チームビール工房 HFT 支店@wcsc32 アピール文

昨年同様 Have Fun Tech 代表の曽根壮大と第 28 回優勝，第 29 回準優勝の芝世弐のチームです。

昨年同様巨大な深層学習モデルで最高精度の局面評価を誇ります。

今の GPU では探索速度が文字通り桁違いですのでどこまで伸びるかギリギリまで強化学習を進めようと考えています。
また，モデルに関してはブロック数，チャンネル数のみならずポリシーヘッド，バリューヘッドの部分変更など複数パターンをテスト中ですので本戦で用いるのが 40 ブロックになるかどうかは乞うご期待と言った感じです。
恐らく選手権後にご報告致します。

第 32 回世界コンピュータ将棋選手権
dlshogi with HEROZ アピール文章

山岡忠夫
加納邦彦
山口祐
大森悠平
2021/3/29

※下線部分は、第 31 回世界コンピュータ将棋選手権からの差分を示す。

1　dlshogi のアピールポイント

dlshogi は、ディープラーニングを使用した将棋 AI である。

2017 年より、AlphaGo の手法を参考に開発を行っている。

ディープラーニング系の将棋 AI は、大局観に優れており、序中盤の形勢判断が従来型将棋 AI と比べて正確であるという特徴がある。一方、終盤の読みが重要になる局面では、従来型将棋 AI の方が正確な場合がある。

dlshogi は、終盤の課題に対処するために、独自の工夫を行っている。

具体的には、「MCTS の葉ノードでの短手数の詰み探索」、「ルート局面で df-pn による長手数の詰み探索」、「勝敗が確定したノードのゲーム木への伝播」、「PV 上の局面に対する長手数の詰み探索」、「強化学習時に初期局面集を使用して局面の多様性を確保する」、「強化学習時に df-pn により詰み探索を行い詰みを報酬とする」という工夫を行っている。

これらのいくつかは、現在、dlshogi 以外のディープラーニング系の将棋 AI には取り入れられているが、dlshogi 以前にこれらを導入しているディープラーニング系の将棋 AI はなかった。

2　チーム参加について

今大会では、HEROZ チームとして参加する。

3　dlshogi の特徴

- ディープラーニングを使用
- 指し手を予測する Policy Network
- 局面の勝率を予測する Value Network
- 入力特徴にドメイン知識を積極的に活用
- モンテカルロ木探索
- 未探索のノードの価値に親ノードの価値を使用
- GPU によるバッチ処理に適した並列化

- 自己対局による強化学習
- 詰み探索結果を報酬とした強化学習
- 既存プログラムを加えたリーグ戦による強化学習
- 既存将棋プログラムの自己対局データを混ぜて学習
- 既存将棋プログラムの自己対局データを使った事前学習
- ブートストラップ法による Value Network の学習
- 引き分けも含めた学習
- 指し手の確率分布を学習
- 同一局面を平均化して学習
- 評価値の補正
- SWA(Stochastic Weight Averaging)
- 末端ノードでの短手順の詰み探索
- ルートノードでの df-pn による長手順の詰み探索
- 勝敗が確定したノードのゲーム木への確実な伝播
- PV 上の局面に対する長手数の詰み探索
- 序盤局面の事前探索（定跡化）
- 定跡作成時に floodgate の棋譜の統計を利用した確率分布を方策に利用
- マルチ GPU 対応（NVIDIA A100×8 を使用予定）
- TensorRT を使用
- Optuna による探索パラメータの最適化
- 確率的な Ponder
- ノードのガベージコレクションとノード再利用処理の改良
- 飛車と角の利きのビット演算
- 2 値の入力特徴量を 1 ビットで転送することで推論のスループットを向上
- KL 情報量を利用した時間制御

4　使用ライブラリ

- Apery[1]（WCSC28）
  →局面管理、合法手生成のために使用

4.1　ライブラリの選定理由

本プログラムは、将棋におけるディープラーニングの適用を検証することを目的としており、学習局面生成、局面管理、合法手生成については、使用可能なオープンソースがあれば使用する方針である。そのため、学習局面を圧縮形式(hcpe)で生成する機能を備えていて、合法手生成を高速に行える Apery を選定した。

[1] https://github.com/HiraokaTakuya/apery

5　各特長の具体的な詳細（独自性のアピール）

5.1　ディープラーニングを使用

DNN(Deep Neural Network)と MCTS を使用して指し手を生成する。

従来の探索アルゴリズム(α β法)、評価関数(3 駒関係)は使用していない。

5.2　Policy Network

局面の遷移確率を Policy Network を使用して計算する。

Policy Network の構成には、Residual Network を使用した。

入力の畳み込み 1 層と、ResNet 15 ブロック(畳み込み 2 層で構成)と出力層の合計 32 の畳み込み層で構成した。フィルターサイズは 3（入力層の持ち駒のチャンネルのみ 1)、フィルター数は 224 とした。

5.3　Value Network

局面の勝率を Value Network を使用して計算する。

Value Network は、Policy Network と出力層以外同じ構成で、出力層に全結合層をつなげ、シグモイド関数で勝率を出力する。

5.4　入力特徴にドメイン知識を積極的に活用

Alpha Zero では、入力特徴に呼吸点のような囲碁の知識を用いずに盤面の石の配置と履歴局面のみを入力特徴とすることで、ドメイン知識なしでも人間を上回ることが示された。しかし、その代償として、入力特徴にドメイン知識を活用した AlphaGo Lee/Master に比べて倍のネットワークの層数が必要になっている。AlphaGo Zero の論文の Figure 3 によると、ネットワーク層数が同一のバージョンでは Master を上回る前にレーティングが飽和している。

強い将棋ソフトを作るという目的であれば、積極的にドメイン知識を活用した方が計算リソースを省力化できると考えられる。

そのため、本ソフトでは、入力特徴に盤面の駒の配置の他に、利き数と王手がかかっているかという情報を加えている。それらの特徴量が学習時間を短縮する上で、有効であることは実験によって確かめている。

5.5　モンテカルロ木探索

対局時の指し手生成には、Policy Network と Value Network を活用したモンテカルロ木探索を使用する。

ノードを選択する方策に、Policy Network による遷移確率をボーナス項に使用した PUCT アルゴリズムを使用する。PUCT アルゴリズムは、AlphaZero の論文[2]の疑似コードに記述さ

[2] http://science.sciencemag.org/content/362/6419/1140

れた式を使用した。

また、末端ノードでの価値の評価に、Value Network で計算した勝率を使用する。

通常のモンテカルロ木探索では、末端ノードから複数回終局までプレイアウトを行った結果（勝率）を報酬とするが、将棋でランダムなプレイアウトは有効ではないため、プレイアウトを行わず Value Network の値を使用する。

5.6　未探索のノードの価値に親ノードの価値を使用

モンテカルロ木探索の UCB の計算時に、未探索の子ノードがある場合、そのノードの価値に何らかの初期値を与える必要がある。子ノードの価値は親ノードの価値に近いだろうという将棋のドメイン知識を利用し、それまでの探索で見積もった親のノードの価値を動的に初期値として使用する。ただし、ノードの訪問回数が増えるに従い、その価値の減衰を行い、幅より深さを優先した探索を行う(FPU reduction)。

5.7　GPU によるバッチ処理に適した並列化

複数回のシミュレーションを順番に実行した後、それぞれのシミュレーションの末端ノードの評価をまとめて GPU でバッチ処理する。その後、評価結果をそれぞれのシミュレーションが辿ったノードにバックアップする。以上を一つのスレッドで行うことで、マルチスレッドによる実装で課題となる GPU の計算後にスレッドが再開する際にリソース競合が起きる問題（大群の問題）を回避する。

GPU で計算中は、CPU が空くため、同じ処理を行うスレッドをもう一つ並列で実行する。2 つのスレッドが相互に CPU と GPU を利用するため、利用効率が高い処理が可能となる。

5.8　自己対局による強化学習

事前学習を行ったモデルから開始して、AlphaZero[3]と同様の方式で強化学習を行う。自己対局により教師局面を生成し、その教師局面を学習したモデルで、再び教師局面を生成するというサイクルを繰り返すことでモデルを成長させる。

2018 年の大会で使用した elmo で生成した教師局面で収束するまで学習したモデルに比べて、自己対局による強化学習によって有意に強くすることができた。

5.9　詰み探索結果を報酬とした強化学習

自己対局時に終局まで対局を行うと、モンテカルロ木探索の特性上、詰むまでの手順が長くなる傾向がある。勝率予測に一定の閾値を設けることで、終局する前に勝敗を判定することで対局時間を短縮できるが、モデルの精度が低いうちは誤差が大きいため、学習精度に影響する。

この課題の対策として、df-pn による高速な長手数の詰み探索の結果を報酬とした。単純に

[3] https://arxiv.org/abs/1712.01815

すべての局面で詰み探索を行うと、自己対局の実行速度が大幅に落ちてしまう。自己対局は複数エージェントに並列で対局を行わせ、各エージェントからの詰み探索の要求をキューに溜めて、詰み探索専用スレッドで処理するようにした。エージェントが GPU の計算待ちの間に詰み探索が完了する。エージェントが探索している局面は別々のため、時間のかかる詰み探索の要求が集中することは少ない。これにより自己対局の速度を大幅に落とすことなく長手数の詰み探索を行えるようになった。

