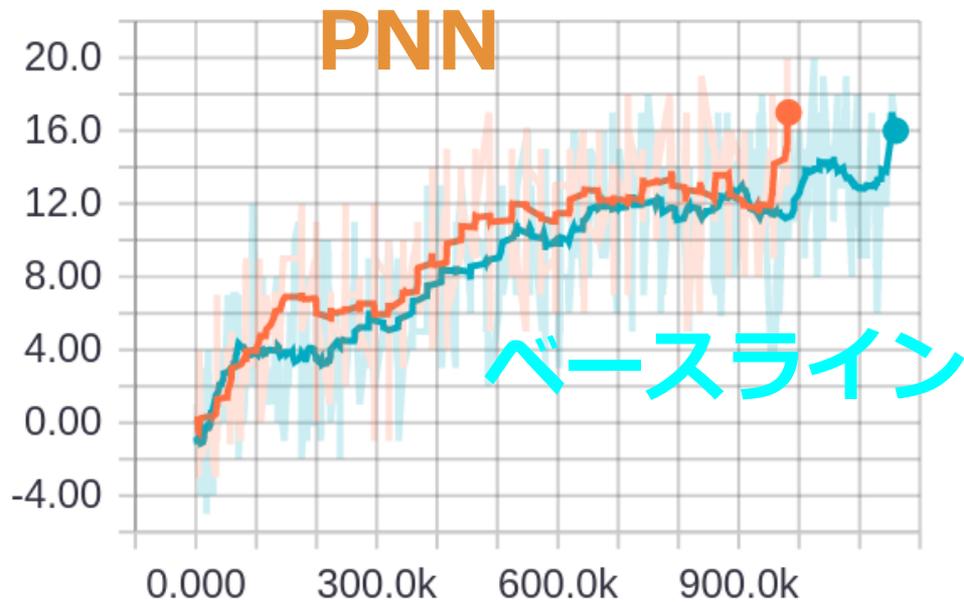
高次な処理はほとんど
新しく学習した

低レベルの特徴は
ゲーム①で
獲得したものを再利用

0.27	0.75
0.46	0.54
0.73	0.27

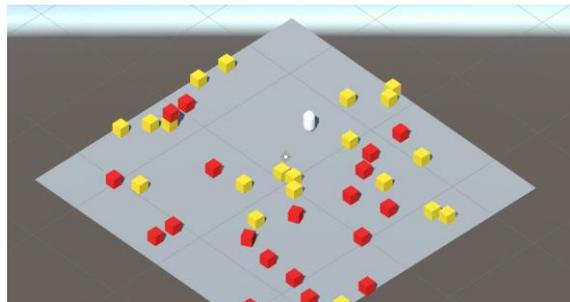
結果 | ゲーム③ | 学習

score



結果 | ゲーム③ | 転移

ゲーム②と似たパターン



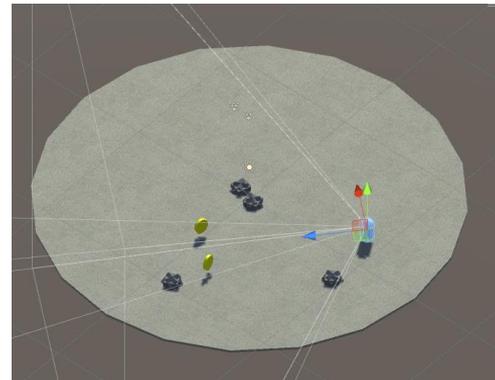
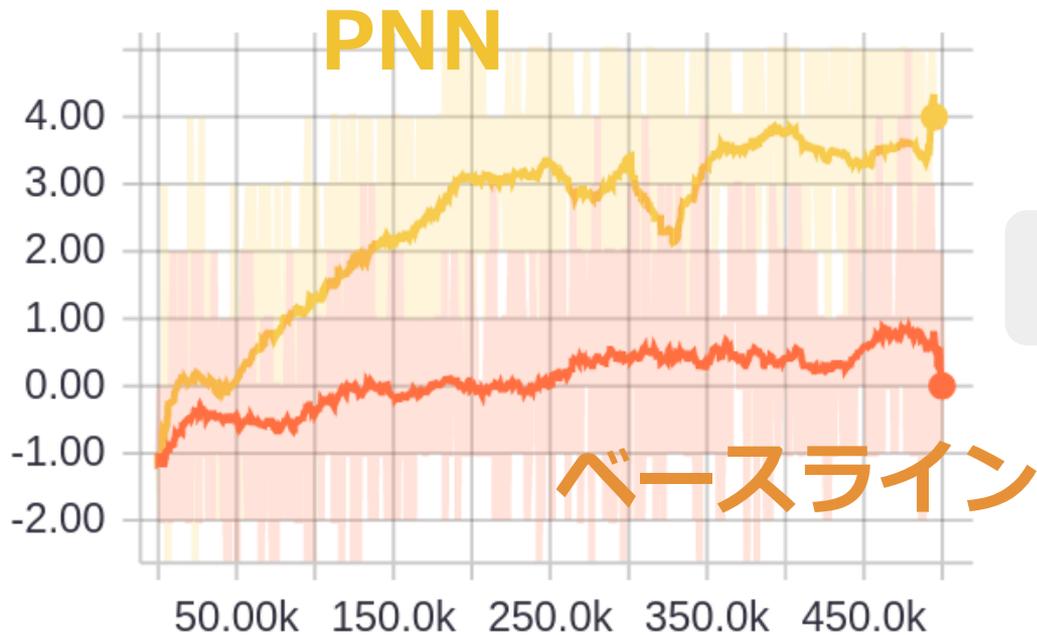
0.14	0.26	0.61
0.48	0.23	0.29
0.68	0.16	0.16

