ResTNet による将棋 AI の解釈: Transformer の Attention 機構による着目領域の可視化と妥当性の検証

横山 凜[1,a)]　魏 廷翰[1,b)]

概要：ResTNet は Residual（R）ブロックと Transformer（T）ブロックを組み合わせた AlphaZero のためのネットワークであり，囲碁と Hex で Attention Map による解釈が示されている．本研究は ResTNet を動物将棋と 9 × 9 の将棋に適用し，Attention Map を用いてモデルが局面のどこに着目しているかを可視化し，その着目が将棋として妥当かを，Integrated Gradients（IG）も用いて確かめた．完全解析された動物将棋では，T ブロックだけの構成の 1 つのヘッドは，無作為に選んだ局面で，手番側のライオンからの重みが最大となるマスが，相手のライオンを取れる局面の 90% で相手のライオン，最善手がライオンの手である負けでない局面の 88% でその行き先であった．本研究で学習した R を含む構成では，測った範囲で重みはほぼ均等であった．9 × 9 の将棋では，プロの対局の局面で Attention Map と持ち駒を可視化して実際に指された手と照らし合わせた．示した局面では重みはほぼ均等で，正規化した図で濃いマスに指された手の行き先は入っておらず，手の確率を押し上げた駒（持ち駒の桂など）は IG で読み取れた．

キーワード：動物将棋，ResTNet，Attention Map，Integrated Gradients，完全解析，説明可能性

Interpreting a Shogi AI Built on ResTNet: Visualizing and Validating Attention over the Board

Rin Yokoyama[1,a)]　Ting-Han Wei[1,b)]

Abstract: ResTNet combines residual (R) and Transformer (T) blocks in a network for AlphaZero, and its attention maps have been used to interpret play in Go and Hex. We apply ResTNet to Dobutsu Shogi and 9 × 9 shogi, visualize where the model attends in a position with its attention maps, and examine whether this attention is reasonable in terms of the game, also using Integrated Gradients (IG). In the solved game of Dobutsu Shogi, one head of the all-T network, from the side to move's lion, puts its largest weight on the opponent lion in 90% of random positions where it can be captured, and on the destination of the best move in 88% of the positions not lost where the best move is a lion move. In our configurations containing R blocks, the weights we measured are nearly uniform. In 9 × 9 shogi we visualize the attention maps and the pieces in hand in positions of a professional game and compare them with the moves played. In the three positions examined, the weights are nearly uniform, the destinations of the moves played are not among the dark squares of the normalized maps, and IG finds the pieces that raise the probability of the move (such as a knight in hand).

Keywords: Dobutsu Shogi, ResTNet, attention map, Integrated Gradients, solved game, explainability

1. はじめに

AlphaZero [1] は，自己対戦による強化学習のみで囲碁・チェス・将棋において超人的な棋力に達したが，その判断の理由を人間が読み取ることは難しい．判断の根拠を示す

[1] 高知工科大学情報学群
School of Informatics, Kochi University of Technology
[a)] 305151a@gs.kochi-tech.ac.jp
[b)] tinghan.wei@kochi-tech.ac.jp

© 2026 Information Processing Society of Japan

説明可能 AI（XAI）は，医療診断や自動運転のように説明が求められる分野で必要とされており，定跡や手筋と照らし合わせられ，同じ局面を何度でも再現できるゲームは，その手法を確かめる場に適している．

ResTNet [2] の Attention Map は，囲碁の死活やシチョウ，Hex の接続といった概念を捉えると示されている（2.2 節）．ただし，その解釈は個々の局面の図によるもので，重みがそれらの概念に向くかを多くの局面で数えてはいない．また，図ごとに [0, 1] に正規化した Attention Map は，重みがほぼ均等でも濃淡を示す（4.3 節）．そのため，図の濃淡からモデルが何に着目しているかを読むには，正解と照らし合わせる必要がある．ResTNet の論文で解釈が示されたのは囲碁と Hex だけであり，我々の知る限り，ResTNet を将棋系のゲームに適用した例はない．将棋系のゲームは持ち駒・成り・駒ごとに異なる動きを持ち，9×9 の将棋では行動空間も 11,259 と大きいため，特徴量や選択肢の多い実世界のモデルへの応用の可能性を示す検証の対象に適している．また，囲碁や Hex にない，盤に写らない持ち駒をどう可視化するかという問題がある．

本研究の目的は，Attention Map を用いて，モデルが局面のどこに着目しているか（何を考えているか）を知ることである．ここでは，局面の正解に関わるマス（取れる相手のライオンや最善手の行き先など）に，選んだ例だけでなく無作為な局面でも重みが向くことを，妥当な着目とみなす．完全解析された動物将棋 [7] では，全局面の最善手と勝敗を正解として参照できる．正解のない 9×9 の将棋では，実際に指された手を仮の正解として，将棋としてそれらしいかを見るにとどめる．本研究では次を行った．

- 動物将棋と 9×9 の将棋で ResTNet を自己対戦で学習し，Attention Map でモデルが着目するマスを可視化した．
- 動物将棋では，ヘッドを選ぶ局面とは別の無作為な局面で，重みが向くマスを正解と照らし合わせた．
- Attention Map が重みを向けたマスが出力にも効いているかを，例の局面で Integrated Gradients（IG） [5] で確かめた．
- 持ち駒について，1 枚を相手に渡したときの Attention Map の変化と，持ち駒の IG を可視化した．