5.10 既存プログラムを加えたリーグ戦による強化学習

自分自身のプログラムのみで強化学習を行うと戦略に弱点が生まれる可能性がある。弱点をふさぐには多様なプログラムによるリーグ戦が有効だが、複数のエージェントを学習するにはエージェント数の分だけ余分に計算資源が必要になる。

計算資源を省力化して、リーグ戦の効果を得るために、オープンソースで公開されている既存の将棋プログラムを 1/8 の割合でリーグに加えて強化学習を行うようにした。

5.11 既存将棋プログラムの自己対局データを使った事前学習

本プログラムを使用して、Alpha Zero と同様に、ランダムに初期化されたモデルから強化学習を行うことも可能だが、使用可能なマシンリソースが足りないため、スクラッチからの学習は行わず、既存将棋プログラムの自己対局データを教師データとして、教師あり学習でモデルの事前学習を行う。

教師データには、elmo で生成した自己対局データを使用した。

5.12 既存将棋プログラムの自己対局データを混ぜて学習

以前の dlshogi は、入玉宣言勝ちできる局面でなかなか入玉宣言勝ちを目指さないという課題があった。

自己対局では入玉宣言勝ちの棋譜が少ないため、それを補うため既存将棋プログラム(水匠)の自己対局で、入玉宣言勝ちの棋譜を生成し、dlshogi の自己対局のデータに混ぜて学習した。

5.13 ブートストラップ法による Value Network の学習

Value Network の学習の損失関数は、勝敗を教師データとした交差エントロピーと、探索結果の評価値を教師データとした交差エントロピーの和とした。

このように、本来の報酬（勝敗）とは別の推定量（探索結果の評価値）を用いてパラメータを更新する手法をブートストラップという。

経験的にブートストラップ手法は、非ブートストラップ手法より性能が良いことが知られている。

5.14 引き分けも含めた学習

将棋はルールに引き分けがあるゲームであるため、引き分けも正しく学習できる方が望ましい。そのため、自己対局で引き分けとなった対局も学習データに含めて学習した。

5.15 指し手の確率分布を学習

以前の dlshogi では、指し手のみを学習していたが、AlphaZero と同様に、自己対局時で MCTS で探索した際のルート局面の子ノードの訪問回数に従った確率分布を学習するように変更した。確率分布を学習することで、最善手と次善手の行動価値が近い場合に、次善手の行動価値を正しく学習できるようになる。

確率分布を学習することで、floodgate の棋譜に対する一致率が向上することが確認できたが、対局して強さを計測すると弱くなるという現象が確認できた。原因は、モデルの方策の出力の性質が変わるため、探索パラメータの調整が必要なためであった。Optuna を使用して探索パラメータを最適化(**エラー! 参照元が見つかりません。**参照)することで、指し手のみを学習したモデルよりも強くすることができた。

5.16 同一局面を平均化して学習

自己対局では、序盤の同一の局面の教師データが多く生成される。それらの重複した局面を別のサンプルとして学習すると、モデルの学習に偏りが起きる。

局面の偏りをなくするために、同一の局面を集約し、指し手の確率分布と勝敗を平均化し、1 サンプルとして学習した。

5.17 評価値の補正

自己対局で生成するデータには、MCTS で探索して得られた勝率(最善手の価値)を局面の評価値を記録し、学習時にブートストラップ項(**エラー! 参照元が見つかりません。**参照)として使用している。記録した評価値(勝率)が、実際の対局の結果から算出した勝率と一致しているか調べたところ、乖離しているという現象が確認できた。そのため、評価値を実際の自己対局での勝率に合うように、補正を行った。

5.18 SWA(Stochastic Weight Averaging)

画像認識の分野でエラー率の低減が報告されている手法である、SWA(Stochastic Weight Averaging)をニューラルネットワークの学習に取り入れた。一般的なアンサンブル手法では、推論結果の結果を平均化するが、SWA では学習時に一定間隔で重みを平均化することでアンサンブルの効果を実現する。

5.19 末端ノードでの短手順の詰み探索

モンテカルロ木探索の末端ノードで、5 手の詰み探索を行い、詰みの局面を正しく評価できるようする。並列化の方式により、GPU で計算中の CPU が空いた時間に詰み探索を行う

ため、探索速度が落ちることはない。

5.20 ルートノードでの df-pn による長手数の詰み探索

モンテカルロ木探索は最善手よりも安全な手を選ぶ傾向があるため詰みのある局面で駒得になるような手を選ぶことがある。

対策として、詰み探索を専用スレッドで行い、詰みが見つかった場合はその手を指すようにする。

詰み探索は、df-pn アルゴリズムを使って実装した。優越関係、証明駒、反証駒、先端ノードでの 3 手詰めルーチンにより高速化を行っている。

5.21 勝敗が確定したノードのゲーム木への確実な伝播

モンテカルロ木探索で構築したゲーム木の末端ノードで詰みが見つかった場合、その結果をゲーム木に伝播して利用する。つまり、モンテカルロ木探索に、AND/OR 木の探索を組み合わせて、詰みの結果を確実にゲーム木に伝播するようにする。

5.22 PV 上の局面に対する長手数の詰み探索

ディープラーニング系の将棋 AI は、選択的に探索を行うために、終盤の局面で読み抜けがあると、頓死することある。

頓死を防ぐため、PV 上の局面に対して、df-pn による長手数の詰み探索を行い、詰みが見つかった場合、局面の価値を更新するようにする。

5.23 序盤局面の事前探索（定跡化）

出現頻度の高い序盤局面は、対局時に探索しなくても、事前に探索を行い定跡化しておくことができる。また、事前に探索することで、対局時よりも探索に時間をかけることができる。

ゲーム木は指数関数的に広がるため、固定の手数までの定跡を作成するよりも、有望な手順を選択的に定跡に追加する方が良い。自分が指す手は、1 つ局面につき最善手を 1 手（または数手）登録し、それに対する応手は、公開されている定跡や棋譜の統計情報を使って確率的に選択する。その手に対して、また最善手を 1 手（または数手）登録する。この手順により、頻度の高い局面については深い手順まで、頻度の低い局面については短い手順の定跡を作成することができる。

5.24 定跡作成時に floodgate の棋譜の統計を利用した確率分布を方策に利用

定跡を自分自身の探索のみで作成した場合、読み抜けがあった場合に定跡を抜けた後に不利な局面になる恐れがある。そのため、モンテカルロ木探索の PUCT の計算で、方策ネットワークの確率分布と floodgate の棋譜の統計を利用した確率分布を平均化した確率分布を利

用し、致命的な読み抜けを防止する。

5.25 マルチ GPU 対応

複数枚の GPU を使いニューラルネットワークの推論を分散処理する。

「5.7 GPU によるバッチ処理に適した並列化」の方式により、GPU ごとに 2 つの探索スレッドを割り当てることで、GPU を増やすことでスケールアウトすることができる。ノードの情報は、すべてのスレッドで共有する。

確認できている範囲で 4GPU までほぼ線形で探索速度を上げることができている。

5.26 TensorRT を使用

モデルの学習にはディープラーニングフレームワークとして PyTorch を使用しているが、対局プログラムには、推論用ライブラリの TensorRT を使用する。

TensorRT を使うことで、事前にレイヤー融合などのニューラルネットワークの最適化を行うことで、推論を高速化することができる。TensorCore に最適化されており、TensorCore を搭載した GPU では CUDA+cuDNN で推論を行う場合より、約 1.33 倍の高速化が可能になる[4]。

また、対局の実行環境にディープラーニングフレームワークの環境構築を不要とすることを目的とする。

5.27 Optuna による探索パラメータの最適化

PFN により公開された Optuna[5]を使用して、モンテカルロ木探索の探索パラメータ（PUCT の定数、方策の温度パラメータ）を最適化した。

Optuna は、主にニューラネットワークの学習のハイパーパラメータを最適化する目的で利用されるが、将棋エンジン同士の連続対局の勝率を目的関数として、探索パラメータの最適化に使えるようにするスクリプト[6]を開発した。Optuna の枝刈り機能により、少ない対局数で収束させることができる。

5.28 確率的な Ponder

モンテカルロ木探索は確率的にゲーム木を成長させる。その特性を活かして、相手が思考中に、相手局面からモンテカルロ木探索を行うことで、確率的に相手の手を予測して探索を行うことができる。予測手 1 手のみを Ponder の対象とするよりも、効率のよい Ponder が実現できる。

---

[4] https://tadaoyamaoka.hatenablog.com/entry/2020/04/19/120726

[5] https://optuna.org/

[6] https://github.com/TadaoYamaoka/DeepLearningShogi/blob/master/utils/mcts_params_optimizer.py

5.29 ノードのガベージコレクションとノード再利用処理の改良

世界コンピュータ将棋オンライン大会でノード再利用に 10 秒以上かかる場合があるこがわかったため、ノード再利用の方式の見直しを行った。

以前は、オープンアドレス法でハッシュ管理を行っており、ルートノードから辿ることができないノードをすべてのハッシュエントリに対して線形探索してノードの削除をおこなっていた。

これを、Leela Chess Zero のゲーム木の管理方法[7]を参考に、ゲーム木をツリーで管理を行うようにし、ルートの兄弟ノードをガベージコレクションする方式に変更した。ノードの合流の処理が行えなくなるという欠点があるが、ノード再利用を短い時間で行えるようになった。