低レベルの
特徴は
ゲーム①のを再
利用

高次元特徴は
新しいのを
利用

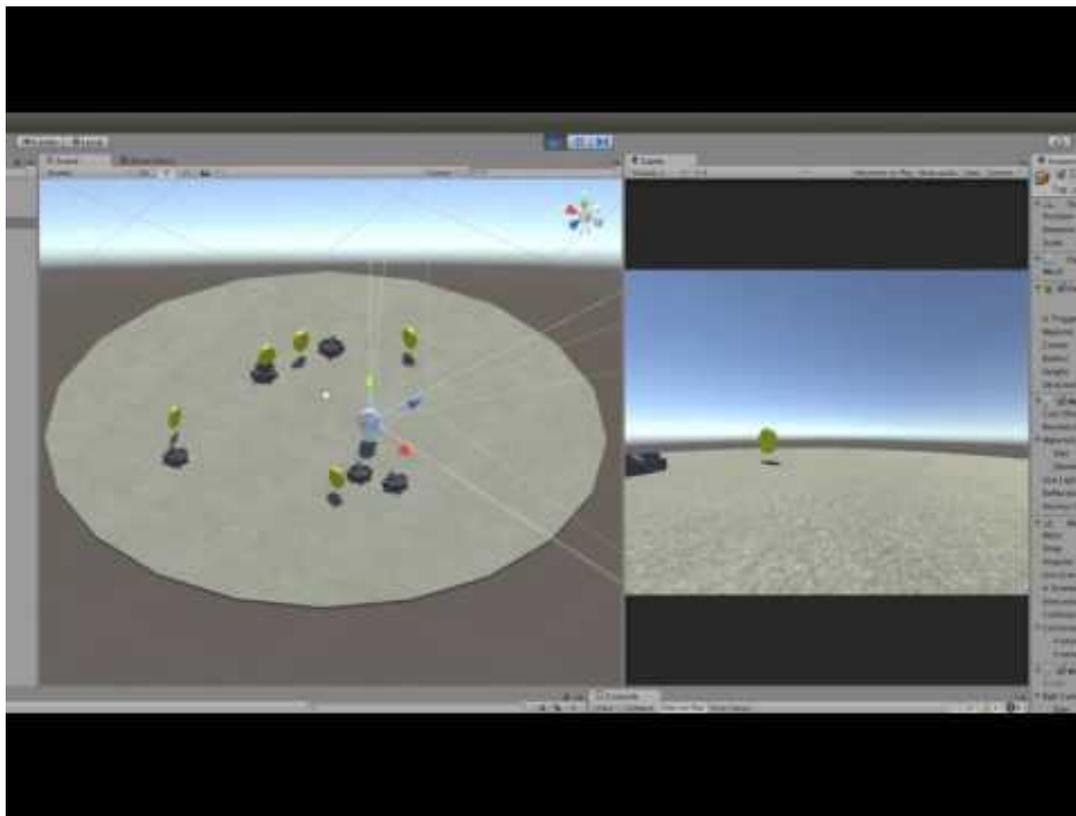
結果 | ゲーム④ | 学習

score

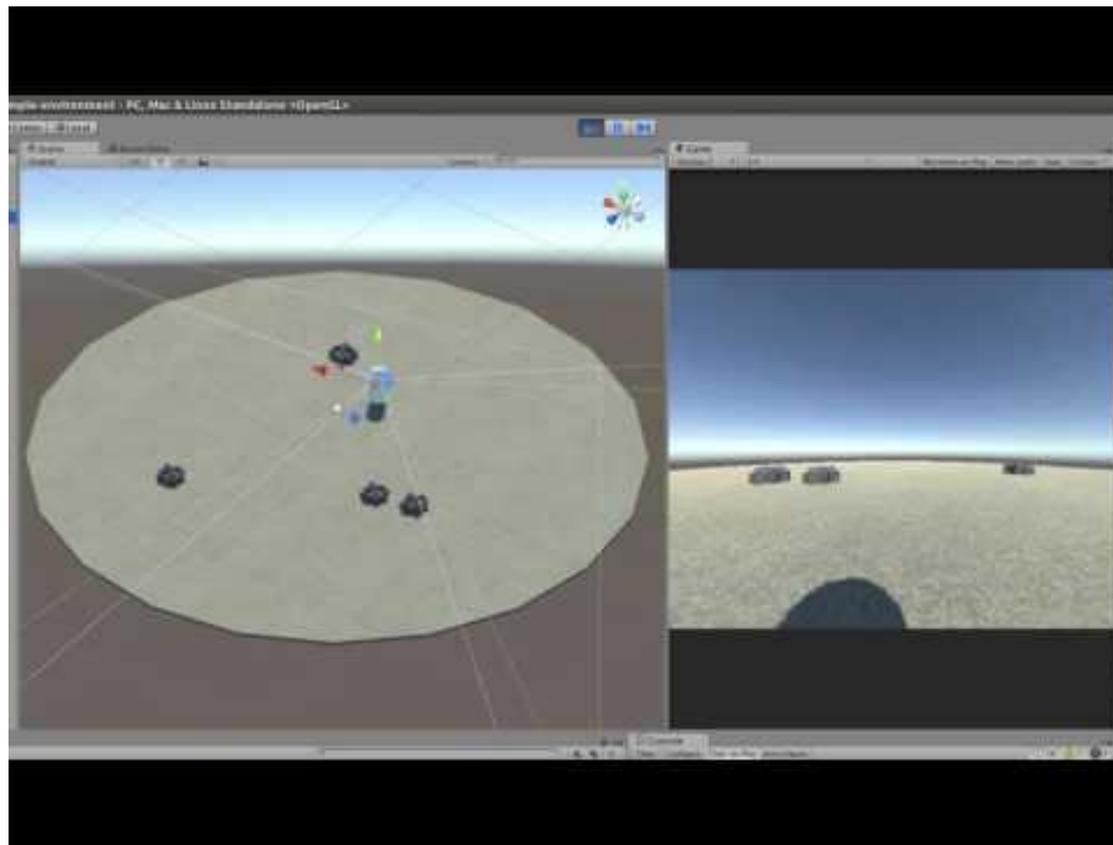


ここで大きな差が出た

結果 | ゲーム④ | 動画 | ベースライン



結果 | ゲーム④ | 動画 | PNN

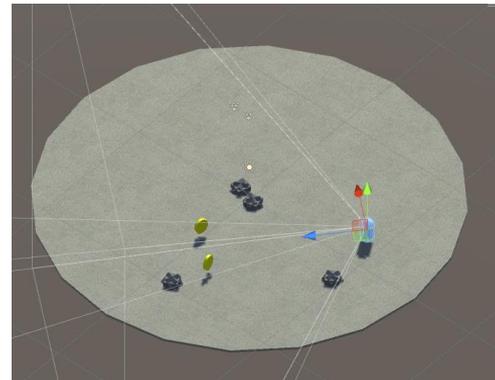


結果 | ゲーム④ | 転移

③の「寄る」と「避ける」が転移？

ここの特徴は相
変わらず
よく利用
される

0.16	0.12	0.38	0.33
0.45	0.16	0.22	0.17
0.80	0.08	0.08	0.04



なぜ④は大きな差を出したのか？

③→④の変化：

見たい目

PNNの方は既に基本的な形を認識することができたから、
もっと複雑なものの学習が速かった

報酬・罰アイテムの数（③20/20 → ④5/5）

報酬信号がよりまばらになった結果、ゼロから学習する
モデルにはそれほど難しくなったのかもしれない

まとめ

汎用人工知能へ向けて、

複数のゲームを攻略できるモデルを実装した

学習されたモデルの「中身」を観察した

一つだけのゲームを学習したモデルよりも、

過去の経験から獲得した知識を再利用するモデルの方が学習が速いと示した

今後の展望

自動にカラム・ニューロンを追加・削除

再帰的な重みの追加

外部記憶の追加

教師なし学習を追加 (Predictive Codingなど)

今後の展望

自動にカラム・ニューロンを追加・削除

再帰的な重みの追加

外部記憶の追加

教師なし学習を追加 (Predictive Codingなど)

