

## DenseNet の将棋 AI への適用

竹内元気<sup>1</sup> 儀同政伸<sup>1</sup> 掛谷英紀<sup>1</sup>

**概要:** 近年将棋 AI において Deep Learning を用いた手法が広く採用されている。多くの将棋 AI において学習ネットワークに 1 層ごとにスキップ接続を行う ResNet を使用している。しかしながら ResNet では直前の層以外と直接特徴量を比較できないという問題がある。本研究では直前までのすべての層と接続する DenseNet を学習ネットワークに使用し、ResNet との局面評価精度及び推論性能の比較を行う。

## Application of DenseNet to Shogi AI

GENKI TAKEUCHI<sup>†1</sup> MASANOBU GIDO<sup>1</sup> HIDEKI KAKEYA<sup>†1</sup>

**Abstract:** In recent years, methods utilizing deep learning have been widely adopted in Shogi AI. Many of these AIs employ the use of ResNet, a learning network that incorporates skip connections for each layer. However, a limitation of ResNet is its inability to directly compare feature maps beyond the preceding layer. In this study, we explore the use of DenseNet, a learning network that connects with all previous layers, and compare its classification accuracy and inference performance with ResNet.

## 1. はじめに

近年、第 1 回～第 3 回電竜戦での GCT の 3 連覇や 2022 年に行われた第 32 回世界コンピュータ将棋選手権及び 2023 年に行われた第 33 回世界コンピュータ将棋選手権での dlshogi with HEROZ の優勝を始めとして Deep Learning を用いた将棋 AI の強さが評価され、開発が盛んになっている。Deep Learning を用いた将棋 AI では図 1 のように駒の配置、駒の利き、持ち駒、王手がかかっているか否かを入力特徴量とし、次に着手する手及び現局面での勝率を出力とする Policy Value Network[1]を採用している。入力特徴量が画像と似ており、画像認識タスクとの親和性が高いためネットワーク構造に ResNet[2]を使用している。

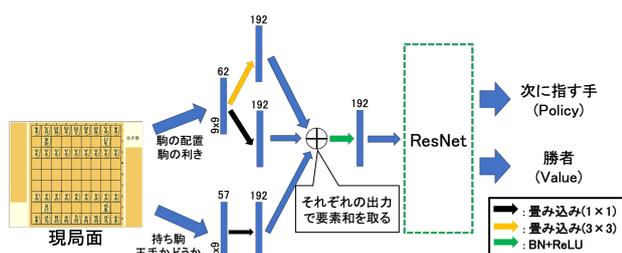


図 1 Policy Value Network の概観

ResNet は残差ブロックにより構成される学習ネットワークである。残差ブロックでは畳み込み・バッチノーマリゼーション及び活性化関数を適用した出力と入力の差分を学習する。このようにスキップ接続を行うことで勾配損失を防いでいる。ResNet Block の

概観を図 2 に示す。

しかしながら ResNet では 1 つ前の層との比較のみを行っており、それより前の層との比較を行うことができない。これを解消する手法として DenseNet[3]が提案されている。

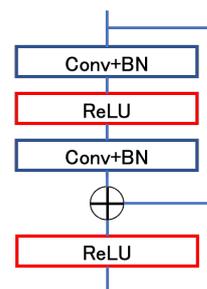


図 2 ResNet Block の概観

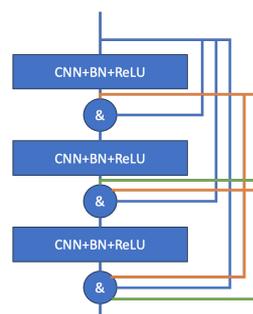


図 3 Dense Block によるスキップ接続

DenseNet は Dense Block と Transition Layer により構成されるネットワークである。Dense Block では図 3 に示すように直前までのすべての層とスキップ接続を行い、接続時にチャンネル方向に特徴量を結合