5.30 飛車と角の利きのビット演算

第 31 回世界コンピュータ将棋選手権の Qugy のアピール文章[8]による、飛車、角の利きをビット演算により求める方法を実装した（実装はやねうら王のソースコードを参考にした)。ZEN2 の CPU で NPS が約 1% 向上した。

5.31 2 値の入力特徴量を 1 ビットで転送することで推論のスループットを向上

マルチ GPU を使用した場合、4GPU 以上では CPU と GPU 間の帯域がボトルネックになるため、2 値の入力特徴量を float の代わりに、1bit で表現し、GPU にビットで転送後、GPU 側で CUDA のプログラムでバッチ単位に並列に float に戻す処理を実装した。こうすることで、転送量が削減でき、NPS が 36.6%向上した。

5.32 KL 情報量を利用した時間制御

探索のルート局面の方策の分布と探索後の訪問回数の分布の KL 情報量が高い局面は、探索がより重要になる局面と考えられるため、KL 情報量が高い場合、より探索に時間を使うようにした。

KL 情報量を利用した時間制御を行うことで、同じ持ち時間でレーティングが 44.1 向上した。

---

[7] https://tadaoyamaoka.hatenablog.com/entry/2020/05/05/181849

[8] https://www.apply.computer-shogi.org/wcsc31/appeal/Qugiy/appeal_210518.pdf

やねうら王 PR 文書

― スーパーテラショック定跡生成手法について ―

やねうら王チーム

要　旨

近年、Deep Learning 系の将棋ソフトはプロ棋士の研究にも取り入れられてきている。Deep Learning 系の将棋ソフトは従来型の将棋ソフトに比べると序盤戦術に長けていると言える。本論文手法は、その優れた序盤感覚のソフトで大規模な定跡を自動生成しようという試みである。

第１章　従来の定跡生成手法

第１節　人間の棋譜から

コンピュータ将棋も 2010 年ごろまでは人間が定跡を手で入力していた。特にプロの棋譜は神聖視されており、プロの棋譜に出現した 32 手目までの手順をそのまま定跡としているソフトも多数存在した。GPS 将棋[2009-][1]などもプロの棋譜の手順をそのまま定跡化しているようであった。

しかしながら、プロの棋譜には 76 歩 34 歩 68 銀 88 角成(角のタダ取り)で投了というような棋譜も混じっており、プロの棋譜をそのまま定跡として採用していた Bonanza[2005-][2]がこの手順を指すということで話題になったこともある。

そこで、その棋譜の指し手が指された回数を集計し、指された回数が多かった指し手を指すことでこのような悪手を指さないようにするような試みがあった。Bonanza で言うと narrow book というエンジンオプションである。

あるいはプロの棋譜に対して自作の将棋ソフトで 1 局面 0.1 秒や探索深さ 12 など短い時間(or 深さ)で思考させ、悪い評価値の指し手だけを取り除くというハイブリッドな手法が取られることもあった。習甦[3][2014]がそのようなアプローチを取っていた。

プロの棋譜を用いる場合、インターネットで入手できる棋譜の数が限られている(4 万局程度)というのがあるし、トッププロより将棋ソフトの方が棋力が高くなった現在においては、もはや人間の棋譜は定跡生成には直接は使えないと言っていいだろう。

第２節　floodgate の棋譜から

棋譜の数で言うと floodgate(コンピューター将棋ソフトの対局サーバー)[4]の棋譜を用いるというのは魅力的である。floodgate の棋譜の数は 50 万棋譜以上存在するし、その時代時代の最新のソフトが参加しているため、floodgate の棋譜を用いればお手軽かつそれなりの精度で生成できる。2015 年ごろまでわりと流行していた手法である。

floodgate の棋譜から定跡を生成する場合、Bonanza の narrow book の考え方を踏襲し、定跡上の各局面では、なるべく floodgate で採用された回数が多い指し手を選択する。採用回数が多い指し手ほどその信頼性が高いと考えられるからである。Apery[2015][5]や、やねうら王[2014][6]の standard_book.db などに見られるようにこの方法で作成された定跡を搭載する将棋ソフトはわりと多い。

しかし採用回数ベースで定跡を生成する場合、棋譜の数が少ないとその局面での採用確率が 100%であっても信用ならないという欠点がある。例えばその局面を含む棋譜が 1 つしかない場合に、その棋譜の指し手を定跡として登録して良いのかという問題がある。

また弱いソフトの指し手が混じっている場合、それがどれほど信用できるのかという問題もある。ひどい例で言うと、定跡を抜けた直後の局面で先手必敗(評価値 -600)ということもあった。

---

[1] Wikipedia 「GPS 将棋」：https://ja.wikipedia.org/wiki/GPS%E5%B0%86%E6%A3%8B

[2] Wikipedia「Bonanza」：https://ja.wikipedia.org/wiki/Bonanza

[3] Wikipedia「習甦」：https://ja.wikipedia.org/wiki/%E7%BF%92%E7%94%A6

[4] floodgate ：http://wdoor.c.u-tokyo.ac.jp/shogi/floodgate.html

[5] Wikipedia 「Apery」：https://ja.wikipedia.org/wiki/Apery

[6] Wikipedia 「やねうら王」：https://ja.wikipedia.org/wiki/%E3%82%84%E3%81%AD%E3%81%86%E3%82%89%E7%8E%8B

あと、floodgate での対局は、序盤での持ち時間を節約するために何らか定跡を用いて対局させることが多いようで、実際の勝率は低いのにわりと採用されている序盤の指し手というのが存在していることが dlshogi の山岡の研究からわかっている。[7]

そこで、floodgate の棋譜を用いる場合、勝率ベースで指し手を選択するという方法も考えられる。その指し手を指したあと、実際に勝っているのかという点を考慮しようというわけである。この方法は、わりとうまく行くのだが、強いソフトが採用している定跡を過度に信用してしまう問題がある。例えば、floodgate には初手 38 銀に固定したソフトや、必ず振り飛車にする定跡を搭載した将棋ソフトが参加していた。おそらくそのような序盤定跡を用いた時に、普通に指すのに比べてどれくらいレートが落ちるのかを見たい開発者がいたのであろう。このような棋譜が混じっている場合、勝率ベースで定跡を生成する場合でも信用ならない指し手が紛れ込む可能性はいくらでもある。

floodgate の棋譜に対しても自作の将棋ソフトで短い時間で思考させ、明らかに悪い評価値の指し手は取り除くというハイブリッドな手法が取られることもあった。習甦の方法に倣い、やねうら王[2015]もそのような方法を用いたことがある。

しかし、floodgate の棋譜上に数回しか出現しなかった局面の指し手は信用ならないので、30 回以上出現した局面についてのみに絞って定跡化しようなどとすると、局面数はかなり減ってしまい、定跡として十分な局面数を確保できないという問題があった。

いずれにしても棋力にばらつきのある外部の棋譜に頼る以上、その信頼性を担保するのが難しく、データも無限に用意できるわけではないので定跡の局面数にも自ずと限界があった。

[7] 山岡忠夫 「floodgate の序盤 3 手の統計」 https://tadaoyamaoka.hatenablog.com/entry/2021/11/06/010026

第 3 節　人間+ソフトのハイブリッド

ある程度の棋力を有する人間が、将棋ソフトを使いながら、将棋ソフトで上位にくる指し手の変化をすべて調べ、そしてその定跡の末端の局面から対局させて勝率を計測し、形勢が互角であっても勝率が悪い局面への指し手は取り除くという、気の遠くなるような作業を経て作られた定跡がある。

このような定跡としては suimon_fan 氏が公開されている s-book_black[8]が優秀なことで有名だ。WCSC31 で優勝した elmo[2021]も手作業による定跡であり、いまだ上位ソフトの開発者でもこのような手作業での定跡生成を行っている開発者は少なくはない。

第 4 節　自己対局型自動生成

そこで出てきたのが定跡の自動生成という技術である。2015 年ぐらいから流行りだす。ただ、当時の将棋ソフトは序盤はわりと精度が低かったので、実際に序盤で思考させて、良い評価値の枝を掘っていく(思考させて定跡局面として登録していく)のは、わりと危なっかしいところがあった。

そこで、自己対局をして勝率の良いところを掘り進めていくという手法が用いられることが多かった。とりわけそのなかでも優秀だったのは shotgun 定跡[9]と呼ばれるもので、SDT5(第 5 回将棋電王トーナメント)で shotgun というソフトが採用し(shotgun は SDT5 準優勝)、その後、WCSC28 で Hefeweizen がそれを受け継いだ。[10]

[8] suimon_fan ： https://twitter.com/mztn7_fan

[9] 芝世弐 ， コンピュータ将棋における定跡生成法の一提案 ： https://ipsj.ixsq.nii.ac.jp/ej/?action=repository_uri&item_id=192055&file_id=1&file_no=1

[10] 芝世弐 ， Hefeweizen WCSC28 PR 文書 https://www.apply.computer-shogi.org/wcsc28/appeal/Hefeweizen/appeal.pdf

shotgunの方法は簡単に言ってしまえば異種ソフトをローカル環境で対局させ、勝率ベースで定跡化するというもので、相手が既知の将棋ソフトの場合、わりと高い確率でその定跡の指し手を指すようである。

Hefeweizenの手法はほぼノーメンテナンスで定跡が生成していけるということで、定跡自動生成系としてはわりと高い評価がなされているが、自己対局ベースなので生成にとても時間がかかることや既知のソフト以外のソフトだと定跡から外れやすいという欠点はあった。