2. 背景と関連研究

2.1 AlphaZero と Gumbel AlphaZero

AlphaZero [1] は，深層ニューラルネットワークとモンテカルロ木探索（MCTS）を組み合わせ，人間の知識を用いずに自己対戦だけで学習する手法である．ネットワークは残差ブロックを重ねた本体と，policy ヘッド，value ヘッドからなる．policy ヘッドは各手の確率の分布を出し，MCTS の根での各手の訪問回数の分布に近づくように学習する．value ヘッドは局面の勝ちやすさを出し，対局の結果に近づくように学習する．MCTS は，policy を各手の事前確率として，value を局面の評価として用いる．学習では，MCTS による自己対戦で棋譜を作ることと，その棋譜でネットワークを最適化することを繰り返す．Gumbel AlphaZero [3] は，少ないシミュレーション数でも policy の改善が保証されるように AlphaZero を改良した手法である．Gumbel AlphaZero では，policy ヘッドは探索で改善した policy に近づくように学習する．

2.2 ResTNet

ResTNet [2] は Residual ブロック（R ブロック）と Transformer ブロック（T ブロック）を並べたネットワークである．R ブロックは AlphaZero と同じく，2 層の畳み込みからなる残差ブロックである．T ブロックは，盤の各マスを 1 トークンとし，相対位置の表現を加えた Transformer のブロックである．同論文は，9×9 囲碁で R と T の並べ方が異なる 6 ブロックの 11 構成を比べ，19×19 囲碁と 19×19 Hex で 10 ブロックの 10R と R3(RRT) を比べた．

T ブロックでは，各マスの特徴から query・key・value の 3 つのベクトルを作る．あるマス（以下，起点）の query と各マスの key の内積に相対位置のバイアスを足して softmax をとったものが attention の重みで，0〜1 の値をとり，起点ごとに全マスの合計が 1 になる．起点の新しい特徴は，この重みで各マスの value ベクトルを足し合わせたもの（重みの合計が 1 なので加重平均）であり，これを入力に足して（残差）次の処理に渡す．同論文は，起点が盤の各マスに向ける attention の重みを盤の形に並べた図を Attention Map とし，重みを「ほかのマスの相対的な重要さ」としている．19×19 囲碁の R3(RRT) では，生き残る石（死活），どちらの地にもなっていない中央，シチョウで逃げる石とつながる石に，19×19 Hex では石の接続に，重みが集まる図が示された．

2.3 IG を用いた研究

Integrated Gradients（IG） [5] は，ネットワークの出力を入力の各要素に割り当てる手法として提案され，画像・文章・化学のモデルに適用された．Czech ら [6] は，AlphaZero のチェスのネットワークで，入力の平面ごとの value への寄与を IG で測った．

2.4 動物将棋

動物将棋は 3×4 の盤で，ライオン・きりん・ぞう・ひよこを用いる将棋である [7]．取った駒は持ち駒として打て，ひよこは相手の陣地に入るとにわとりに成る．相手のライオンを取るか，自分のライオンが相手の陣地に入り直後に取られなければ（トライ）勝ちである．完全解析されており [7]，初期局面は 78 手で後手勝ちで，すべての局面

© 2026 Information Processing Society of Japan

表 1 学習の設定

	動物将棋	9 × 9 の将棋
シミュレーション数	64	64
Gumbel のサンプル数	16	16
1 iteration の自己対戦	2,000 局	2,000 局
1 iteration の最適化	200 ステップ	200 ステップ
iteration 数	200	500
バッチサイズ	1,024	1,024
最適化手法	SGD	SGD
学習率（初め）	0.02	0.02
学習率の半減	無効	70,000，90,000
リプレイバッファ	20 iteration	15 iteration
投了	無効	閾値 −0.9

の勝敗と最善手がわかる．

2.5 9 × 9 の将棋

9 × 9 の盤で行う通常の将棋で，行動空間は AlphaZero と同じ 11,259（9 × 9 × 139）である [1]．512 手に達した対局は引き分けとし，入玉宣言（27 点法）を有効とした．▲は先手，△は後手の手を表す．

3. 手法

3.1 ネットワークと学習

ResTNet の実装 [2] を用いた．どちらのゲームでも，入力を 3 × 3 の畳み込みで 256 枚の平面に変換して，以降の R ブロック（3 × 3 の畳み込み）と T ブロック（4 ヘッド）で計算する．policy ヘッドは AlphaZero と同じ畳み込み型，value ヘッドは Transformer 型（全マスの特徴の平均から value を出す）とした．2 つのゲームで異なるのは，盤の大きさ（3 × 4 と 9 × 9），入力の枚数（3.2 節），policy が出す手の数（132 と 11,259），ブロックの数と並べ方である．動物将棋は ResTNet の論文の 9 × 9 囲碁と同じ 6 ブロックの 11 構成（6R, 6T, 5R1T, 4R2T, 3R3T, 2R4T, 1R5T, TRRRRT, RTRRRT, RRTRRT, RRRTRT）を，9 × 9 の将棋は同論文が 19 × 19 囲碁で用いた 10 ブロックの R3(RRT)（RRRTRRTRRT）を学習した．MiniZero [4] 上の Gumbel AlphaZero [3] で学習した（表 1）．自己対戦で指す手は，根の子のうち，最も訪問回数の多い子との value の差が 0.1 以内のものから，訪問回数に比例して抽選した．9 × 9 の将棋のシミュレーション数，Gumbel のサンプル数，バッチサイズ，学習率とその変え方，自己対戦の局数（100 万局），最適化のステップ数（100,000）は，ResTNet の論文の 9 × 9 囲碁と同じである．

3.2 入力

入力は AlphaZero [1] と同じく，盤と同じ大きさの平面を重ねたものである．盤上の駒は，手番側と相手のそれぞれについて駒の種類ごとに 1 枚の平面で表し，その駒があるマスを 1 とする．持ち駒は駒の種類ごとに 1 枚の平面で表し，盤の全マスにその枚数を入れる．9 × 9 の将棋は，同じ局面が現れた回数の平面（3 枚）を加えた直近 8 局面の平面を重ね，手番と手数の平面を加える（362 枚）．動物将棋は現在の局面だけを入力し，手番（2 枚）と同じ局面が現れた回数（2 枚）の平面を足す（20 枚）．