<sup>1</sup> 筑波大学  
University of Tsukuba

する。Transition Layer では畳み込みと Average Pooling を行い、チャンネル数の圧縮を行う。

本研究では Deep Learning を用いた将棋 AI においてネットワーク構造に DenseNet を使用してその性能の評価を行う。

## 2. 提案手法

提案手法では Policy Value Network のネットワーク構造に DenseNet を用いる。DenseNet のレイヤ数は 10 とし、Dense Block では 2 層の畳み込み層を採用する。畳み込み層には  $3 \times 3$  のカーネルを用いる。また、それぞれの畳み込みにおいては入力と出力の高さと幅が等しくなるようなパディングを行う。そして、それぞれの層の前に、共変量シフトに対応するための batch normalization(以下、BN)層、活性化関数として、rectified linear unit(以下 ReLU)層を配置する。

1 層目の畳み込み時にはチャンネル数を 128 に、2 層目の畳み込み時にはチャンネル数を 32 にする。2 層目の畳み込み層の後に、直前のレイヤまでのすべての出力をチャンネル方向に結合する。また、ダウンサンプリングによる位置情報のズレを防ぐため Transition Layer によるダウンサンプリングは行わない。図 4 に提案手法における Policy Value Network の概観を、図 5 に DenseNet の概観を示す。

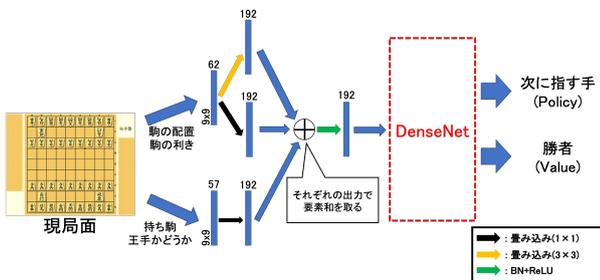


図 4 提案手法における Policy Value Network の概観

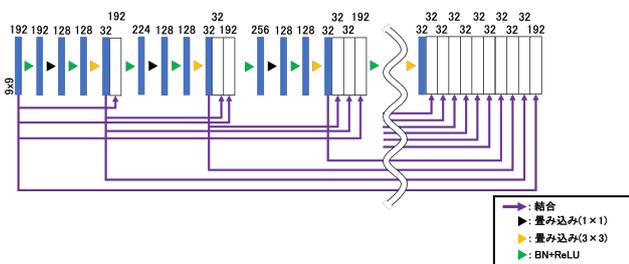


図 5 提案手法における DenseNet の概観

## 3. 実験と結果

### (1) 識別精度の比較実験

DenseNet の識別精度を評価するための計測実験を行った。学習データに書籍「強い将棋ソフトの創り方」付属の学習データ[4]を使用し、288 エポック学習させた。その後テストデータとして同本付属のテストデータを使用し Policy 及び Value の識別精度を計測した。学習率スケジューラには初期値を 0.2 として ReduceLROnPlateu を適用した。また、汎化性能を向上させるため 250 学習ステップごとに学習ネットワークの重みを平均化する Stochastic Weight Averaging (SWA)を適用した。更に GPU メモリの使用率削減及び学習の高速化のために精度を維持しながら 16bit 半精度浮動小数点数により学習を行う Automatic Mixed Precision (AMP)を適用した。提案手法と比較するため同じフィルタサイズを持つ ResNet10 (32channel)及びパラメータ数が同等の ResNet10 (154 channel)でも同様の計測を行った。

表 1 に DenseNet10, Resnet10 (32 channel), ResNet10 (154 channel)で計測を行った結果を示す。Policy, Value ともに Resnet10 (32 channel)より識別精度は高いものの ResNet10 (154 channel)よりは低い結果となった。これは層が深くなるごとに特徴量のチャンネル数が増加し、複雑化しすぎたためであると考えられる。

DenseNet ではすべての層とチャンネル方向にスキップ接続を行うため、層が深くなるごとに入力特徴量のチャンネル数が増える。本研究において各 DenseBlock の出力のチャンネル数は 32 であったため、1 層深くなるごとに前の層から 32 チャンネル増えることになる。そのため、最終的な出力のチャンネル数は 512 チャンネルとなる。