生成のためにとても時間がかかるのでは、定跡に登録できる局面数が稼げないことになる。いくら精度が高く優秀であっても相手より先に定跡が尽きてしまったのでは、大会では相手の方が多くの持ち時間を残したまま終盤に突入してしまい、結果、不利になってしまう。

このように定跡DBはその登録されている指し手の質、精度はもちろんのこと、なるべく実戦で実現しやすい局面が数多く登録されていることも重要である。

第5節　Minimax探索型(テラショック化)

どんな方法で定跡を生成するにせよ、その定跡のleaf node(末端の局面)での評価値が得られているなら、定跡のゲームツリー上でMinimax探索を行えば、先後が定跡上の指し手で最善を尽くした時に到達するleaf nodeが確定する。

やねうら王では、これを**テラショック化**と呼んだ。[11]やねうら王[2017]には与えた棋譜の局面で思考させ、定跡DB上の各局面に評価値をつけるコマンドをすでに用意していたので、このコマンドを用いて、まずfloodgateの棋譜などを与え、各局面に評価値をつける。その後、その定跡DBをテラショック化することができれば、定跡ツリー上の各局面からのPV(最善応手列)が得られる。それをその各局面の最善手とした定跡DBファイルを別途出力する。これがテラショック化コマンドの概要である。

このテラショック化コマンドは、やねうら王[2019]で実装され、このテラショック化した定跡を用いてやねうら王はWCSC29で優勝した。

ところが、その大会後に判明したことだが、Minimax探索は末端の評価値がroot(定跡の探索開始局面 = 初期局面)まで伝播してくるので、ノイズに極めて弱いという性質がある。従来の将棋ソフト(非Deep Learning系の将棋ソフト)では、評価値にずいぶんノイズが乗っているようで、テラショック化には向かないという意味があった。実際、やねうら王がWCSC29で用いた定跡と前述のs-book_blackとを対局させてみたところ、定跡を抜けた局面でやねうら王の定跡側が不利な局面であった。

また、上の手法は、与えた棋譜ファイル上でMinimax探索のようなことをやっていることになるわけだが、この時、与えた棋譜の指し手しか先後ともに指さないという暗黙の仮定をしていることになる。これはじゃんけんで言うとグーが封じられているようなもので、その状態で(グー、チョキ、パーすべてを使える相手に)勝てるのかという意味もある。

テラショック化という発想自体はさほど悪くなかったのだと思うのだが、以上のように明らかな欠点も抱えており、従来型のソフトには荷が重いと言わざるを得なかった。

第6節　第一章まとめ

floodgateの棋譜から勝率の高かった指し手のみを選んで定跡化するのはさほど悪くないものの、floodgateの棋譜に出現した指し手しか指せないという意味で、グーしか出せないジャンケンにも似ている。今後、将棋ソ

[11] やねうら王ブログ　「テラショック定跡の生成手法」　：https://yaneuraou.yaneu.com/2019/04/19/tera-shock-book-generation/

フトの序盤がシビアになってくるとそんな方法は通用しなくなってくるだろう。

結局、現時点で定跡の自動生成手法で成功しているのは shotgun 定跡ぐらいのものだが、実際にローカル対局を行うので費やすリソースのわりに掘れる(登録できる)定跡の局面数に自ずと限りがある。

テラショック化は悪いアイデアではなかったが、従来の将棋ソフトには評価値にムラがある(ノイズが乗っている)ので、意図通りには機能しない。また PV(最善応手列)の周りを重点的に掘りたいのに、事前に与えた棋譜の局面しか掘れず、テラショック化してからその定跡を用いて自己対局させて、その対局棋譜を与えて思考させて、またテラショック化する、というようないイテレーション(反復)でしか定跡を掘っていけないので思考対象局面の選出に非常に手間と時間がかかる。

第 2 章　スーパーテラショック定跡生成手法

第 1 節　Deep Learning 系思考エンジンの利用

従来型の非 Deep Learning 系の将棋ソフトの序盤には評価値にムラがある(ノイズが乗りやすい)、不正確であるという弱点があった。

そこで定跡の生成には Deep Learning 系の将棋ソフトを用いることにした。現在、ソースコードが公開されている Deep Learning 系の将棋ソフトのなかで最強である dlshogi[12]の互換エンジンとして**ふかうら王**という将棋ソフトを開発した。

今回の定跡生成では、このふかうら王で 1 局面 1 秒程度思考させる。Deep Learning 系の将棋ソフト、特にふかうら王では、思考させた局面のすべての合法手に対する評価値が得られる。なので、この得られた評価値をその指し手で 1 手進めた局面での評価値であると仮定して、有望そうな局面のみを効率的に展開していくことができる。

そのあと任意のタイミングで定跡 DB に対してテラショック化を行い、最終的な定跡 DB を得る。これがスーパーテラショック定跡生成手法の骨子である。

第 2 節　思考対象局面の選出

どの局面を思考対象として選ぶかという問題がある。外部から棋譜を与えてその局面を思考させるという方法もあるが、それだと与えた棋譜の局面しか思考しないので、「自分だけがグーの出せないじゃんけん」のようになってしまう。

テラショック化した定跡を用いて、実際に対局させ、その対局棋譜上に現れた局面について再度思考させるようなイテレーション(反復)も考えられる。やねうら王[2019]ではそうやって定跡を生成していたのだが、テラショック化自体に時間が相当かかるし、ローカル対局にも時間を要する。この方法だとあまり PV まわりを掘り進められない。

そこで、定跡ツリー上で、α β 探索[13]を行い、PV(最善応手列)を取得し、その leaf node(末端の局面)を展開する(思考対象とする)ような仕組みを用意することにした。

これをここでは「(次に思考すべき局面の)選出」と呼ぶことにする。選出された局面をふかうら王の思考エンジンを用いて思考していく。これをここでは「思考」と呼ぶことにする。つまり、「選出」と「思考」。今回の定跡の自動生成はこの二つで成り立っている。

第 3 節　選出の高速化と思考との並列化

この「思考」中にも「選出」を行わなければ思考エンジンに遊び時間が出来てしまうから、「選出」と「思考」は並行して行える必要がある。また「選出」自体を高速化しないと、思考エンジンに遊び時間ができてしまう。

そのためには、

1)　思考エンジンが思考中にも次に有望そうな局面を何局面でも選出できること
2)　選出が思考より遥かに短い時間で完了すること

この二つが必須条件である。

---

[12] dlshogi GitHub : https://github.com/TadaoYamaoka/DeepLearningShogi

[13] Wikipedia : Alpha beta pruning : https://en.wikipedia.org/wiki/Alpha%E2%80%93beta_pruning

最終的な局面数は 1500 万局面程度を想定している。1 局面 1 秒で間断なく思考しつづける時、1 日 86400 局面思考できるから、半年で 1500 万程度であるという想定である。

この 1500 万局面の定跡をメモリ上に読み込んでいる状態においても 1 回の選出が 1 秒未満で完了する必要があると考え、今回はそれを目標に開発を行った。

そこで今回、

1)のために ranged alpha beta search という技法を開発した。

2)のために 高速化のための探索上の工夫を複数実施した。

第 4 節　ranged alpha beta search

まず、典型的な alpha beta 探索の疑似コードを示す。これはゲーム木探索の教科書などに載っている。[14]

```
// pos   : 局面
// alpha : alpha beta 探索の alpha 値
// beta  : alpha beta 探索の beta 値
Value search(pos,alpha,beta):
  foreach m in 全合法手:
    if pos を m で進めた局面が定跡 DB 上にある:
      pos.do_move(m)  // m で 1 手進める
      value = -search(pos,-beta,-alpha)
      pos.undo_move() // 1 手戻す
    else:
      value = pos の局面で m を指した時の評価値
      // 思考した時に全合法手に対応する評価値が得られている。
    if alpha < value:
      if beta <= value:
        return value # beta-cut
      alpha = value   # update alpha
  return alpha
```

[14] Wikipedia 「アルファ・ベータ法」：https://ja.wikipedia.org/wiki/%E3%82%A2%E3%83%AB%E3%83%95%E3%82%A1%E3%83%BB%E3%83%99%E3%83%BC%E3%82%BF%E6%B3%95

上記のプログラムの

foreach m in 全合法手:

の直後に、pos を m で進めた局面が思考中であるなら、この指し手 m はないもの(非合法手)として扱えば、次に良い評価値を持つ leaf node が探せるはずである。基本的な考えかたはそれだけなのだが、これを高速に行える必要がある。

やねうら王では、局面に対応する hash key として Zobrist Hashing という技法を用いている。[15]　また、やねうら王には、ある局面で指し手 m を指した局面に対応する hash key を求める関数も用意されている。

これを用いれば実際には盤面を動かさずして、指し手 m を指したあとの局面の hash key が得られる。この hash key が思考中の局面集合のなかにあれば、ないものとして扱う。つまり、さきほどの部分は、次のようなコードを書いてある。

```
foreach m in 全合法手:
  // 探索中のノードの hash key 集合に m を指した局面の hash key が含まれるなら、m をないものとして扱う。
  if searching_nodes.contains(pos.key_next(m)):
    continue
```

ranged alpha beta search の基本的なコードは以上である。

この疑似コードの searching_nodes は実際のプログラムでは C++の std::unordered_set を用いている。そのためこの集合に含むかどうかの判定は極めて短い時間で行われる。

hash key だとたまたま衝突してしまうと困るので、本来は局面を一意に識別できるものを使うべきである。

[15] Zobrist hashing ：https://en.wikipedia.org/wiki/Zobrist_hashing

そのようなものとしてはSFEN文字列[16]やそれを256bitに符号化したPackedSfen[17]などがあるが、その変換コストは馬鹿にならない。

やねうら王では、hash keyを通常使う64bitのみならず、128bit、256bitに変更する機能があるので、本手法では、128bitのhash keyを用いることにした。この場合、天文学的な確率でしかhash衝突は生じないので、定跡生成の用途で用いるならば問題ないと言えるだろう。

