

## 将棋 AI における DenseNet の改良と局面識別精度の評価

竹内元気<sup>1</sup> 儀同政伸<sup>1</sup> 中川翔太<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 は ResNet を使用しているが, これは直前の層とのみ特徴量を比較するため, それ以外の層と直接比較できない. この問題を解決するために DenseNet が提案されているが, 層が深くなるとチャンネル数が増加し特徴量が複雑になりすぎるため, 将棋 AI において ResNet より局面識別精度が低下する傾向がある. 本研究では, この問題を解決する改良版 DenseNet を考案し, 局面識別精度の評価を行う.

## Improvements to DenseNet in Shogi AI and Evaluation of Board State Identification Accuracy

GENKI TAKEUCHI<sup>1</sup> MASANOBU GIDO<sup>1</sup> SHOTA NAKAGAWA<sup>1</sup>  
HIDEKI KAKEYA<sup>1</sup>

**Abstract:** In recent years, deep learning techniques have been widely adopted in Shogi AI. Many Shogi AI programs use ResNet, which only compares features with the immediately preceding layer, limiting direct comparison with other layers. To address this issue, DenseNet has been proposed, but as the network depth increases, the number of channels also increases, leading to overly complex features. Consequently, DenseNet tends to exhibit lower board state identification accuracy than ResNet in Shogi AI. This study proposes an improved version of DenseNet to solve this problem and evaluates its board state identification accuracy.

## 1. はじめに

近年, 第 1 回~第 3 回電竜戦での GCT の 3 連覇や第 32 回~第 33 回世界コンピュータ将棋選手権での dlshogi with HEROZ の連覇を始めとして 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.

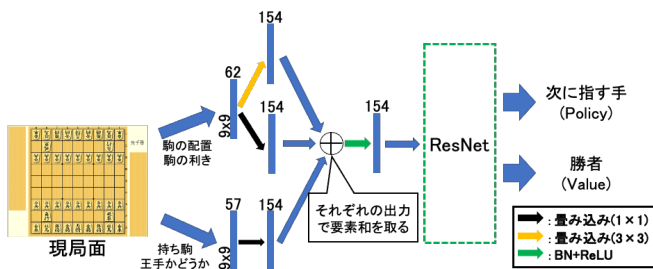


図 1 Policy Value Network の概観

ResNet は残差ブロックにより 1 つ前の層との比較のみを行っており, それ以外の層との比較を行うことができない. これを解消するため特徴量を直前ま

でのすべての層とチャンネル方向に結合する DenseNet[3]を適用する手法を提案し性能の評価を行った[4]. しかしながら層が深くなるにつれて特徴量のチャンネル数が増加し, 複雑化しすぎたため同等のパラメータ数の ResNet より識別精度が低い結果となった.

本研究では従来の DenseNet が抱えていたチャンネル数の増大による識別精度の低下を解消する改良を施した改良版 DenseNet を使用しその識別精度の評価を行う.

## 2. 提案手法

提案手法では Policy Value Network のネットワーク構造に改良版 DenseNet を用いる. 従来の DenseNet では直前までのすべての層とチャンネル方向にスキップ接続を行っていたがこれを ResNet のように直前までのすべての層と要素和を取る. 要素和を取ったあとオーバーフロー対策のため要素和を取った層の数で割り, 平均を取る. 改良版 DenseNet のレイヤ数は 10 とし, チャンネル数は 154 にする. 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,

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

BN)層, 活性化関数として, rectified linear unit(以下 ReLU)層を配置する.

図 2 に提案手法における Policy Value Network の概観を, 図 3 に従来の Dense Block と改良した Dense Block の比較を示す.