3.3 Attention Map

T ブロックの attention の重み（softmax の後）を用いる．起点は，動物将棋ではモデルが選んだ手（図 4(d) を除く），9 × 9 の将棋では実際に指された手で動かす駒のマスとし，駒打ちでは打つ先のマスとした．無作為な局面での集計（4.2 節）では，手番側のライオンを起点とした．Attention Map は T ブロックにしかないため，ResTNet の論文と同じく T ブロックだけを入力側から数えて「第 n T ブロック」，各 T ブロックのヘッドを「第 h ヘッド」と呼ぶ（6T は第 n ブロックが第 n T ブロック，RRTRRT の第 3・6 ブロックは第 1・2 T ブロック，R3(RRT) の第 4・7・10 ブロックは第 1・2・3 T ブロック）．

重みの偏りは，重みにマスの数 N を掛けた値で表す（動物将棋は $N = 12$，9 × 9 の将棋は $N = 81$）．この値は，全マスに同じ重みを向けたとき 1，1 マスだけに向けたときそのマスで N になる．動物将棋の図は，この値を全部の図で同じ目盛りで描く．9 × 9 の将棋の重みはほぼ均等であったため（4.3 節），ResTNet と同じく図ごとに [0, 1] に正規化して（最小の重みを 0，最大の重みを 1 とする）描き，図の上に重み × 81 の最大を書く．この表示は均等に近い重みにも濃淡を作るので，濃淡は最大の値と合わせて読む必要がある．重みがほぼ均等であることは，T ブロックが何もしていないことを意味しない．2.2 節のとおり，起点の新しい特徴は各マスの value ベクトルの重み付きの平均であり，重みが均等なら盤全体の平均になる．図の青い矢印は最善手（9 × 9 の将棋は実際に指された手），黒い点線の矢印はモデルが選んだ手である．モデルが選ぶ手は探索を用いず，policy が最大の合法手とする．

3.4 Integrated Gradients

Attention Map は内部の重みであり，出力（手の確率や value）がどの入力で決まったかは示さない．そこで，重みを向けたマスが出力にも効いているかを IG [5] で確かめる．IG は，全部 0 の入力（盤上の駒も持ち駒もなく，手番などの平面も 0）を基準とし，基準から今の局面まで入力を少しずつ増やしたとき，それぞれの入力の分として出力がどれだけ動いたかを表す（300 分割の和で近似）．値の単位は出力と同じで，全部の入力の値を足すと「今の局面の出力 − 基準での出力」になる．正の値は出力を押し上げたこと，負の値は押し下げたことを表し，ある駒 1 枚を取り除いたときの出力の変化ではない．出力には，value

© 2026 Information Processing Society of Japan

（手番側から見た勝ちやすさ）と，モデルが選んだ手（9 × 9 の将棋は実際に指された手）の確率を用いる．盤上の駒の値はマスごとに足して盤の形に描き（9 × 9 の将棋は直近 8 局面分を足す），持ち駒は駒の種類ごとの棒で示す．目盛りは図ごとに，値の絶対値の最大で決める．

3.5 持ち駒の可視化

持ち駒は盤の全マスに同じ値を入れた平面で入力されるため，Attention Map には持ち駒の場所がない．そこで，最善手（9 × 9 の将棋は実際に指された手）が駒打ちの局面で，次の 3 つを見る．(1) 打つ先を起点とし，打つ駒を持っているときと，その駒を 1 枚相手の持ち駒に移したとき（駒の総数は同じ）の重み × N の差（目盛りは全部の図で ±7）．重みは入力全体から計算されるため，持ち駒の平面が変わると重みも変わる．(2) 持ち駒の IG．(3) 打つ駒の種類ごとに，各マスに打つ手の policy の確率．

3.6 ヘッドと局面の選び方

動物将棋のヘッド．ヘッドを選ぶ局面と，選んだヘッドを確かめる局面を分けた．選ぶ局面には，完全解析の最善手順の 61 局面（最善手がすべて駒打ちの局面を除く．判定した手 71 個）を用い，最善手が動かす駒のマスから行き先のマスへの重み × 12 を，T ブロックを持つ 10 構成の全 116 ヘッドについて平均した．均等（1）を明確に上回ったのは 6T の第 5 T ブロックの第 4 ヘッドだけで（1.99．2 番目は 6T の第 2 T ブロックの第 1 ヘッドの 1.12），6T 以外の 9 構成の 92 ヘッドは 0.994〜1.006 であった．このヘッドを，選ぶのに使わなかった無作為な局面で確かめた（4.2 節）．6T の第 4 T ブロックの第 1 ヘッドは例の局面を見る中で重みが大きく偏っていたヘッドで，その見方（相手のライオンから手番側のライオンに重みを向ける）は無作為な局面では確かめていない．

動物将棋の局面．完全解析から条件ごとに選んだ候補から，説明しやすい局面を選んだ．図 1 は 6T が勝ちを失った局面から無作為に選んだ候補のうち，重みが取れる相手のライオンに集まっていた局面で，図 4(a) は 6T が詰みやトライを外した局面から無作為に選んだ候補である．図 4(b)〜(d) は示したヘッドの重み × 12 の最大（5 以上）が正解のマス（(d) は手番側のライオン）に向いた局面から，図 9 は持ち駒を渡したときの重みの変化が最も大きい局面から選んだもので，示す性質そのもので選んでいる．

9 × 9 の将棋の局面．藤井聡太五段と羽生善治竜王の対局（第 11 回朝日杯将棋オープン戦 準決勝，2018 年）[*1]から，R3(RRT) が選ぶ手が実際に指された手と一致した 80 手目までの局面（次の 81 手目に ▲5 五銀）と 103 手目までの局面（次に △5 五銀打），および最後の手の直前の 118 手目までの局面（次の 119 手目に ▲4 七桂打．王手で，直後に後手が投了）を用いた．図には 118 手目までの局面を示す．