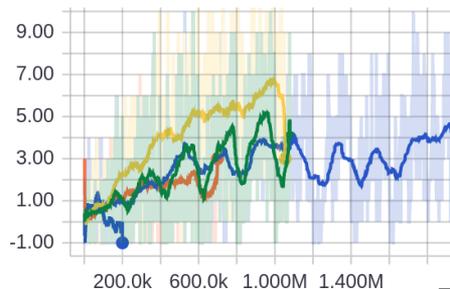
今後の展望 | 自動追加・削除

PNNの問題の一つ：

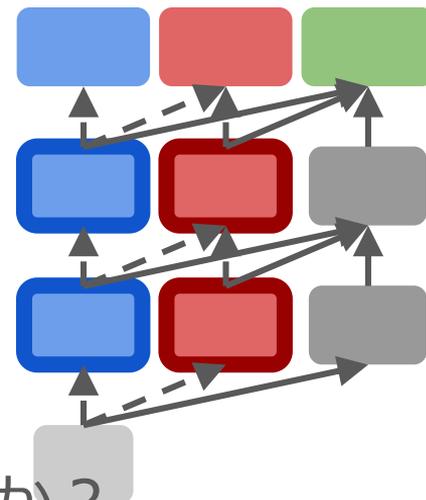
タスクが増えるほどパラメータの数が急増する

あまり使われていないニューロンを削除できるか？

→ 性能を保ち、効率化する



現在実験中...



0.16	0.12	0.38	0.33
0.45	0.16	0.22	0.17
0.80	0.08	0.08	0.04

もっと後の展望

色々学習させてAGIに近づく??

関連リンク

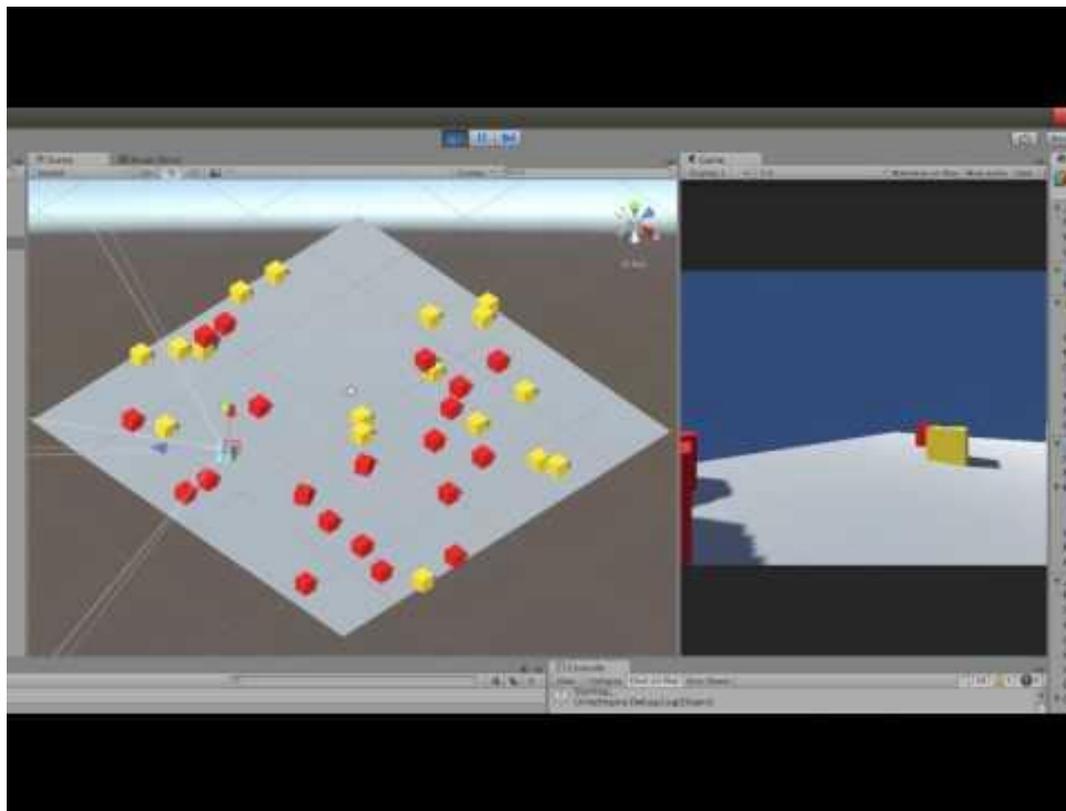
[1] A3C

<https://arxiv.org/abs/1602.01783>

[2] Progressive Neural Networks

<https://arxiv.org/abs/1606.04671>

結果 | ゲーム③ | 動画 | PNN



より精密な観察を試した

中身をよりよく知るため、
③のモデルをいじった

環境の変化がどう内部・
出力が変わるかを観察した
が、目ではあまりわから
なかった...