表 1 DenseNet10 と ResNet10 の識別精度の比較結果

Model	Policy Accuracy (%)	Value Accuracy (%)
DenseNet10 (提案手法)	47.2	74.9
ResNet10 (32 channel)	41.0	71.7
ResNet10 (154 channel)	48.6	75.6

### (2) 対戦による比較実験

識別精度の比較実験で学習したモデルを使用し、DenseNet と ResNet の推論性能を比較するための対戦実験を行った。DeepLearning Shogi のリーグ戦機能を使用し、DenseNet10, ResNet10(32 channel), ResNet10(154 channel)の 3 者リーグを

それぞれ 200 局ずつ計 600 局行った。初期局面は floodgate の棋譜から作成した互角局面とし、各互角局面に対し先後入れ替えて 1 局ずつ対局させた。各モデルにおいて探索パラメータは DeepLearning Shogi のデフォルト値を使用し、推論時のバッチサイズは 1024 とした。また、使用したマシンのスペックは Intel Core i5-8500, NVIDIA GeForce RTX2080Ti, RAM 32GB, Ubuntu18.04+Docker (nvidia/tesorrt:22.08-py3)である。

リーグ戦の結果を表 2 に示す。提案手法のレーティングは -4.7(±19.8)となり、ResNet10 (154 channel)に次ぐ強さとなった。ResNet10 (32 channel)に対しては 233 勝 62 敗 5 分、ResNet10 (154 channel)に対しては 43 勝 223 敗 34 分という結果であった。初期局面で 1 分間思考させた際の NPS (Node Per Second)は DenseNet10 が約 51,000 NPS, ResNet10 (32 channel)が約 250,000 NPS, ResNet10 (154 channel)が約 64,000 NPS であった。NPS で劣る ResNet10 (32channel)に対しては識別精度の高さで上回ることができた一方で、ResNet10 (154 channel)に対しては NPS・識別精度の双方で劣っていたため、推論性能としても劣る結果になったと考えられる。ResNet10(154 channel)と DenseNet10 は同等のパラメータ数であるにも関わらず DenseNet10 の NPS が低くなった原因としてチャンネル数の増大による計算量の増加が挙げられる。そのため、識別精度の面だけでなく推論性能の面からもチャンネル数増大の対策が必要であると考えられる。

表 2 DenseNet と ResNet によるリーグ戦の結果

Model	RATING	ERROR	(%)	CFS (%)
DenseNet10 (提案手法)	-4.7	19.8	49	100
ResNet10 (32 channel)	-192.3	24.8	18	---
ResNet10 (154 channel)	197.0	24.9	83	100

#### 4. おわりに

本研究では従来の Policy Value Network に採用されている ResNet に代わり DenseNet を採用し、識別精度を比較した。その結果 ResNet10 (32 channel)と比較して識別精度が向上したものの ResNet10 (154 channel)より劣る結果となった。また、リーグ戦を行い、推論性能を評価した結果 ResNet10 (32 channel)に大きく勝ち越した一方で ResNet10 (154 channel)に大きく負け越すという結果となり、同等のパラメータ数の ResNet より識別精度・推論性能双方において劣ることがわかった。今後の展望としてチャンネル数の肥大化の対策や畳み込みカーネルの改良による識別精度の向上が考えられる。

#### 参考文献

- [1] Silver, D., et al.: Mastering the game of Go without human knowledge. Nature 550(7674), pp. 354–359 (2017)
- [2] Kaiming He, Xiangyn Zhang, Shaoqing Ren, Jian Sun: “Deep Residual Learning for Image Recognition”, 2015
- [3] Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger: “Densely Connected Convolutional Networks”, 2016
- [4] 山岡忠夫, 加納邦彦. 強い将棋ソフトの創り方 Python で実装するディープラーニング将棋 AI, 2021, 212p.