4. 結果と考察

4.1 モデルの精度と強さ

動物将棋．モデルが選んだ手（探索なしで policy が最大の合法手）が最善手（勝ちなら最短で勝つ手，負けなら最も長く粘る手，引き分けなら引き分けを保つ手）と同じ評価である局面の割合を，完全解析の 239,784,182 局面（相手のライオンがトライ済みでどの手も同じ評価になる負け局面を除く）で数えた．完全解析の局面は先手番の向きで記録されており，動物将棋の入力は盤を手番側の向きに回さないため，盤を 180° 回して先後を入れ替えたものを後手番として入力した場合も数えた（正解は同じで，入力だけが変わる）．11 構成とも 0.82〜0.87 で，6T が最も高く（先手番として入力したとき 0.865，後手番として入力したとき 0.866），R ブロックだけの 6R は 0.843（先手番）であった．11 構成の最大と最小の差は，先手番として入力したとき 0.041（6T と 3R3T）であった．これは探索なしの policy の 1 手で数えた値であり，探索を用いた対局の強さとは別の量である．

9 × 9 の将棋．正解がないため，ResTNet [2] が KataGo の学習途中のモデルを相手にしたのにならい，AobaZero [9] が公開している学習初期の重み（w50, w60）[*2]と対局させた．AobaZero（v18）は 1 手 800 シミュレーション，1 スレッド，乱数なし，R3(RRT) は 1 手 64 シミュレーション（学習と同じ），ノイズなしで，候補の手を半分ずつに絞る Gumbel AlphaZero の探索（sequential halving）で最後に残った手を指した．開始局面は出村と金子 [8] と同じく人間の棋譜集の 9 戦型の 20〜40 手目から選び，先後を入れ替えて各重みに 400 局指した．R3(RRT) の勝率（勝ち ÷ 局数）は，w50 に対して 60.8%（243 勝 9 分 148 敗），w60 に対して 31.5%（126 勝 3 分 271 敗）であった．

4.2 動物将棋：Attention Map と IG

Attention Map．モデルが誤った局面で Attention Map がどこに重みを向けるかを見るため，6T が勝ちを失った局面を示す（図 1）．後手は a2a3 で相手のライオンを取れるが，6T は手番側のライオンを c2b1 と動かした．6T の第 5 T ブロックの第 4 ヘッドは，起点 c2 から相手のライオンのいる a3 に重みを集めた（6.69）．同じ T ブロックのほかの 3 ヘッドの最大は 1.05〜1.11，同じく c2b1 を選んだ RRTRRT の第 2 T ブロックの 4 ヘッドの最大はどれも 1.01 であった．重みは取れる相手のライオ

[*1] 棋譜は将棋 DB2 の https://shogidb2.com/games/87a8f10ff4177696b2e8d70c4a09ca00cc0c59936962838dd7fa052cc51800 による．

[*2] http://www.yss-aya.com/aobazero/

© 2026 Information Processing Society of Japan

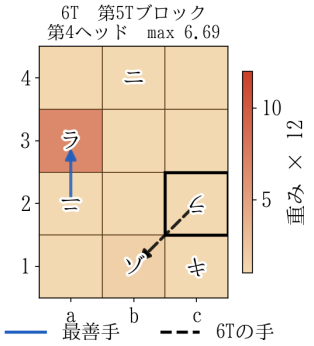


図 1　動物将棋：6T が勝ちを失った後手番の局面での Attention Map．起点（黒枠）は手番側のライオン c2．各マスの値は重み × 12（盤の色が 1，赤いほど大きい．最大 12）．駒は 1 文字（ラ：ライオン，キ：きりん，ゾ：ぞう，ヒ：ひよこ，ニ：にわとり），逆さの駒が後手．

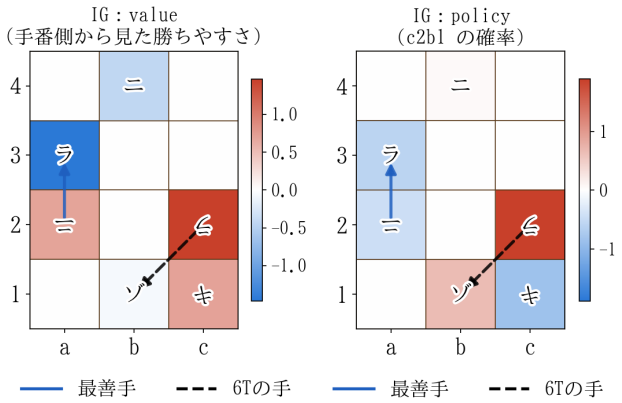


図 2　動物将棋：図 1 の局面での 6T の盤上の駒の IG．

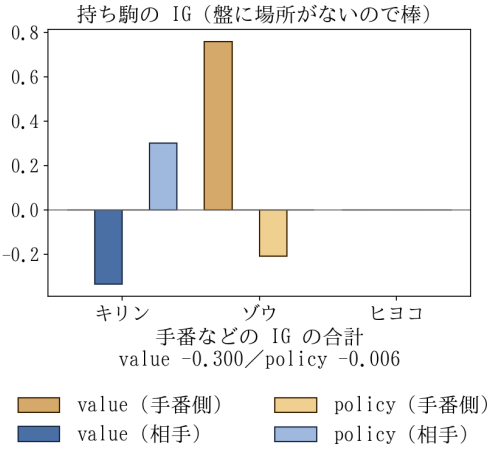


図 3　動物将棋：図 1 の局面での 6T の持ち駒の IG．

ンに集まっていたが，policy は別の手を選んだ．

IG による確かめ．同じ局面の IG（図 2，図 3）では，6T の value（後手から見た勝ちやすさ，0.99）は，a3 の先手のライオン（−1.45）が最も押し下げ，後手のライオン c2（+1.47）が最も押し上げ，後手の持ち駒のぞう（+0.76）が続いた．a3 のライオンの値の絶対値は盤上の駒で 2 番目に大きく，重みが集まったマスは value にも大きく効いている．一方，c2b1 の確率（0.81）を最も押し上げたのは動かす c2 のライオン自身（+1.89）で，後手のきりん c1（−0.84）と a3 のライオン（−0.60，盤上の駒で 4 番目）は押し下げる向きに働いた．

