盤上ゲーム変種における手番の有利・駒価値を調査する手法の提案

西岡 宏祐[1,a)]　竹内 聖悟[1]

概要：本稿では，将棋の変種である 66 将棋を対象とし，低計算コストで手番の有利性および駒価値を定量的に分析する手法を提案する．従来の AlphaZero に代表される深層強化学習による分析手法は先入観を排した評価が可能である一方，膨大な計算資源を要する課題があった．本研究では，約 207 万通りの初期配置と大駒選択の偏りを排した棋譜生成を行い，Fairy-Stockfish の HCE を基盤としたブートストラップ学習により NNUE モデルの構築を行った．対戦検証の結果，構築した NNUE モデルは基準となる HCE に対して最大 57.80%の勝率を達成し，一般的な計算機環境において低コストで強い AI を構築できることを確認した．さらに，対局結果に基づく非線形回帰モデルを持駒・盤上成駒を含む 20 次元特徴量へと拡張し，未知対局データに対する勝敗予測精度によりモデルの妥当性を検証した上で分析を行った結果，中盤対称局面における手番バイアスや，狭い盤面における金・飛車の持駒優位性，小駒の成り上昇値など，66 将棋特有の戦術的特性を客観的数値として明らかにした．

A Method for Analyzing First-Move Advantage and Piece Values in Board Game Variants

Kosuke Nishioka[1,a)]　Shogo Takeuchi[1]

Abstract: In this paper, we focus on 66 Shogi, a variant of Shogi, and propose a method for quantitatively analyzing turn advantage and piece value with low computational cost. While analysis methods based on deep reinforcement learning—such as the conventional AlphaZero—enable bias-free evaluation, they have the drawback of requiring enormous computational resources. In this study, we generated game records using approximately 2.07 million initial board configurations while eliminating bias in the selection of major pieces, and constructed an NNUE model using bootstrap learning based on Fairy-Stockfish's HCE. Results from match verification showed that the constructed NNUE model achieved a win rate of up to 57.80% compared to the baseline HCE, confirming that it is possible to build a strong AI at low cost in a general computing environment. Furthermore, we extended a nonlinear regression model based on game results to a 20-dimensional feature space that includes captured pieces and promoted pieces on the board. After verifying the model's validity through its win-loss prediction accuracy for unknown game data, our analysis revealed move-order bias in symmetrical midgame positions, the advantage of holding Gold and Rook pieces in confined board spaces, and the promotion value of minor pieces—all of which are tactical characteristics unique to 66 Shogi—as objective numerical values.

1. はじめに

将棋やチェスには「どうぶつしょうぎ」や「5 五将棋」をはじめとする多種の変種が存在する．

これらの変種盤上ゲームにおいては，本将棋のように長年の人間の対局経験によって確立された定跡や駒の損得の基準が定まっていないことが多い．本研究の目的は，定跡や経験則が未確立な盤上ゲーム変種において，ルール構造に起因する「手番の有利性」および「各駒の相対的価値」を客観的かつ定量的に明らかにする手法を確立することである．手番の有利性を定量化することは，そのゲームのルー

[1] 高知工科大学 情報学群
Kochi University of Technology, Kami, Kochi 782–8502, Japan
[a)] 270356d@ugs.kochi-tech.ac.jp

© 2026 Information Processing Society of Japan

ルが先手・後手間で公平なゲームバランスを有しているかを検証する上で不可欠である．また，盤面の広さやルール変更に応じた駒価値を明らかにすることは，人間プレイヤが新たなゲームの戦術を理解するための基礎指標となるだけでなく，ゲーム AI の評価関数を設計・調整する上でも重要な指針となる．

このような盤上ゲームにおける駒価値や手番の有利性の定量的分析手法としては，AlphaZero のような深層強化学習モデルを用いたアプローチがある．この手法は人間の先入観を排し，勝敗に直結する価値を測定できる強力な利点がある．しかし，完全ランダム状態から大規模なニューラルネットワークの学習を開始するため多大な計算コストを要し，一般的な計算機環境での多様な変種への適用は容易ではない．

そこで本研究では，66 将棋を題材とし，多様な変種に対応するゲームエンジン「Fairy-Stockfish [1]」と，軽量かつ高速な評価関数学習手法である「NNUE（Efficiently Updatable Neural Network） [2]」を組み合わせることで，一般的な計算機環境でも実行可能な, 低計算コストで手番および駒価値を分析する手法を提案する．

2. 関連研究

嶽ら [3] は，強化学習により学習した評価関数の精度に関する研究を行っており，正確な評価関数を獲得するためには，学習元となる教師データの質を向上させることが必要であると示唆している．完全ランダムな初期重みから自己対局を開始する手法では，学習初期の教師データの質が低く，質の高いデータが得られるまでに膨大な対局数と計算時間を要する．そこで本研究では，嶽らの知見を踏まえ，最初から一定の棋力を持つ手動設計された評価関数である HCE（Hand-Crafted Evaluation）による自己対局データを初期の教師データとして利用することで，学習初期のデータの質を担保する．さらに，学習した NNUE モデル自身による自己対局データを次の世代の学習に用いるブートストラップ学習を採用する．これにより，計算コストを抑えつつ教師データの質を段階的に向上させ，初期の HCE に含まれる人間的な先入観をデータ駆動で補正した評価関数の構築を目指す．