第5節　棋譜上の局面を掘る

本提案手法の目的は、外部棋譜を用いず、自分の思考エンジンのみでノーメンテナンスで低コスト(少ない計算量)で定跡を自動生成することにあるが、実際には、与えられた棋譜の局面を掘り進めたいこともある。

そのため、さきほどのranged alpha beta searchの疑似コードの以下の行

value = posの局面でmを指した時の評価値

の続きに以下のコードを追加する。

```
// kif_nodes:棋譜上に出現した局面のhash keyの集合
if kif_nodes.contains(pos.key_next(m)):
  value += 100
```

棋譜上に出現した局面であれば、leaf nodeの評価値に加点している。これにより、ranged alpha beta searchを行う時にこのleaf nodeは優遇される。

尤も、元があまりに悪い評価値であれば100点を加点したところで評価値としては悪いままであるから、このleaf nodeが選出されることはない。このように、与えた棋譜であっても展開するに値しないならばそこ以上は掘らないというのも自動的に上のコードでなされるので、有望な枝だけが延長される。このため大量の棋譜を与えてもそのすべての局面について思考するわけではなく、優れた局面の「選出」性能を発揮する。

第6節　千日手局面回避のテクニック

本手法では、千日手局面に到達した時のスコアは0として扱っている。通常の探索においては先手は、初期局面においてプラスの評価値がついている。後手は(先手が初手で最善手を指した場合)自分の局面でマイナスの評価値がついている。すなわち、ranged alpha beta searchでは先手は千日手を回避しながらプラスの評価値の局面に辿り着きたいし、後手はマイナスの評価値を避けるため千日手を目指すような探索をしていることになる。

この手法を実装する上で難しい点として、千日手まわりの処理が挙げられる。そこまでの経路(手順)と同じ局面に循環してしまう時、それをどのように取り扱うかという問題がある。

局面の合流を取り扱わなければ千日手に関してあまり難しい問題は発生しないのだが(Deep Learning系でMCTSを用いる将棋ソフトや囲碁のソフトはそうなっているものが多い)、定跡の生成で合流を取り扱わない場合、将棋では特に角換わりで手待ちを繰り返して同じ局面に合流することが多く、そこで組み合わせ爆発を生じてしまい、そこ以降の定跡を掘れなくなってしまう。

このため、定跡生成においては局面の合流を適切に取り扱う必要があるが、合流を取り扱うと千日手の問題が出てくる。

---

[16] SFEN文字列　「USIプロトコルとは」
: http://shogidokoro.starfree.jp/usi.html

[17] やねうら王ではSFEN文字列をハフマン符号化し、256bitにする機能が備わっている。これをPackedSfenと呼ぶ。

そのため、今回、千日手局面を ranged alpha beta search で回避するための手法を開発した。次のように行う。

「思考」済みの局面が再び「選出」された時、それは千日手手順でその局面に到達したものだと考えられる。これを banned nodes 集合と呼ぶ。PV が千日手である場合、循環局面に至る指し手 m とその局面の hash key をペアで保持しておき、その組み合わせの指し手 m を非合法手として扱えば良いのである。

この状態で「選出」を行えば、自動的にその次に有望な leaf node が得られるので、千日手局面が PV になり続けて「思考」できないという状況は回避できる。

これで「選出」時の千日手に関する問題は解決したのだが、テラショック化の時に千日手局面をどう解決するかと言う問題はある。これについては、第 9 節で詳しく述べる。

第 7 節 PV and nonPV

ranged alpha beta search は、通常のαβ探索と同様に再帰的に行われるが、ある局面の探索結果を記憶しておき、二度目にその局面に訪問した時は前回の結果を用いたい。

しかし、PV の leaf node は「選出」されたあと、「思考」が完了するまで無いものとして扱われるので、記憶していた各局面での探索結果の値が不正なものとなってしまう。

そこで、PV と NonPV という考え方を導入する。これは、チェスの Stockfish[18]というチェスのソフトなどαβ探索を行う現代の将棋・チェスのソフトで広く使われている手法である。

PV node ： PV(最善応手列)に関係する node に関する探索。枝刈りはほとんどしない。
NonPV node ： PV 以外の node に関する探索。枝刈りわりとする。

すなわち、探索する時に PV node 用の探索モードと、NonPV node 用の探索モードとの二つの探索モードがあると考えられる。PV はしっかり leaf node まで確認するが、NonPV node では枝刈りをできる限りする。PV(最善応手列)の読みが担保されていればまあいいだろうと言う考えかたである。

例えば、ranged alpha beta search で指し手 m で 1 手進めて再帰的に search 関数を呼び出すところ(次行)は、

value = -search(pos,-beta,-alpha)

以下のように、最初にまず NonPV モードで探索をし、α値を更新しそうな時だけ真面目に PV モードとして探索しなおすというコードになる。

```
value = -search<NonPV>(pos,-beta,-alpha)
if nodeType == PV && alpha < value:
  value = -search<PV>(pos, -beta, -alpha)
```

また、NonPV node では、前回その局面に訪問して探索した時の探索のスコア(best alpha)を記録しておき、それを用いて枝刈りを行う。

ただし、αβ探索では、探索窓として区間(alpha,beta) の範囲に収まる値を探索している。探索結果がこの値の範囲内に収まれば、再度訪問した時に、その値をそのまま使えるが、そうでない場合はどうなるのだろうか？これについては次節で述べる。

[18] Stockfish ： https://stockfishchess.org/

第8節 fail low/fail high

alpha beta 探索は、その局面で区間(alpha,beta)の間に収まる値のなかで最大のものを探す探索である。beta 以上の値がひとつでも見つかれば、その局面の探索を即座に中断し、search 関数はその値を返す。この状態は fail high と呼ばれ、そこで関数から抜ける枝刈りのことは beta cut と呼ばれる。

fail high が生じた時、この node のなかの指し手で beta を超えるものが一つ以上あることはわかるが、これを次回の探索の時に活かすにはどうすれば良いだろうか？

これを解決するのが、bound lower(下界)という考え方である。[19] fail high が生じた時の value(探索値)をこの局面の探索の値 search_value として保存しておく。また、同時にこの値に関するラベルとして bound lower であるとラベルをつけておく。

実際は search_value 以上の値を記録する指し手 m があるかも知れないが、前回の訪問時にすべての指し手を調べたわけではないので(beta cut したので)、そこはわからない。ただ、少なくとも search_value の値を持つ指し手 m が 1 つは存在することは言えている。

再度訪問したときに、bound lower の値として search_value が記録されていたとして、その時の探索窓の beta が

beta <= search_value

であるなら、beta cut して良いことになる。(下界による枝刈り)

同様に、前回の探索で alpha を上回る指し手 m がなかったとして、この場合 fail low と呼ばれる状態だが、この時の最大を記録した value を search_value に保管し、bound upper(上界)とラベルをつけておく。

次にこの node に訪問したとき、alpha が

alpha >= search_value

であれば、どの指し手 m でも alpha を上回らず fail low が起きる見込みが高いので即座に関数から抜け出すことができる。(上界による枝刈り)

また、alpha < search_value < beta であるような search_value の時は、search_value に bound_exact(正確にその範囲)のラベルをつけておく。

以上 3 つの枝刈りは NonPV でのみ行われる。そこで、その 3 つを合わせると以下のような枝刈りが search 関数の先頭で行えることがわかる。

```
// すでに探索済みでかつ千日手が絡まないスコアが記録されている時の枝刈り。(NonPV 限定)
if nodeType == NonPV and  search_value != VALUE_NONE:
  if    bound == BOUND_EXACT
    or (bound == BOUND_LOWER && search_value >= beta
    or (bound == BOUND_UPPER && search_value <= alpha
      return search_value
```

第9節 cyclic score

循環スコア(cyclic score)とは千日手が絡んだ探索の値のことである。いかに NonPV node であっても循環スコア(cyclic score)を信じない方が良いと思われる。

千日手は経路(そこまでの手順)に依存するので、経路が異なれば千日手にならないこともある。

そこで、千日手を検出した場合、循環スコアには cyclic フラグを立てて、子 node に cyclic フラグが立

[19] 英語では lower bound と呼ぶが、Stockfish などのソースコード上では BOUND_LOWER という定数ラベルが用いられているので、それに倣い、ここでは bound lower と書く)

っていれば、その node の探索値 search_value は cyclic score であるとみなし、それを信用しない、とすることは出来る。

ただ、こうしてしまうと組み合わせ爆発が起きるようでテラショック化が現実的な時間で終わらなくなってしまう。主な原因として次のような局面がある。

60 手目付近で矢倉に組み上げて、先後ともに角を動かして手待ちを繰り返す。角の動かし場所は 5 箇所程度あり、先後で 5×5 の組み合わせがある。cyclic score だからと言って、前回の探索値が丸々使えないのでは、こういう部分で組み合わせ爆発を容易に起こすようである。

df-pn による詰将棋にも似た問題があって、GHI 問題という有名な問題がある。df-pn に出現する GHI 問題自体は、千日手を検出した場合、そこまでの手順を hash key 化したものを置換表に記憶しておくことで、GHI 問題自体は回避できる。[20] [21]