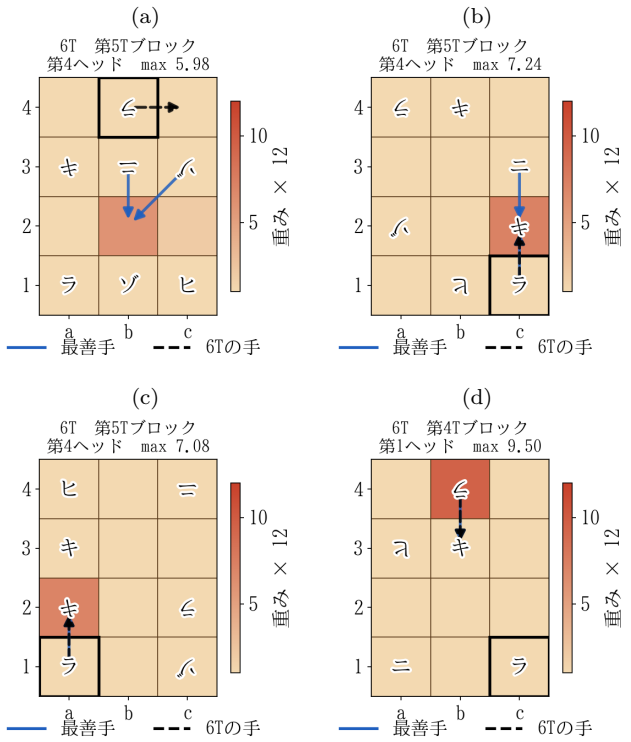


図 4　動物将棋：6T が局面の種類ごとに重みを集めるマス．(a) 1 手詰めの後手番の局面，(b) ライオンを狙う駒がある先手番の局面，(c) 負けの先手番の局面，(d) 後手番の局面．

局面の種類ごとの例．同じヘッドは局面の種類によって違うマスに重みを集め，別のヘッドは別のマスに重みを集めた（図 4）．(a) 詰み：1 手詰めに相当する後手番の局面で，第 5 T ブロックの第 4 ヘッドは，起点 b4 から詰ませるマス b2（最善手 b3b2・c3b2 の行き先）に 5.98 を集めたが，6T は b4c4 と指した．(b) 狙ってくる駒：同じヘッドは，起点 c1 から，手番側のライオンを狙う c2 の駒に 7.24 を集め，6T はその駒を取った（c1c2．最善手の 1 つ）．(c) 粘りの手：負けの局面で，手番側のライオンに王手をかけている a2 のきりんに 7.08 を集め，6T はそれを取った（a1a2．最も長く粘る手）．(d) 第 4 T ブロックの第 1 ヘッドは，後手番の局面で相手のライオン（c1）を起点にすると，手番側のライオン（b4）に 9.50 を集めた．

無作為な局面での確かめ．選んでいない局面でも成り立つかを，完全解析から無作為に選んだ局面（先手番・後手番として入力したもの各 10,000 局面）で，手番側のライオンを起点に調べた（図 5）．比べたのは，6T のほかの 23 ヘッドと RRTRRT の 8 ヘッドのそれぞれで問いごとに最も高いものと，偶然（ライオン以外の 11 マスから 1 つ選んだとき．正解のマスが複数ある局面があるため，問いごとに異なる）である．第 5 T ブロックの第 4 ヘッドの重

© 2026 Information Processing Society of Japan

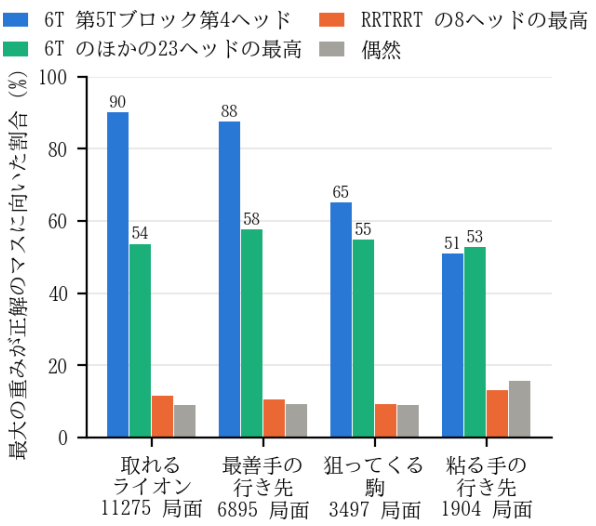


図 5 動物将棋：手番側のライオンを起点に，最大の重みが正解のマスに向いた割合．

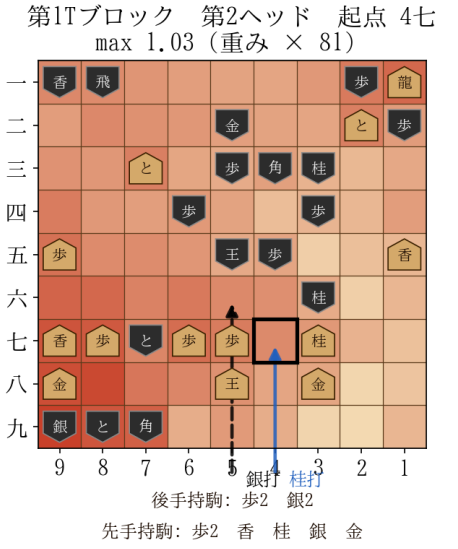


図 6 9 × 9 の将棋：藤井－羽生戦の 118 手目までの局面（次に ▲4 七桂打）での，R3(RRT) の Attention Map．黒枠は起点．駒は，先手が明るい色で上向き，後手が暗い色で下向き．図ごとに [0, 1] に正規化（赤いほど重みが大きい）．