また，盤上ゲーム変種におけるゲームバランスや駒価値の定量的分析手法として，McGrath ら [4] は AlphaZero を用いた調査を行っている．同研究では，キャスリング禁止やポーンの移動規則を変更した 9 種類のチェス変種に対し，自己対局から引き分け率や手番の有利性を定量的に比較した．さらに，自己対局から得られた局面の駒数差を特徴量ベクトルとし，活性化関数に tanh（双曲線正接関数）を用いた回帰モデルによって勝敗結果を予測することで，変種ごとの相対駒価値を導出した．

しかしながら，McGrath らの手法を将棋変種の分析へ適用するにあたっては，計算コストとモデル表現力の 2 点において課題がある．本研究と McGrath らの先行研究との差異は，以下の 2 点に整理される．

(1) **AI の学習方法**: 先行研究では膨大な計算資源を要する AlphaZero によるゼロからの深層強化学習を用いているのに対し，本研究では汎用変種エンジン Fairy-Stockfish の HCE を初期基盤とし，CPU 上で高速に動作する NNUE のブートストラップ学習を用いることで，一般的な計算機環境での分析を可能にした点．

(2) **駒価値推定方法**: 先行研究の回帰モデルから「局面の特徴量ベクトルと重みの内積を tanh 関数に通して最終勝敗との平均二乗誤差を最小化する」という基本枠組みを利用しつつ，本研究独自の拡張として，チェスには存在しない将棋特有の「成駒」と「持駒の再利用」を分離した 20 次元特徴量（盤上駒 7 種・盤上成駒 6 種・持駒 7 種）および手番バイアス項を導入した点．

これにより，計算資源を抑えながら，将棋変種特有の「持駒優位性」や「盤上成駒への純増価値」を含めたより精密な分析を実現する．

3. 66 将棋とは・ルール説明

3.1 66 将棋とは

66 将棋 [5] は, 将棋の変種ゲームであり, 6×6 の盤上で両手番自陣二段目に歩を並べた盤面から, 王将・金・銀・桂・香・飛車または角の計 6 枚を自陣一段目に交互に打ち (この流れを以降初期配置と呼ぶ), そこから指し始める将棋である．

3.2 66 将棋のルール

(1) **使用する駒**: 王将・歩・金・銀・桂・香・飛車または角の計 8 種類

(2) **初期配置および対局の始め方**: 初期配置は先手から交互に行う. 各陣自陣二段目に歩 6 枚を事前に配置した上で王将・金・銀・桂・香・飛車または角を交互に各一枚ずつ打つ. 後手番が 6 枚目の駒を打ち終わった盤面より対局が始まる．

(3) **成り条件**: 歩・銀・桂・香・飛車・角は自身の手番で敵陣一段目または二段目に駒を指すことで成れる．

(4) **初期配置時の条件**: 初期配置時の 6 手は, 自陣一段目以外への駒打ちができない. 必ず自陣一段目に駒を打つ. また, 自陣に飛車を配置した場合は以降自陣に角を配置することはできず, 自陣に角行を配置した場合は以降自陣に飛車を配置することはできない．

(5) **勝利条件**: 本将棋と同じく, 王将を詰ませれば勝利

(6) **駒の動き**: 本将棋と同じ駒の動き方

© 2026 Information Processing Society of Japan

3.3 本将棋との構造的相違点

(1) **初期配置の多様性**:2,073,600 通りの初期局面 [6] が存在し, 定跡の固定化が起こりにくい.
(2) **対局盤面の狭さ**: 盤面サイズが 6×6 と狭く, すぐに中終盤に入る.
(3) **大駒選択の非対称性**: 先手と後手の大駒は必ずしも同一とは限らず, 非対称性が発生することがある.

4. 提案手法

盤上ゲーム変種における手番の有利性および駒価値の定量的評価を達成するために，自己対局によって生成した棋譜の局面と勝敗結果から回帰分析により各駒の価値と手番バイアスを逆算するというアイデアで，ゲームバランスを調査する手法を提案する．そのためには，対象ゲームにおいて高い棋力を持つ強い AI が必要であるが，先行研究では AlphaZero ベースの手法が用いられていた．本研究では，対象のゲームはチェス・将棋の変種に限定されるものの，Fairy-Stockfish と NNUE の利用による比較的低コストな手法を採用する．

4.1 AI の作成

チェスや将棋の変種であれば，多変種対応エンジンである Fairy-Stockfish を用いることができる．本手法は，多変種チェス・将棋エンジン「Fairy-Stockfish」が内蔵する HCE を学習初期の基盤とし，探索付き自己対局データの生成と NNUE の再学習を繰り返すブートストラップ学習によって評価関数を強化する．本手法の利点は以下の通りである．

- **立ち上がりの高速性**: AlphaZero と異なり，初動から HCE の枝刈り・探索能力を利用できるため，少ない対局数で高水準な探索棋譜を生成可能である．
- **CPU 探索の超高速性**: NNUE は差分計算と整数量子化に最適化されているため，GPU を占有せず標準的なマルチコア CPU 上で毎秒数百万局面の評価・木探索を実行できる．

一方で，自己対局データの偏りや HCE 由来の構造的バイアス（局所解），および特定局面への過学習が生じるリスクがあるが，AlphaZero と比較して低コストで強い AI を作成できることが大きな利点である．これらのリスクへの対策として，後述するデータ収集・正規化・フィルタリングを導入する．