しかし、テラショック化の時に GHI 問題の回避のためにそのように経路を保存しておいても上に書いたようにその経路自体が容易に組み合わせ爆発を起こすので無限に近い経路の数をその局面の探索結果の情報として保持する必要が出てくる。

これを回避するためには、千日手を検出した時、そこまでの経路で千日手に関与しない局面の hash key の集合(white list)と、千日手に関与する局面の hash key の集合(black list)とその時の探索の結果値をその局面の情報として保存しておく必要がある。これは実装自体が難しく、また、よほど工夫しないとメモリ空間的にも現在の PC では厳しいので、今回の採用は見送る。

そこで本手法では、cyclic score に関してはきちんと取り扱うことは諦め、NonPV では cyclic score であろうと信用するような実装にしてある。

第 10 節 本手法の効果

本論文の手法で 80 万局面ほど思考し、テラショック化を行ったスーパーテラショック定跡では、初手 76 歩に対する 34 歩を明確に悪手(評価値-243)だと認定した。[22]

2 手目 34 歩はプロの将棋においても昔からよくあるオープニング(序盤)だが、本論文の手法は、この 2 手目の 34 歩を咎めるところまできている。実際、そのあとソフト同士の対局によると先手勝率が 6 割程度であり、このオープニングは現在プロの将棋でも減りつつある。[23]

また、第一章で紹介した s-book_black とスーパーテラショック定跡とで対局させた場合、29 手目まで定跡で進行し、スーパーテラショック定跡側の定跡が先に尽きたが、その局面から最新の将棋ソフト(水匠 4)で対局を引き継ぎ、思考時間を変えて 100 戦やってみたところ 55 勝 42 敗 3 引き分けであった。s_book_black は先手専用定跡のため、スーパーテラショック定跡側は後手番である。後手番で勝ち越しているのでこれは十分な戦果であり、人間がソフトを活用し、長い時間と労力を掛けて作り上げた定跡集を、外部棋譜を一切使わず、かつ、ノーメンテナンスな自動定跡生成により打ち破ったと言えるだろう。

[20] Kishimoto, Akihiro and Martin Müller. “A solution to the GHI problem for depth-first proof-number search.” Inf. Sci. 175 (2005): 296-314.

[21] koumori-n , コウモリのちょーおんぱ 「詰将棋ソルバーにおける GHI 問題対策」 https://komorinfo.com/blog/and-or-tree-ghi-problem/

[22] やねうら王ブログ , スーパーテラショック定跡が 76 歩に 34 歩を全否定 ： https://yaneuraou.yaneu.com/2021/11/05/super-tera-shock-book/

[23] 山口 祐, ツイッター https://twitter.com/ymg_aq/status/1456283886439129089

第 11 節　本手法のまとめ

現代にふさわしい定跡生成手法として、次のような手法の誕生が望まれていた。

・完全な自動生成(ノーメンテナンス)

・少ない計算資源で掘っていける

・(floodgate の棋譜など)外部の棋譜を用いない

・(shotgun 定跡のように)対戦相手の思考エンジンを仮定しない

・思考対象局面の選出が小さな計算コストで出来る

・テラショック化のような定跡ツリー上で Minimax を行い、評価値の高い leaf node を目指す定跡が生成される

本論文で提案するスーパーテラショック定跡生成手法では、これらの要求をすべて満たすことが出来た。

また、スーパーテラショック定跡生成手法は実際にやねうら王のソースコード上に実装し、公開もしている。[24]

参考にしていただければ幸いである。

[24] やねうら王 GitHub , makebook2021.cpp : https://github.com/yaneurao/Yaneura0u/blob/e620b83d4ecb110120cf2abe4f4c806e0634c9b4/source/book/makebook2021.cpp

マメット・ブンブク
アピール文書

ザイオソフト コンピュータ将棋サークル
野田久順 岡部淳 鈴木崇啓
河野明男 伊苅久裕

目次

- マメット・ブンブク
- 改良点
- 使用ライブラリ

たぬきち

- 元ネタは『ファイナルファンタジーXIV』に登場するミニオンの名前です。
  - ミニオンとは、プレイヤーが一緒に連れて歩くことができる「ペット」のようなものです。
- ミニオンのように、いつも一緒にいてもらえるような将棋ソフトを目指しています。

改良点（1）

- 定跡生成手法に、たややん2020手法を使用しました。
  - floodgate の棋譜から定跡を作りました。
  - レーティング 3900 以上のソフト同士の対局の棋譜のみ使用しました。
  - 勝率が 33% 以上の指し手のみ使用しました。

改良点（2）

- 学習データの生成条件を変更しました。
  - 自己対局の対局開始局面を変更しました。
    - floodgate のレーティング 3900 以上のソフト同士の棋譜を使用しました。
    - 32 手目までからランダムに局面を選択しました。
    - ランダムムーブを入れないようにしました。
  - 探索深さ 9 で対局しました。

改良点（3）

- 局面数を数億から数十億に増やしました。
- 学習データの生成に「水匠 5」を使用させていただきました。
  - 貴重なソフトを公開してくださり
    ありがとうございます。

改良点（4）

- 入力特徴量に HalfKP_vm を採用しました。
  - 玉が 6～9 筋にいるとき、
    盤面を左右反転させて入力します。
  - 左右対称次元下げと同じ効果が得られ、
    かつネットワークパラメーター数が減ります。
  - より少ない学習データで学習できると
    考えられます。

改良点（5）

- 機械学習のパラメーターを変更しました。
  - elmo 式学習法における、勝敗項の教師信号（t）を t=0.80 としました。
    - 評価値のスケールが小さくなりました。
  - K･P･HalfKP相対次元下げを無効化しました。

使用ライブラリ

- やねうら王
  - やねうら王を元に改造した思考部を使用している。
    - 独自の工夫を加えるにあたり、改造しやすく、レーティングも高いため。
- 水匠5
  - 学習データの生成に使用している。
    - レーティングが高く、学習データの生成速度が速いため。
- tanuki-
  - 学習データの生成に使用している。
    - 過去に開発した資産の再利用のため。

よろしくお願いします

第32回世界コンピュータ将棋選手権　「S.Lightweight-EF」アピール文書

2022.3.31
神田 剛志

■開発コンセプト

名前の通り軽く速く。（末尾のEFはDNNのモデル(EfficientNet)が由来です）
ローカルPC環境でもCPU系/GPU系に限らず、つよつよインスタンス勢や
高級スリッパと戦うことがLightweightシリーズの目的です。

■アピールポイント

・DNNモデルの改良

本家のResNetをEfficientNetで再構築し、１から学習しなおしました。
第2回電竜戦時のモデルから6層追加した改良型に当たります。

・USIエンジンのパラメータ設定変更によるNPS向上

GPUに局面を渡す際のバッチサイズを1024に上げています。
これと軽量なモデルと組み合わせにより、ローカルPC環境での平均NPSを向上させています。

・GCT学習データによる教師あり学習とLightweight-EF自身による強化学習

dlshogiチームが公開してくださっている学習データとLightweight-EFの
自己対局データを用いた強化学習を実施しています。
またこの際、学習時のバッチサイズをあげる事で学習の安定化を図っています。
（学習データを無償で公開されている山岡さん、加納さんには感謝申し上げます）

・UCB選択アルゴリズムの一部変更（NPS向上のための簡易枝刈りの実施）

PUCTアルゴリズムに従って探索木を降りていく際、各子ノードの着手確率を
利用した簡易的な枝刈りを実施することで、最大UCB値の子ノード選択処理に
かかる時間を短縮しています。

・定跡の使用

初期局面の事前探索結果を利用することで、持ち時間の消費を抑えます。

■使用ライブラリ

dlshogi：自己対局データ生成・探索部・モデル学習・定跡作成に利用
Gikou2 ：検証時のテスト対局に使用
Suisho3：検証時のテスト対局に使用
Suisho4：検証時のテスト対局に使用
elmo for learn：学習データ作成に利用

WCSC32 W@nderER アピール文書

Dated 2021/12/27

昨年に 引き続き、入玉宣言による勝利を積極的に目指します。

名人コブラ アピール文書

松山洋章

概要

ディープラーニング評価関数とNNUE評価関数をベースとしたアンサンブル評価関数を使用します

評価関数

MultiPVで出力したdlshogiとやねうら王の評価値や、局面情報等を入力特徴としたスタッキング評価関数を作成します。

使用ライブラリ

- **dlshogi**

  局面評価のベースとして。

  序中盤の局面評価に優れるため。

- **やねうら王**

  局面評価のベースとして。

  読みの速さに優れるため。

ソフト名の由来

劇団鋼鉄村松

「二手目8七飛車成り戦法」

登場人物より

参考:
https://stage.corich.jp/stage_main/23036

𑖖 (Qha)のPR文章

Ryoto Sawada, Yuki Ito, Toshihiro Shirakawa, Keigo Nitadori (Quorax 党 将棋部)