みが最大となったマスは，相手のライオンを取れる局面の 90.1% で相手のライオン，負けでない局面で最善手がライオンの手のときの 87.7% でその行き先，ライオン以外の駒に手番側のライオンが狙われている局面の 65.2% でその駒，負けの局面で最も長く粘る手がライオンの手のときの 51.0% でその行き先であった．最初の 3 つの問いでは，6T のほかの 23 ヘッドで最も高いもの（問いごとに選ぶので高く出やすい）より，95% 信頼区間（Wilson 法）が重ならずに高かった．粘る手の行き先では，ほかの最も高いもの（52.8%）と区間（48.8〜53.2% と 50.6〜55.0%）が重なり，差があるとは言えなかった．RRTRRT の 8 ヘッドで最も高いものは 4 つの問いで 11.6，10.4，9.2，13.1% で，偶然（9.1，9.3，9.1，15.7%）との差は 2.6 ポイント以内であった．T ブロックごとの重み × 12 の最大（4 ヘッドの最大）の中央値は，6T の第 1〜6 T ブロックで 1.50，1.41，1.21，4.49，5.16，1.22，RRTRRT は 2 つの T ブロックとも 1.01 であった（ライオンが盤上にある 19,434 局面）．重みの偏りは深い第 4・5 T ブロックで大きく，最後の第 6 T ブロックでは小さい．

したがって，測った問いでは，第 5 T ブロックの第 4 ヘッドが正解のマスに重みを向けることは，選んだ例だけでなく無作為な局面でも成り立つ．また，図 1 や図 4(a) のように，正解のマスに重みを向けていても policy が別の手を選ぶ局面がある．Attention Map が示すのは，起点の特徴を作るときにどのマスの特徴を用いたかであり，選んだ手の理由そのものではない．

4.3 9 × 9 の将棋：Attention Map と IG

Attention Map． 3 局面とも，3 つの T ブロックの 12 ヘッドのうち起点からの重みの偏りが最も大きいのは第 1 T ブロックの第 2 ヘッドで，重み × 81 は 0.974〜1.030 とほぼ均等であった．T ブロックごとの最大（4 ヘッドの最大）は，第 1・2・3 T ブロックの順に 1.02〜1.03，1.01，1.00 で，深い T ブロックほど均等に近かった．[0, 1] に正規化した図では，3 局面とも，最も薄い 5 マスはすべて空きマスで，濃いマスの多くは駒のあるマスであった．一方，3 局面とも，実際に指された手の行き先や，相手の玉のマスは，濃いマスに入っていなかった．重みの差は最大で均等の 1.03 倍であり，この濃淡がモデルの着目を表すと言えるかは確かめられていない．R3(RRT) が選んだ手は，80 手目までの局面の ▲5 五銀（確率 0.88）と 103 手目までの局面の △5 五銀打（0.65．王手を受ける局面で合法手は 3 つ）では実際の手と一致し，118 手目までの局面では ▲5 六銀打を選んで ▲4 七桂打には 0.09 を置いた．

重みが均等になる理由は確かめていないが，R ブロックが近くのマスどうしの形を処理し，T ブロックは盤全体の平均を全マスに配る役割（3.3 節）になった可能性がある．ResTNet の論文は R3(RRT) で概念に重みが集まる図を示しており，学習の量や設定，調べる局面によっては，R を含む構成の Attention Map からも着目を読み取れる可能性がある．

IG による確かめ． 同じ局面の IG では，▲4 七桂打の確率（0.09，図 7）を最も押し上げたのは持ち駒の桂（+0.06）で，盤上の駒の値はどれも 0.03 以下であった．value（先手から見た勝ちやすさ，図 8）では，盤上では 2 二 の先手のと金（+0.20）が最も押し上げ，7 七 の後手のと金（−0.16）が最も押し下げた．持ち駒では，先手の銀・金が押し上げ（+0.14，+0.10），後手の銀・歩が押し下げた（−0.22，