4.2 駒価値の推定

チェスや将棋と異なる変種では, 盤面サイズや初期配置などのルールが異なるため，従来の駒価値体系（歩 $= 100$, 銀 $= 500$，飛車 $= 1000$ 等）が成立しているかは自明でない．そこで，McGrath らのチェス変種分析手法を拡張し，将棋特有の「成り」および「持駒」を独立した次元として分離した非線形回帰モデルを構築する．

4.2.1 回帰モデルの定式化

ある局面における先手と後手の駒の枚数差を表す特徴量ベクトルを $\mathbf{d} \in \mathbb{R}^D$（$D = 20$），各駒の潜在的価値を表す重みベクトルを $\mathbf{w} \in \mathbb{R}^D$ とする．また，駒の枚数差に依存しない定数項として，手番バイアス項 $b \in \mathbb{R}$ を導入する．

局面における先後戦力差および定数項を合算した総合形勢スコアを $\mathbf{w}^T\mathbf{d} + b$（ただし T はベクトルの転置）と定義したとき，対局の最終勝敗 $z \in \{+1.0\ (\text{先手勝}), 0.0\ (\text{引分}), -1.0\ (\text{後手勝})\}$ に対する勝敗期待値 $\hat{z} \in [-1.0, +1.0]$ を，シグモイド系活性化関数である tanh を用いて次式のようにモデル化する．

$$\hat{z} = \tanh\left(\mathbf{w}^T\mathbf{d} + b\right) \tag{1}$$

式 (1) において，戦力差および定数項の合計が先手有利（$\mathbf{w}^T\mathbf{d} + b > 0$）であれば $\hat{z} \to +1$，後手有利であれば $\hat{z} \to -1$ へ漸近する．得られた勝敗期待値 $\hat{z}$ から，その局面における先手番の期待勝率 $P_{\text{win}} \in [0, 1]$ は $(1 + \hat{z})/2$ により算出できる．特に，駒の枚数差が皆無である対称局面（$\mathbf{d} = \mathbf{0}$）においては $\hat{z} = \tanh(b)$ となり，対称局面における先手番期待勝率 $P_{\text{first}} \in [0, 1]$ を次式により評価できる．

$$P_{\text{first}} = \frac{1 + \hat{z}}{2} = \frac{1 + \tanh(b)}{2} \tag{2}$$

なお，定数項 b は駒の損得がない状態（$\mathbf{d} = \mathbf{0}$）における先手・後手の勝敗傾向の偏りを表すが，純粋な先手番の着手先行効果だけでなく，本モデルの特徴量 $\mathbf{d}$（駒の枚数差）には含まれていない局面特徴（玉の安全度や攻勢・守勢の非対称性など）の平均的な影響も吸収している可能性がある点には注意が必要である．そのため，本研究ではこの b による推定値と，実際の対局全体における先手勝率の双方を比較して手番の有利性を考察する．

5. 66 将棋での実装・設定

5.1 棋譜データの収集手法および条件

健全な教師データを確保するため，以下の共通サンプリング条件を設ける．

(1) **初期配置の完全ランダムサンプリング**: 約 207 万通りの初期配置空間から均等に初期盤面を抽出する．これにより，特定の初期配置への集中を抑制し，生成される局面の多様性を高める．なお，狭小な盤面特性上，初手付近に人為的ランダムノイズを注入すると大駒のタダ捨てや即詰みといった低品質局面を量産するため，探索開始直後からの最善手を指すサンプリングを徹底する．
(2) **大駒 4 パターンの均等棋譜生成**: 先手・後手の大駒選択の組み合わせ（R–R: 飛-飛，R–B: 飛-角，B–R: 角-飛，B–B: 角-角）を正確に 1 : 1 : 1 : 1 の比率で生成

© 2026 Information Processing Society of Japan

し，特定大駒に偏った過学習を抑制する．

また，棋譜収集時の具体的な条件は以下の通りである．

- **探索深度**: すべて固定深度 14
- **対局数**: 基盤となる HCE 同士の自己対局は 20 万回，それ以降の NNUE モデル同士の自己対局は 10 万回ずつ行う．

5.2 学習手法およびハイパーパラメータ

評価関数モデルには，Fairy-Stockfish でサポートされている `HalfKAv2^` アーキテクチャを採用した．本構造は，自玉位置（36 マス）と他駒の盤上位置および持駒状態の組み合わせを疎な二値特徴量ベクトルとして入力し，特徴量変換層を経て隠れ層および出力層へと伝播させ，手番側視点の内生評価値を出力する．

学習には，探索評価値と最終的な勝敗結果を調和させる複合損失関数を用いる．モデルの出力評価値を v，教師データに記録された探索評価値を q，終局結果を $z \in \{0.0\ (\text{負}), 0.5\ (\text{分}), 1.0\ (\text{勝})\}$ とする．評価値をシグモイド関数 $\sigma(x) = 1/(1+\exp(-x/S))$ により勝率空間へ写像した上で，以下の損失関数 $\mathcal{L}$ を最小化する．

$$\mathcal{L} = \lambda\big(\sigma(v) - \sigma(q)\big)^2 + (1-\lambda)\big(\sigma(v) - z\big)^2 \qquad (3)$$