進捗を575でまとめると

MuZeroはAlphaZeroより弱かった

以下、MuZeroがどんなものであるか、どういう実験をしてどういう失敗をしたかについて解説します

大会で出すネタがねえとどうしよう

そもそもMuZeroとは何者か

MuZeroはAlphaZeroの発展形のひとつ。探索時にゲームのシミュレータを必要としないことでより幅広い問題に適用することができる。また、原著論文によれば囲碁将棋などのゲームでもAlphaZeroと同等以上の性能を発揮している

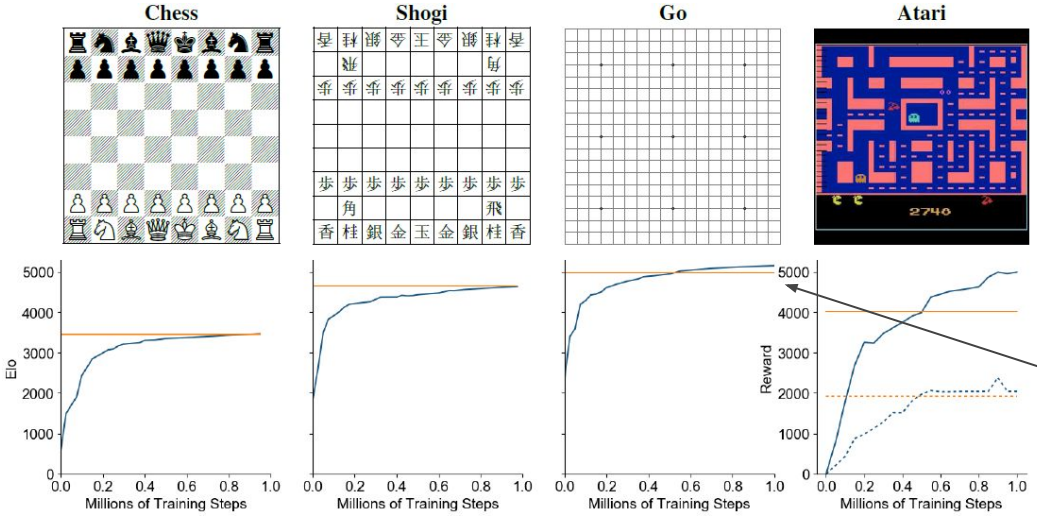

次ページからAlphaZeroとMuZeroの違いを解説

囲碁ではAlphaZeroよりも強いと言ってる

https://arxiv.org/pdf/1911.08265.pdf

AlphaZeroがどのようにして盤面を評価するか

AlphaZeroは局面を評価値に変換するAIとシミュレータ（図中のパソコン）からなる

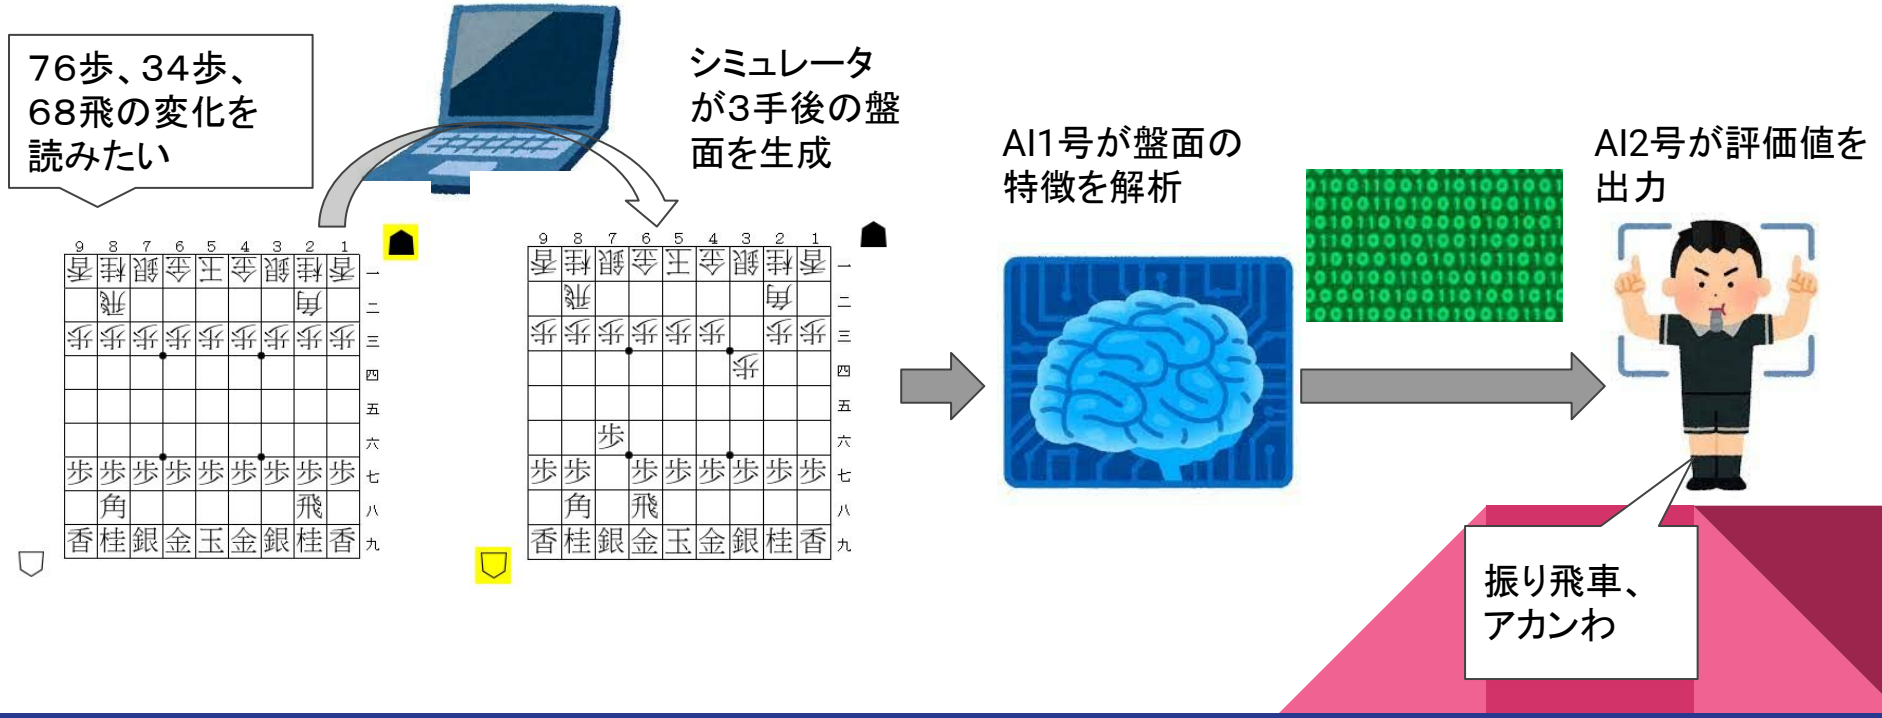

MuZeroがどのようにして盤面を評価するか

MuZeroは探索時にシミュレータを使わない

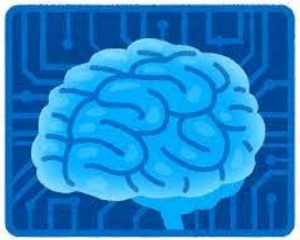

AI3号が指し手の情報から数手先の盤面の特徴を生成する

AlphaZeroとMuZeroの違い

シミュレータが重いケース（テレビゲームなど）に対してMuZeroは有効

AlphaZeroでも対応可能

シミュレータが3手後の盤面を生成（一瞬）

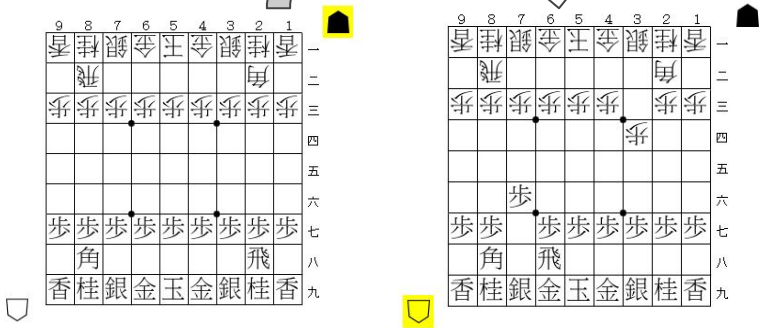

AlphaZeroには厳しい

マ○オをジャンプさせた後の盤面を生成（高コスト）

AlphaZeroとMuZeroの違い

囲碁、将棋などのシミュレータは極めて軽いため、MuZeroを使う必然性はない。
AlphaZeroとの優劣は数手先の局面をどれだけ正確に評価できるかで決まる

シミュレータが3手後の盤面を生成

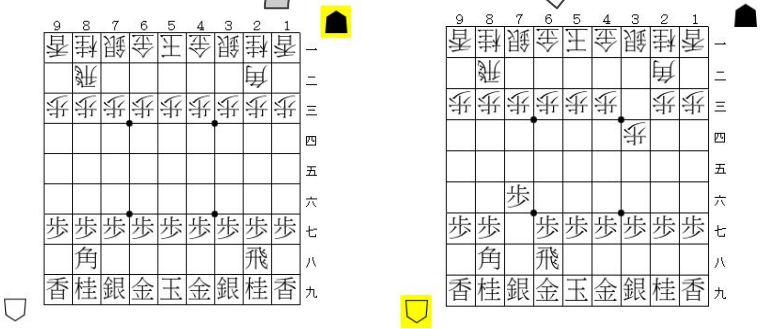

VS

Q : 3手後の局面をどちらがより正確に評価できるか

AlphaZero vs MuZero

AlphaZero派の主張：AIを使って3手後の局面を完全に復元できるとは限らない。シミュレータを使えば正確な結果が出るのだからシミュレータを使ったほうが良いに決まってる