© 2026 Information Processing Society of Japan

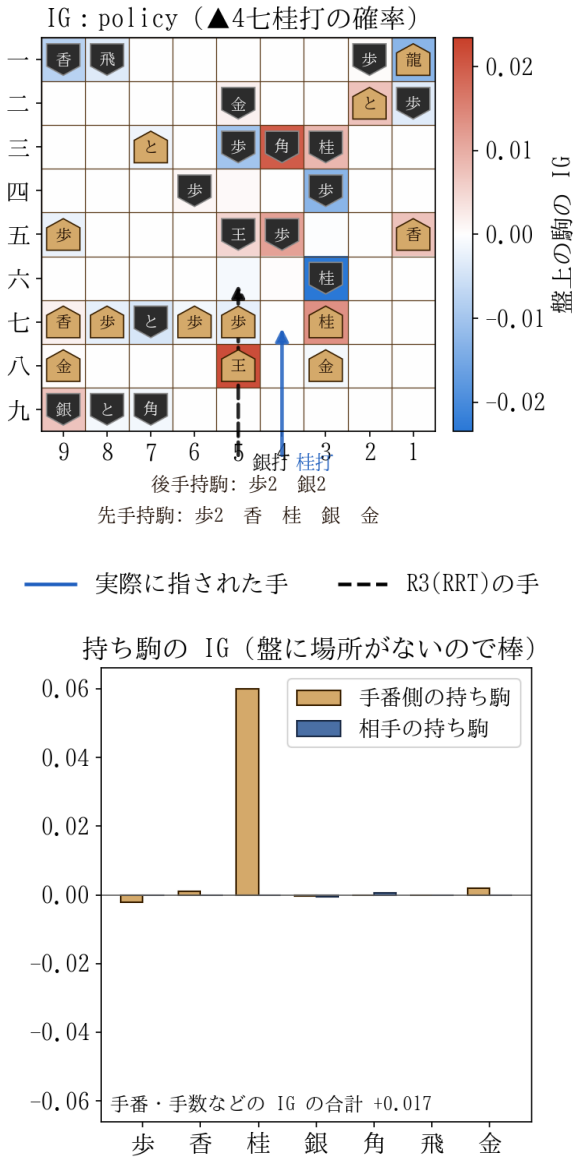


図 7　9 × 9 の将棋：図 6 の局面での R3(RRT) の，▲4 七桂打の確率の IG．盤上の駒と持ち駒の値は，直近 8 局面分の和．

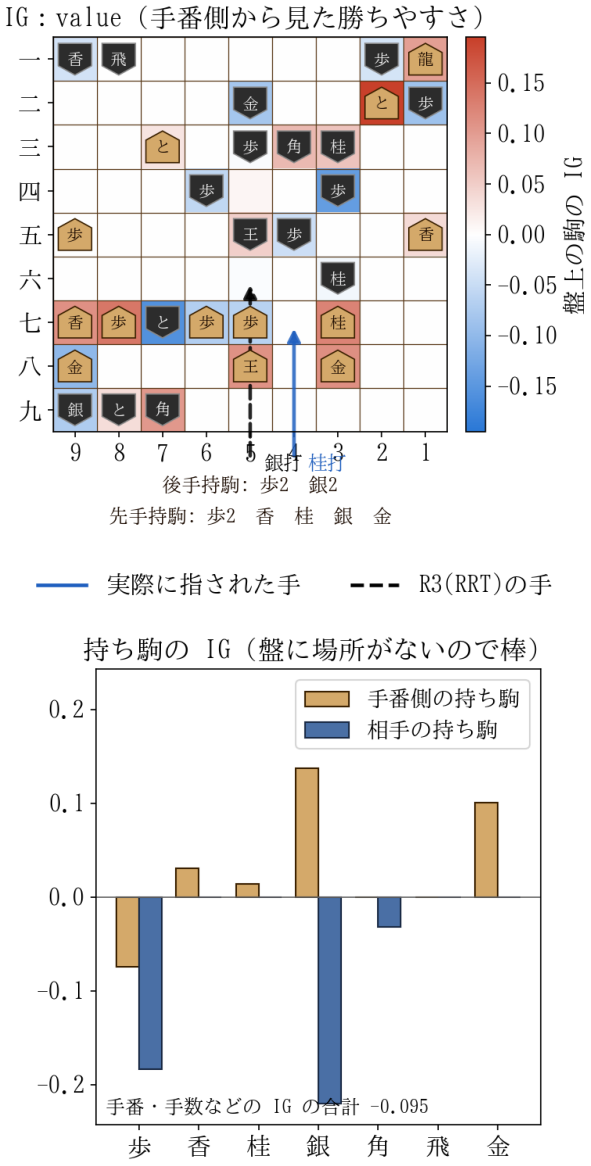


図 8　9 × 9 の将棋：図 6 の局面での R3(RRT) の，value（先手から見た勝ちやすさ）の IG（表示は図 7 と同じ）．

−0.18）．持ち駒の IG も直近 8 局面分の和なので，今は持っていない駒にも値が出る（後手の角の棒は，114 手目の △7 九角打 より前の 3 局面で後手が角を持っていたことによる）．ほかの 2 局面では，▲5 五銀の確率を動かす銀 5 六（+0.64）が，△5 五銀打の確率を王手をかけられている後手の玉 4 四（+0.48）が最も押し上げた．IG の合計と，出力と基準での出力の差は，3 局面とも 0.006 以内で一致した．IG と Attention Map の上位 5 マスの重なりは，どちらの出力でも 3 局面で 0〜2 マスで，手の確率を押し上げた駒は Attention Map ではなく IG で読み取れた．

4.4　持ち駒

動物将棋．図 9 は，最善手がきりんを a3 に打つ手（▲キ a3 打．a3 のきりんは隣の b3 にいる後手のライオンを取れる位置にある）で，6T もこの手に 0.79 の確率を置い

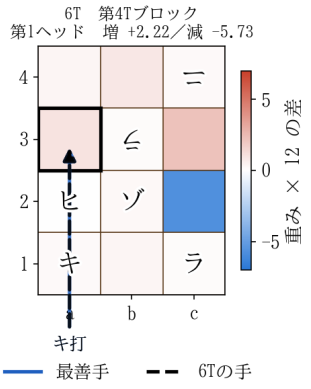


図 9　動物将棋：最善手が ▲キ a3 打の先手番の局面（先手はきりんを 1 枚持つ）での，起点 a3 からの重み × 12 の差（きりんを持っているとき − 1 枚相手に渡した後）．

© 2026 Information Processing Society of Japan

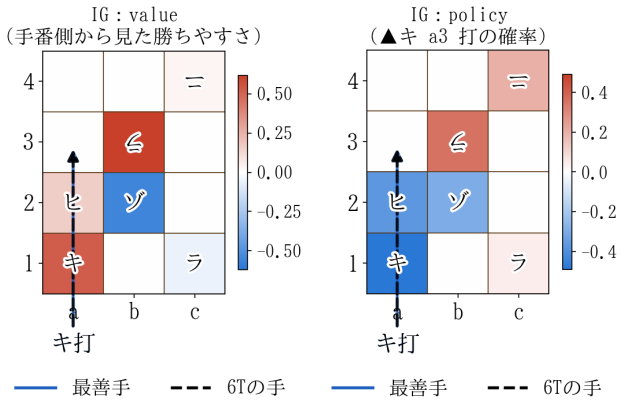


図 10　動物将棋：図 9 の局面での 6T の盤上の駒の IG.