ここで λ は評価値と勝敗結果のブレンド比率，S は評価値スケーリング定数である．式 (3) の複合損失関数を採用した理由は，探索評価値 q のみを教師とすると初期 HCE や前世代モデルが持つ評価値の偏りをそのまま引き継いでしまい，逆に終局結果 z のみを教師とすると一局の勝敗という粗い情報しか得られず中盤の細かな形勢判断の学習が不安定になるためである．両者を組み合わせることで，局面の滑らかな評価と客観的な勝敗事実の双方を学習に反映できる．また，ブレンド比率について，本研究では初期 HCE に含まれる人間的な先入観を除去し実際の勝敗結果 z に基づく自己修正を促すため，$\lambda = 0.6$ (探索評価値 6 割，終局結果 4 割) に設定した．NNUE 学習時のハイパーパラメータは以下の通りである．

- **バッチサイズ**: 16,384
- **初期学習率**: 1.0×10^{-3}
- **損失ブレンド比率**: 式 (3) において $\lambda = 0.6$
- **最大エポック数**: 100

5.2.1 対戦・棋力評価条件

- **探索深度**: すべて固定深度 10
- **対局数およびペアマッチ方式**: 各対戦カードにおいて計 10,000 局を実施．初期配置における盤面バイアスを相殺するため，5,000 通りのランダム初期配置それぞれについて先手・後手を入れ替えて 2 局ずつ戦わせるペアマッチ方式を採用した．
- **勝率の算出方法**: 評価対象モデルの勝率を算出する際，勝利を 1.0 点，引分を 0.5 点，敗北を 0.0 点として集計し，全対局数（10,000 局）で除算した値を総合勝率とする．

5.3 局面サンプリングと特徴量表現

回帰分析で使用するデータセットは，以下のフィルタリングおよびデータ分割手順を経て構築する．

(1) **中盤静止局面フィルタリング**: 66 将棋では先後交互に 6 枚ずつ駒を配置する初期配置フェーズに 1〜12 手目を要し，13 手目から通常の指し手が開始される．また，6×6 の狭い盤面では交戦が早く，本将棋に比べて平均終局手数が短い．そこで，初期配置直後の序盤（13〜19 手目）および勝敗が確定した終局直前の局面を排除し，純粋な駒の損得や形勢判断が勝敗に直結する実質的な中盤戦の範囲として 20〜60 手目を設定し，1 対局あたり 2 局面を抽出する．

(2) **静止局面フィルタ**: 王手局面および直前の駒取り直後局面を除外する．これにより，探索木深層の静止探索に相当する戦術的安定局面のみを分析対象とする．

(3) **対局単位での学習・評価データの分割**: 同一の対局から抽出された複数の局面は互いに相関を持ち同じ終局結果 z を共有するため，局面単位でランダムに分割すると汎化性能が落ちる可能性がある．そこで，回帰モデルの汎化性能を正しく評価するため，各パターン 10,000 局の棋譜を対局単位で学習用 80%（各 8,000 局）と評価用 20%（各 2,000 局）に分割し，学習用データで推定したモデルを用いて評価用データに対する予測誤差および勝敗予測精度を検証する．

抽出された局面から，先手視点での駒数差を表 1 に示す計 20 次元の特徴量ベクトル $\mathbf{d}$（$D = 20$）として定義する．

表 1 回帰分析に用いる特徴量ベクトル $\mathbf{d}$ の内訳（計 20 次元）

カテゴリ	次元数	対象駒種
盤上駒	7	歩 (P), 香 (L), 桂 (N), 銀 (S), 金 (G), 角 (B), 飛 (R)
盤上成駒	6	と金 (+P), 成香 (+L), 成桂 (+N), 成銀 (+S), 馬 (+B), 竜 (+R)
持駒	7	歩, 香, 桂, 銀, 金, 角, 飛

5.3.1 パラメータ最適化

サンプリングされた N 個の静止局面データセット $\mathcal{D} = \{(\mathbf{d}_i, z_i)\}_{i=1}^{N}$ に対し，式 (1) による各局面の予測値 $\hat{z}_i = \tanh\left(\mathbf{w}^T\mathbf{d}_i + b\right)$ と実際の勝敗 z_i との平均二乗誤差（MSE）を最小化する損失関数 $\mathcal{L}(\mathbf{w}, b)$ を定義する．

$$\mathcal{L}(\mathbf{w}, b) = \frac{1}{N}\sum_{i=1}^{N}\left(z_i - \tanh\left(\mathbf{w}^T\mathbf{d}_i + b\right)\right)^2 \qquad (4)$$

最適化には，BFGS（Broyden-Fletcher-Goldfarb-Shanno）

© 2026 Information Processing Society of Japan

法を適用する．本回帰モデルのパラメータ数は最大 21 個（重み 20 次元＋バイアス 1 次元）と少数であり，確率的勾配降下法等のように学習率の調整を要さず，高速かつ安定して最適解へ収束させることができる．

$$\frac{\partial \mathcal{L}}{\partial \mathbf{w}} = -\frac{2}{N}\sum_{i=1}^{N}(z_i - \hat{z}_i)\left(1-\hat{z}_i^2\right)\mathbf{d}_i \qquad (5)$$

$$\frac{\partial \mathcal{L}}{\partial b} = -\frac{2}{N}\sum_{i=1}^{N}(z_i - \hat{z}_i)\left(1-\hat{z}_i^2\right) \qquad (6)$$

最適化におけるパラメータの初期値は，駒重みベクトルを $\mathbf{w}_0 = [0.1, \ldots, 0.1]^T$，手番バイアスを $b_0 = 0.0$ と設定した．また，最大反復回数を 1,000 回，収束判定基準を勾配の無限大ノルム $\|\nabla\mathcal{L}\|_\infty < 10^{-5}$ と設定した．