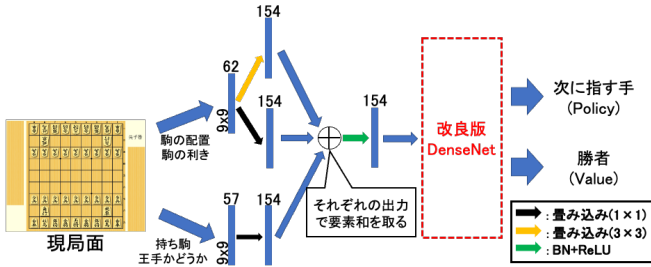


図 2 提案手法における Policy Value Network の概観

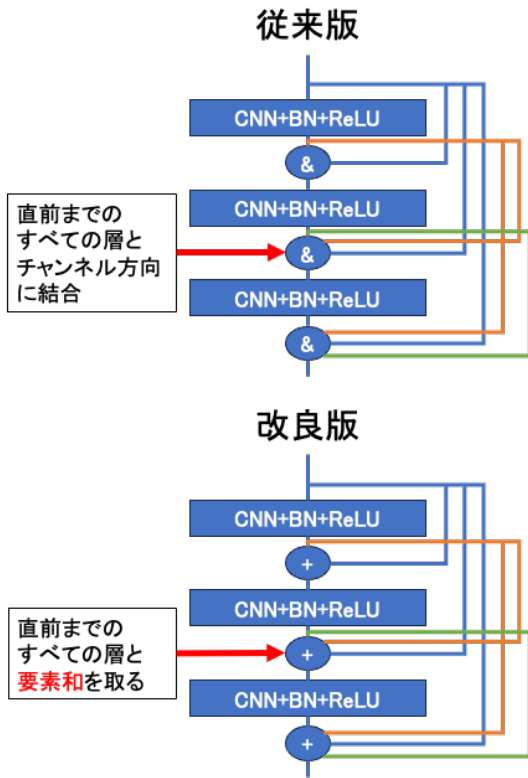


図 3 従来の Dense Block と改良した Dense Block の比較

### 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[5]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. 比較としてパラメータ数が同等の DenseNet10 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 に改良版 DenseNet10, Resnet10 (154 channel), DenseNet10 で計測を行った結果を示す. Policy, Value ともに改良版 DenseNet10 (154 channel)の方が Resnet10 (154 channel)及び DenseNet10 より識別精度が高いことがわかる. これは従来の DenseNet で問題となっていたブロック数の増加に伴う特徴量の複雑化が解消されたためであると考えられる.

表 1 改良版 DenseNet10 と ResNet10・DenseNet10 の識別精度の比較結果

Model	Policy Accuracy (%)	Value Accuracy (%)
改良版 DenseNet10 (154 channel, 提案手法)	49.0	75.8
ResNet10 (154 channel)	48.6	75.6
DenseNet10	47.2	74.9

#### (2) 対戦による比較実験

識別精度の比較実験で使用したモデルを用いて, 推論性能を比較するための対戦実験を行った. DeepLearningShogi のリーグ戦機能を使用し, 改良版 DenseNet10, ResNet10, DenseNet10 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を入れ替えて 1 局ずつ対局させた.

使用したマシンのスペックは Intel Core i5-8500, NVIDIA GeForce RTX2080Ti, RAM 32GB, Ubuntu 18.04 + Docker (nvidia/tensorrt:22.08-py3)である. 推論時のバッチサイズは 128 とした. また, 各モデルにおいて探索パラメータは Optuna による調整を行った. 探索パラメータの調整において, 初期局面は floodgate の互角局面を, 基準ソフトは水匠 5 を使用した. パラメータ調整の試行回数は 50 回とし, 50 回終了時点で最も対水匠の勝率が高いパラメータを使用した. モデルごとの探索パラメータを表 2 に示す.

表 2 モデルごとの探索パラメータ

Model	改良版 DenseNet10 (154 channel, 提案手法)	ResNet10 (154 channel)	DenseNet10
C_init	123	170	144
C_base	28445	39081	28288
C_fpu_reduction	11	26	27
C_init_root	132	134	116
C_base_root	22178	41586	25617
Softmax_ Temperature	158	138	174

リーグ戦の結果を表 3 に示す。提案手法のレーティングは-16.3(±19.0)となり、ResNet10 (154 channel)に次ぐ強さとなった。DenseNet10 に対しては 188 勝 84 敗 28 分、ResNet10 (154 channel)に対しては 105 勝 170 敗 25 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)は改良版 DenseNet10(154 channel)が約 28,000 NPS、ResNet10(154 channel)が約 58,000 NPS、DenseNet10 が約 52,000 NPS であった。DenseNet10 に対して NPS で劣りながらも識別精度で上回った結果推論性能で上回った一方で ResNet10 (154 channel)に対しては識別精度でのみ僅差で上回ったが NPS で劣ったため、推論性能で劣る結果になったと考えられる。ResNet10(154 channel)と改良版 DenseNet10 (154 channel)は同等のパラメータ数であるにも関わらず改良版 DenseNet10 の NPS が低くなった原因として直前までのすべての層との総和を取る部分がボトルネックになっていると考えられる。今回の実装では各層において 1 層目からのすべての層の総和を取っていた。そのため、ResNet と比較して総和を取る回数が増え、NPS が低くなったと考えられる。

表 3 リーグ戦の結果

Model	RATING	ERROR	(%)	CFS (%)
改良版 DenseNet10 (154 channel, 提案手法)	16.3	19.0	53	100
ResNet10 (154 channel)	84.1	19.0	67	100
DenseNet10	-100.4	19.1	30	---

#### 4. おわりに

本研究では従来の DenseNet を改良し、Policy Value Network に採用して識別精度を比較した。その結果従来の DenseNet10 及び ResNet10 (154 channel)と比較して局面識別精度が向上した。一方で対戦による比較実験では ResNet10 (154 channel)に負け越し、推論性能で劣ることがわかった。今後の展望として改良版 DenseNet の推論速度の高速化が挙げられる。

#### 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]竹内 元気, 儀同 政伸, 掛谷 英紀: DenseNet の将棋 AI への適用, ゲームプログラミングワークショップ 2023 論文集, 2023, 70-72
- [5] 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.