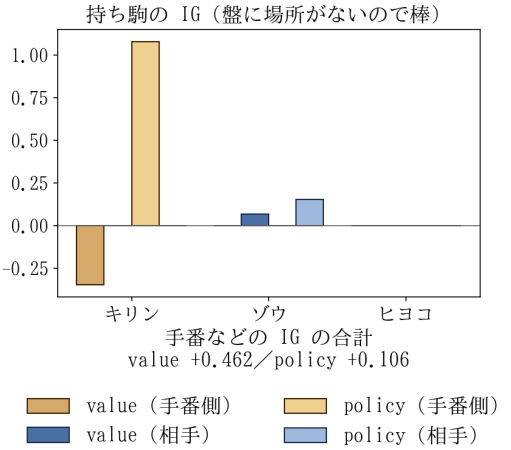


図 11　動物将棋：図 9 の局面での 6T の持ち駒の IG.

た局面である．6T の第 4 T ブロックの第 1 ヘッドでは，きりんを持っているときのほうが，起点 a3 から c3 に向ける重み × 12 が 2.22 大きく，c2 に向ける値が 5.73 小さかった．きりんの有無で打つ先から重みを向けるマスが変わったが，その変化が ▲キ a3 打を選ぶことにどう効くかは，この図からはわからない．同じ局面の IG（図 10，図 11）では，▲キ a3 打の確率を最も押し上げたのは持ち駒のきりん（+1.08）であった．

9 × 9 の将棋． 103 手目までと 118 手目までの局面で，打つ駒を 1 枚渡しても，起点からの重み × 81 の変化は 0.001 以下で，持ち駒の有無は Attention Map にほとんど表れなかった．打つ確率では，118 手目までの局面で，駒打ち全体では銀を 5 六 に打つ手（0.24）が最も高かった．

5.　まとめと今後の展望

動物将棋では，6T の第 5 T ブロックの第 4 ヘッドが，測った問いで，選んだ例だけでなく無作為な局面でも正解のマス（取れる相手のライオンや最善手の行き先など）に重みを向けており，将棋として妥当な着目がはっきり見られた．本研究で学習した R ブロックを含む構成では，測った範囲で重みはほぼ均等で，9 × 9 の将棋の調べた 3 局面では，正規化した図で濃いマスに指された手の行き先は入っておらず，手の確率を押し上げた駒は IG で読み取れた．9 × 9 の将棋は，モデルを変えて Attention Map を調べ直す余地がある．持ち駒は，動物将棋の 6T の第 4 T ブロックの第 1 ヘッドでは有無で重みの向くマスが変わり，9 × 9 の将棋では Attention Map にほぼ表れず，図の局面では両ゲームとも打つ駒が手の確率を最も押し上げた．

限界として，例の局面は説明しやすいものを選んでおり，無作為な局面で確かめたのは動物将棋の手番側のライオンを起点とした重みだけである．9 × 9 の将棋は 1 局の 3 局面で，正解がないため，Attention Map と IG が将棋として正しいかは確かめられておらず，モデルの強さも AobaZero の学習初期の重みと同じ程度である．また，IG の値は基準の選び方で変わり，本稿の基準（全部 0 の入力）は実際に現れない局面である．今後の展望を次に挙げる．

- 人間の棋譜の多くの局面で，強いエンジンの最善手と Attention Map・IG を照らし合わせ，9 × 9 の将棋全体で言えることを調べる．
- R ブロックを含む構成で重みが均等になる理由を，学習の設定や構成を変えて調べる．
- IG の値が完全解析の正解と合うかを，動物将棋の全局面で確かめる．

参考文献

[1] Silver, D., Hubert, T., Schrittwieser, J., Antonoglou, I., Lai, M., Guez, A., Lanctot, M., Sifre, L., Kumaran, D., Graepel, T., Lillicrap, T., Simonyan, K. and Hassabis, D.: A General Reinforcement Learning Algorithm that Masters Chess, Shogi, and Go through Self-Play, *Science*, Vol. 362, No. 6419, pp. 1140–1144 (2018).

[2] Ju, Y.-R., Wu, T.-L., Shih, C.-C. and Wu, T.-R.: Bridging Local and Global Knowledge via Transformer in Board Games, *Proc. IJCAI*, pp. 7446–7454 (2025).

[3] Danihelka, I., Guez, A., Schrittwieser, J. and Silver, D.: Policy Improvement by Planning with Gumbel, *Proc. ICLR* (2022).

[4] Wu, T.-R., Guei, H., Peng, P.-C., Huang, P.-W., Wei, T.-H., Shih, C.-C. and Tsai, Y.-J.: MiniZero: Comparative Analysis of AlphaZero and MuZero on Go, Othello, and Atari Games, *IEEE Transactions on Games*, Vol. 17, No. 1, pp. 125–137 (2025).

[5] Sundararajan, M., Taly, A. and Yan, Q.: Axiomatic Attribution for Deep Networks, *Proc. ICML*, PMLR, Vol. 70, pp. 3319–3328 (2017).

[6] Czech, J., Blüml, J., Kersting, K. and Steingrimsson, H.: Representation Matters for Mastering Chess: Improved Feature Representation in AlphaZero Outperforms Switching to Transformers, *Proc. ECAI*, pp. 2378–2385 (2024).

[7] 田中哲朗：「どうぶつしょうぎ」の完全解析，情報処理学会研究報告ゲーム情報学（GI），Vol. 2009-GI-22，No. 3，pp. 1–8 (2009).

[8] 出村洋介，金子知適：将棋 81 万：強化学習のための多様性を持った将棋初期局面集，ゲームプログラミングワークショップ 2023 論文集，pp. 111–118 (2023).

[9] 山下宏，保木邦仁，小林祐樹：AobaZero の紹介と観戦記，コンピュータ将棋協会誌，Vol. 31，pp. 38–44 (2020).

© 2026 Information Processing Society of Japan