5.4 正規化および評価指標の導出

得られた最適重み $\mathbf{w}^*$ に対し，直感的な解釈を可能にするため盤上の生歩（$w^*_{\text{Board_P}}$）の値を 1.00 とする正規化を施す（$\mathbf{w}_{\text{norm}} = \mathbf{w}^*/w^*_{\text{Board_P}}$）．この正規化重みから，以下の指標を導出する．

- **成り上昇値** $\Delta_{\text{prom}}(p)$: 盤上駒が成ることによる純増戦力 $(w_{\text{norm}}(+p) - w_{\text{norm}}(p))$.
- **持駒優位性** $\Delta_{\text{drop}}(p)$: 盤上駒に対する持駒の相対的付加価値 $(w_{\text{norm}}(\text{Hand_}p) - w_{\text{norm}}(\text{Board_}p))$.

6. 実験と結果

6.1 実験環境

本研究の有効性を検証するため，以下のハードウェア環境および探索エンジンに基づいて実験を実施した．

- **計算機環境**: 今回の実験で使用した計算機環境を表 2 に載せる．
- **探索エンジン**: Fairy-Stockfish（66 将棋ルール定義ファイルおよび HalfKAv2N̂NUE 拡張を適用）.

表 2 実験に使用した計算機環境

項目	デスクトップ PC	ラップトップ PC
CPU	Ryzen 9 7950X	Core i7-14700F
コア数	16 コア	20 コア (8P+12E)
メモリ	32 GB	32 GB
GPU	—	GeForce RTX 4070
OS	Windows 11 Home	Windows 11

6.2 各モデルの強度検証と計算コストの評価

各モデルの学習と棋譜収集に要した時間を表 3 に，構築した各世代の NNUE モデルおよび HCE 間の対戦勝率を表 4 に示す．

表 3 より，探索深度 14 での自己対局による棋譜収集は約 5〜7 日（116〜170 時間），NNUE のネットワーク学習自体は 1 世代あたり 2.1〜2.6 時間で完了している．さらに，駒価値分析用の棋譜生成は約 50 時間，BFGS 法による回帰分析の最適化計算は CPU 上で 5 分未満で完了した．

表 3 各段階のデータ規模および所要時間

工程・モデル名	自己対局数	棋譜収集時間	学習・分析時間
NNUE_ver1	20 万局	約 170 時間	2.6 時間
NNUE_ver2	10 万局	約 116 時間	2.1 時間
NNUE_ver3	10 万局	約 130 時間	2.4 時間
回帰分析	4 万局	約 50 時間	5 分未満

表 4 モデル間の対戦勝率（各行からみた各列に対する総合勝率および先手番勝率）

モデル名	HCE	NNUE ver1	NNUE ver2	NNUE ver3
NNUE_ver1	56.49% (59.55%)	—	45.90% (48.80%)	54.00% (59.32%)
NNUE_ver2	57.80% (60.24%)	54.10% (59.40%)	—	55.60% (66.80%)
NNUE_ver3	48.29% (51.89%)	46.00% (49.48%)	44.40% (47.60%)	—

※ 上段は総合勝率，下段の括弧内は該当モデルが先手番を持った際の勝率を示す．

続いて表 4 より，HCE の自己対局棋譜から学習した NNUE_ver1 は，基準となる HCE に対して勝率 56.49%（先手勝率 59.55%）と勝ち越しを達成した．さらに，NNUE_ver1 の自己対局棋譜から学習した NNUE_ver2 は，NNUE_ver1 に対して勝率 54.10%，HCE に対して勝率 57.80%（先手勝率 60.24%）を記録し，ブートストラップ学習によって評価関数の精度が段階的に向上することが実証された．また，各対戦カードの下段に示した先手勝率に着目すると，同水準のモデル同士の対局においても先手番勝率がおおむね 50%〜60%前後を記録しており，先手番の有利性が一貫して現れていることを確認できる．

一方で，NNUE_ver2 の自己対局棋譜のみを用いて学習した NNUE_ver3 においては，対 HCE 勝率が 48.29%，対 NNUE_ver2 勝率が 44.40%へと大きく低下する現象が見られた．この性能低下の要因として，単一世代の自己対局データに依存したことで学習対象の局面分布が偏り，特定の戦型や指し手に過学習した可能性が考えられる．

この自己対局の偏りによる性能劣化を抑止するため，直近世代の棋譜だけでなく過去世代（HCE や NNUE_ver1）の棋譜データを混合して学習させたモデル（NNUE_ver2+，NNUE_ver3+）を構築し，HCE との対戦検証を各 10,000 局行った結果を表 5 に示す．

© 2026 Information Processing Society of Japan

表 5 学習モデル別の対 HCE 性能比較

モデル名	学習データ構成	総合勝率	先手勝率
NNUE_ver2+	HCE + ver1	54.50%	55.25%
NNUE_ver3+	HCE + ver1 + ver2	53.26%	56.85%

※先手勝率は，各モデルが HCE に対して先手番を持った際の勝率を示す．

表 5 より，過去世代のデータを混合した NNUE_ver2+ は勝率 54.50%，NNUE_ver3+は勝率 53.26%となり，直前世代のデータのみで学習したものの, HCE モデルに対して負け越した NNUE_ver3（48.29%）とは対照的に，複数世代の棋譜を蓄積・混合することで HCE に対する勝ち越し水準を安定して維持できることが確認された．もっとも，最良棋力を記録した単一世代学習の NNUE_ver2（57.80%）と比較すると勝率の上昇幅はやや緩やかに留まっている．この結果から，ブートストラップ学習においては，特定戦型への過学習を防ぎつつ棋力を伸ばすための学習データの選別が重要な要素となる可能性が示唆された．

6.3 駒価値・手番の分析

最良の棋力となった NNUE_ver2 モデルを用いて, 駒価値の分析を行った結果を表 6〜表 10 に示す．

6.3.1 手番バイアスおよび回帰モデルの妥当性検証

まず，5.3 節で述べた回帰モデルの汎化性能について検証する．表 6 より，全パターンにおいて学習用データの MSE（0.6848 ∼ 0.7381）と評価用データのテスト MSE（0.6799 ∼ 0.7410）の差は小さく，本実験の範囲では顕著な過学習は認められなかった．なお，本回帰モデルの目的変数 z は勝敗を $[-1, 1]$ の値域で定義しているため，予測が完全に外れた場合の最大二乗誤差は $(1-(-1))^2 = 4$ となる（一般的な $[0, 1]$ 区間の勝率予測スケールに換算すると約 0.175 に相当する）．また，この回帰モデルの予測値 $\hat{z}$ の符号（$\hat{z} > 0$ なら先手有利，$\hat{z} < 0$ なら後手有利）と実際の最終勝敗が一致する割合（一致率）を検証した結果，評価用データに対して 68.50% ∼ 73.45% となり，盤上の位置情報を含まない 20 次元の駒数差のみを用いたモデルでも最終勝敗に関する一定の予測能力を持つことが確認された．これらの結果から，推定された駒価値は勝敗傾向を説明する指標として有用であると考えられる．

以上の検証を踏まえ，統計的信頼性を高めるため，各パターンの全抽出局面を用いて最適化したパラメータにより考察を行う．表 6 に，各大駒選択パターン別に推定した手番バイアス b^*，式 (2) による対称中盤局面（$\mathbf{d} = \mathbf{0}$）での先手期待勝率，および実際の対局全体における実測先手勝率を示す．

手番の有利性について，回帰モデルの推定値と実測勝率を比較する．表 6 より，対局全体の実測先手勝率は 58.71% ∼ 61.66% となった．この結果より, 本実験の条件下においては, 先手番が初手の着手先行利を活かして主導権を握りやすく，先手勝率が高くなる傾向が確認された．また, 回帰モデルの手番バイアス b^* も, R–B を除く 3 パターン（R–R, B–R, B–B）において正の値（+0.1156 ∼ +0.1694）を示し，駒の損得がない対称な中盤局面（$\mathbf{d} = \mathbf{0}$）における先手期待勝率は 55.76% ∼ 58.39% と，実測勝率と同様に先手有利の傾向を示した．

一方で，R–B の非対称戦においては，実測の先手勝率は 58.71% と先手有利であるにもかかわらず，手番バイアス b^* は −0.0217（先手期待勝率 48.91%）とわずかに負の値を示している．この違いが生じた要因として，実測勝率は「先手飛車が先行利を活かして序中盤に駒得や成り込みを成功させた対局」をすべて含んでいるのに対し，手番バイアスは「中盤まで進んだ時点で，先手が一切の駒得や成駒の優位を作れず均衡している状態（$\mathbf{d} = \mathbf{0}$）」を前提としている点が考えられる．さらに，4.2.1 節で述べた通り，定数項 b^* には駒数差以外の局面特徴（先手飛車と後手角行の配置や陣形の非対称性など）の影響も吸収されている可能性があり，これらが複合して R–B の対称中盤局面における評価値の差として表れたと推察される．

6.3.2 先手飛車 vs 後手飛車

表 7 より，先後双方が飛車を選択する相飛車戦では，すべての駒種において持駒差が負（−0.79 ∼ −0.01）となり，持駒として保持するよりも盤上に配置されている状態の方が一貫して高く評価された．また，竜が 7.08（成り上昇値 +2.47）と高い価値を示すとともに，成桂（4.61）や成銀（4.54）が盤上の飛車（4.61）と同等の評価値となった．

この結果に対する仮説として，角行による斜めの遠隔牽制が存在しない相飛車戦では，手駒を温存して隙をうかがうよりも，獲得した駒を即座に盤上へ配置し前線を押し上げ，盤上での直接的な突破力や防衛力を高める総力戦が勝敗に直結しやすいことが考えられる．また，飛車先突破に連動して敵陣深くに成り込んだ小駒が，大駒に匹敵する制圧力を発揮していると推察される．

6.3.3 先手飛車 vs 後手角行

表 8 より，先手が飛車，後手が角行を選択する非対称戦では，竜（8.43）および馬（8.07）の盤上成駒価値が全 4 パターン中で最も高い水準を記録した．また，持駒優位性（持駒差が正）を持つ駒は飛車（+0.65），角行（+0.84），金（+0.22）に限定され，歩・香・桂・銀の持駒差は負となった．

この結果に対する仮説として，縦の飛車と斜めの角行という異なる射線の大駒が対峙する局面では，互いの死角を突いて大駒を敵陣へ成り込むこと，あるいは相手の大駒を捕獲して持駒として打ち込むことが決定的な戦力差を生むためと考えられる．また，先手飛車側が直線的な突破を図

© 2026 Information Processing Society of Japan

表 6 大駒選択パターン別の手番バイアス・実測先手勝率および未知評価データに対する回帰モデルの予測精度

大駒選択パターン	手番バイアス b^*	先手期待勝率	実測先手勝率	学習用 MSE	テスト MSE	一致率
R–R	+0.1156	55.76%	58.74%	0.7381	0.7410	68.50%
R–B	−0.0217	48.91%	58.71%	0.7102	0.7220	69.20%
B–R	+0.1694	58.39%	59.75%	0.7180	0.7082	70.45%
B–B	+0.1321	56.57%	61.66%	0.6848	0.6799	73.45%

る際に生じる自陣の隙を後手角行の斜め射線が狙う展開になりやすいため，自陣の隙を埋める盤上の金・銀の守備価値が高まるとともに，決定打となる大駒と金の持駒価値が突出していると推察される．

6.3.4 先手角行 vs 後手飛車

表 9 より，先手が角行，後手が飛車を選択する場合，盤上の飛車（4.24）が角行（3.85）をやや上回る価値を示した．さらに持駒差に着目すると，飛車（+0.72），角行（+0.53），金（+0.50）に加えて，銀（+0.13）も正の持駒優位性を持つ一方，歩・香・桂は負となった．

この結果に対する仮説として，先手番の着手先行利が角行の牽制力を高めるものの，基礎的な突破力においては依然として飛車が優位に立つと考えられる．また，銀を含む広範な駒に持駒優位性が生じていることから，先手角行側は相手の飛車の機動力を抑え込むために，獲得した駒を状況に応じて即座に急所へ再配置するカウンター的な流動的戦術が強く求められる構造になっていると考えられる．

図 1 にその特徴的な局面の例を示す．先手が敵陣（3 二）に作った馬の射線によって後手飛車（1 三）の機動力を封じ込め，手駒の金が敵玉（6 一）への寄せの切り札となっている．

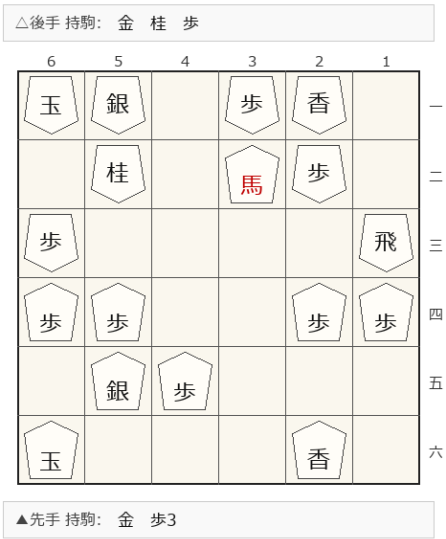


図 1 先手角行 vs 後手飛車における馬による飛車封殺（49 手目, 次先手番）

6.3.5 先手角行 vs 後手角行

表 10 より，双方が角行を選択する相角行戦では，成香（2.81），と金（2.50），成銀（3.08）といった小駒の成駒が，盤上の金（3.10）をやや下回る評価値帯へ収束した（成桂のみ 3.60）．また，他パターンと比較して各駒の数値が全体的に低く圧縮されており，正規化の基準である盤上の歩（1.00）の相対的価値が 4 パターン中で最も高くなっている．さらに，持駒差に着目すると，金（+0.20）および角（+0.08）において正の持駒優位性が観測された（銀の持駒差は負に転じている）．

この結果に対する仮説として，縦を貫く飛車が存在しない相角行戦では一気の直線突破が起こりにくく，歩の突き合いや拠点作りといった地道な前線構築の比重が高まるため，歩の相対価値が底上げされていると考えられる．また，斜め射線が主体の相角行戦では角行や馬だけでは隣接マスの死角を埋めきれないため，終盤の寄せや受けにおいて周囲のマスを確実に制圧できる手駒の金が，角の死角を補完する要素として高い決定力を持つためであると推察される．

図 2 にその特徴的な局面の例を示す．飛車の直線突破がない相角行戦特有の，歩の突き合いが多発している．3 六角の斜め射線に加え，手駒に金と桂を保持しており，角の死角となる隣接マスへ打ち込んで敵玉（3 一玉）を包囲する寄せの態勢が完成していると言える．

表 7 先手飛車 vs 後手飛車の駒価値推定結果（角行除外）

駒種	盤上駒	盤上成駒	成り上昇	持駒	持駒差
歩 (P)	1.00	3.40	+2.40	0.59	−0.41
香 (L)	1.73	2.94	+1.21	1.30	−0.43
桂 (N)	1.89	4.61	+2.72	1.10	−0.79
銀 (S)	2.87	4.54	+1.67	2.65	−0.22
金 (G)	3.36	—	—	3.35	−0.01
角 (B)	—	—	—	—	—
飛 (R)	4.61	7.08	+2.47	4.52	−0.09

7. まとめと今後の展望

本稿では，盤上ゲーム変種における手番の有利性および駒価値を低計算コストで調査する手法として，Fairy-Stockfish

© 2026 Information Processing Society of Japan

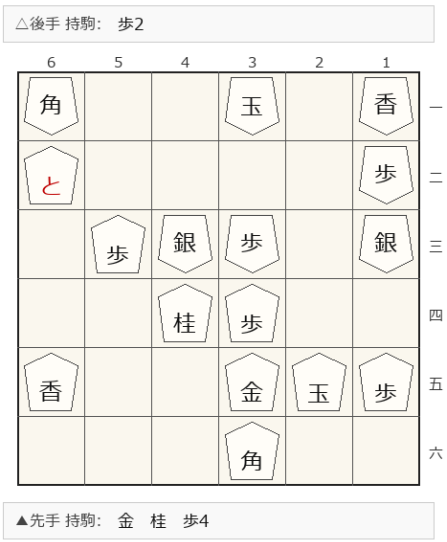


図 2 相角行戦における敵陣突破と寄せの局面（53 手目, 次先手番）

表 8 先手飛車 vs 後手角行の駒価値推定結果

駒種	盤上駒	盤上成駒	成り上昇	持駒	持駒差
歩 (P)	1.00	3.75	+2.75	0.54	−0.46
香 (L)	2.17	4.12	+1.95	1.80	−0.37
桂 (N)	2.30	5.53	+3.23	1.53	−0.77
銀 (S)	3.54	5.01	+1.47	3.27	−0.27
金 (G)	4.06	—	—	4.28	+0.22
角 (B)	4.18	8.07	+3.89	5.02	+0.84
飛 (R)	5.14	8.43	+3.29	5.79	+0.65

表 9 先手角行 vs 後手飛車の駒価値推定結果

駒種	盤上駒	盤上成駒	成り上昇	持駒	持駒差
歩 (P)	1.00	3.27	+2.27	0.53	−0.47
香 (L)	1.86	2.88	+1.02	1.51	−0.35
桂 (N)	1.86	4.36	+2.50	1.20	−0.66
銀 (S)	2.84	4.30	+1.46	2.97	+0.13
金 (G)	3.40	—	—	3.90	+0.50
角 (B)	3.85	6.16	+2.31	4.38	+0.53
飛 (R)	4.24	7.24	+3.00	4.96	+0.72

表 10 先手角行 vs 後手角行の駒価値推定結果（飛車除外）

駒種	盤上駒	盤上成駒	成り上昇	持駒	持駒差
歩 (P)	1.00	2.50	+1.50	0.39	−0.61
香 (L)	1.52	2.81	+1.29	1.09	−0.43
桂 (N)	1.90	3.60	+1.70	1.03	−0.87
銀 (S)	2.64	3.08	+0.44	2.43	−0.21
金 (G)	3.10	—	—	3.30	+0.20
角 (B)	3.19	5.76	+2.57	3.27	+0.08
飛 (R)	—	—	—	—	—

と NNUE を用いたブートストラップ学習，および成駒・持駒を分離した 20 次元非線形回帰モデルを提案し，66 将棋を対象に分析を行った．実験の結果，構築した NNUE モデルは基準となる HCE に対して勝ち越しを達成し，少ない計算資源で高品質な分析用棋譜を生成できることを示した．また，自己対局データに基づく回帰分析の結果，中盤の対称局面においては一部の大駒選択パターンを除き先手番が有利となる傾向や，本将棋と同様に角行よりも飛車の価値が高く評価されること，さらに大駒の組み合わせによって小駒の成り価値や金の持駒優位性が大きく変動することを明らかにした．残された課題として，本研究では対局局面の多様性を確保するため初期配置フェーズ（1〜12 手目）をランダムかつ大駒均等に生成しており，プレイヤによる初期配置や大駒選択が全体の勝敗に与える影響までは考慮できていない点が挙げられる．初期配置フェーズに関しては，田中ら [6] が配置完了局面の評価値を事前計算するデータベース探索手法を提案しているが，そこでは飛車と角行を同価値とする単純な駒得評価関数が用いられており，学習ベースの評価関数の導入が課題とされている．今後は，こうした初期配置探索の枠組みに本研究で構築した NNUE 評価関数や推定駒価値を統合し，初期配置戦略までを含めた包括的なゲームバランスの解明に取り組むとともに，他の盤上ゲーム変種への本手法の適用を進めていく予定である．

参考文献

[1] Fabian Fichter: Fairy-Stockfish, `https://github.com/fairy-stockfish/Fairy-Stockfish`.

[2] 那須 悠: 高速に差分計算可能なニューラルネットワーク型将棋評価関数, 第 28 回世界コンピュータ将棋選手権 アピール文書 (2018).

[3] 嶽 俊太郎, 金子 知適: 強化学習を用いた評価関数の作成手法の信頼性の分析, ゲームプログラミングワークショップ 2017 論文集 (2017).

[4] Thomas McGrath, Andrei Kapishnikov, Nenad Tomašev, Adam Pearce, Martin Wattenberg, Demis Hassabis, Been Kim, Ulrich Paquet and Vladimir Kramnik. : Acquisition of Chess Knowledge in AlphaZero, Proceedings of the National Academy of Sciences(2022).

[5] 天童商工会議所: 66 将棋 - ROKUROKU SHOGI -, `http://www.tendocci.com/66shogi/index.html`.

[6] Taisuke Tanaka, Yoshimasa Yamaguchi and Takeshi Ito: An Initial Position Generation Problem in the Placement Phase of Rokuroku Shogi and a Database-based Search Method, IPSJ SIG Technical Report, Vol.2026-GI-58, No.3, pp.1–6 (2026).

© 2026 Information Processing Society of Japan