AIが将棋のルールを完全に理解できるの？ どこかでエラーがでたりしないの？

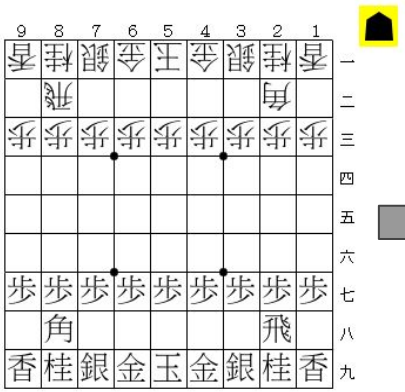

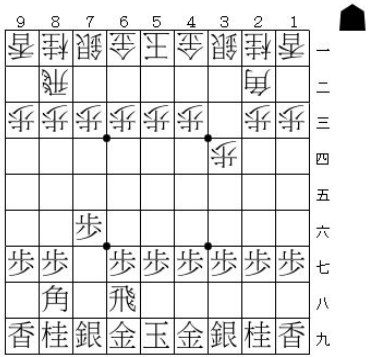

AlphaZero vs MuZero

MuZero派の主張：AIのモデルは基本的に大きいほど精度が高い。盤面の伝言ゲームを経ることでより高度な情報を抽出することができる

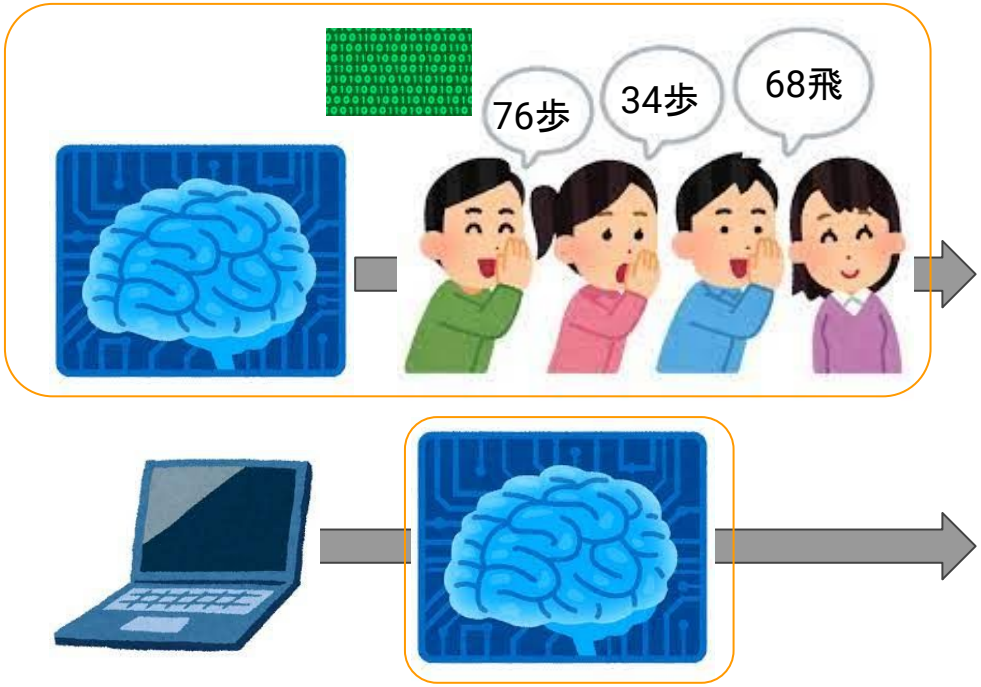

評価値を計算するまでに経由するAIの数が多い → より沢山の計算を行っている → 精度が高い

This suggests that MuZero may be caching its computation in the search tree and using each additional application of the dynamics model to gain a deeper understanding of the position.
(原著論文より引用)

実験してみる

- python-dlshogi2を改造してMuZero形式に対応した → 全然勝てなかった
  - 1手1秒で20連敗したあたりで心が折れた

- 原著論文ではMuZero同士の対局では1手800 simulation(800nodesに相当？)、elmoなどとの対局では1手0.1秒で対局したらしい
  - スレッド数などの条件は不明。というか、1手0.1秒っておま、WCSC27のelmoってなどとツッコミどころは絶えない
  - ディープ系列同士の対局は同じ局面に偏りがちなので初期局面をどうするの問題もあまり触れられていないように見える

勝率以外の指標でも評価してみる

MuZeroが内包している盤面を特徴量に変換する部分を切り出し、AlphaZeroと同じ挙動をさせたうえで、各々のモデルの盤面評価制度を比較する

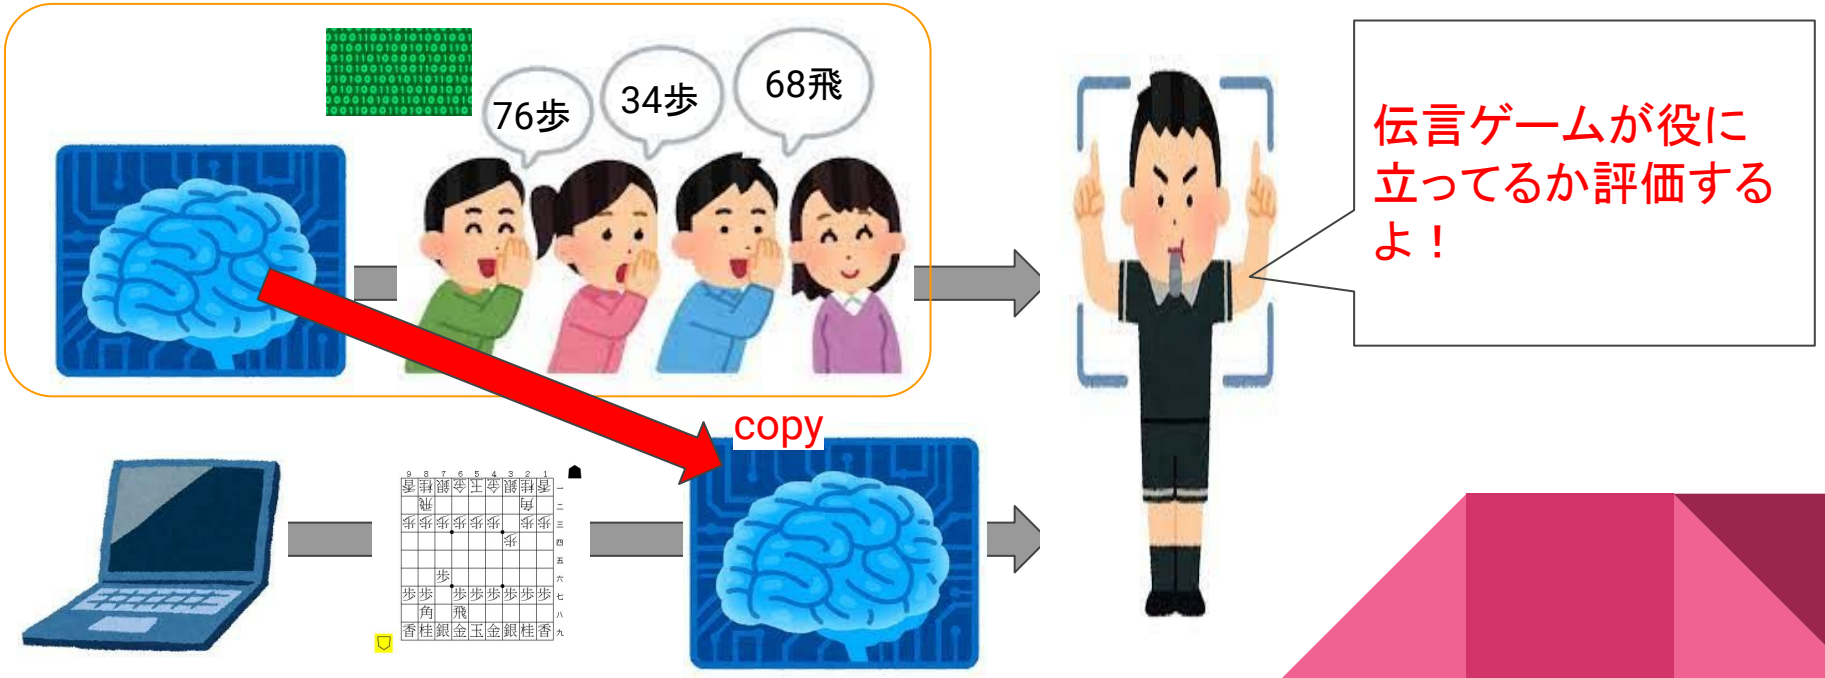

伝言ゲームの効果はあるのか

MuZero形式にすることで盤面評価精度が下がった

	MuZeroの一致率（伝言ゲーム5回後の一致率）	MuZeroから切り出したAlphaZero部分＋シミュレータの一致率
公開モデルからのfinetune	40.6%	53.1%
ゼロからの学習	35.3%	48.1%

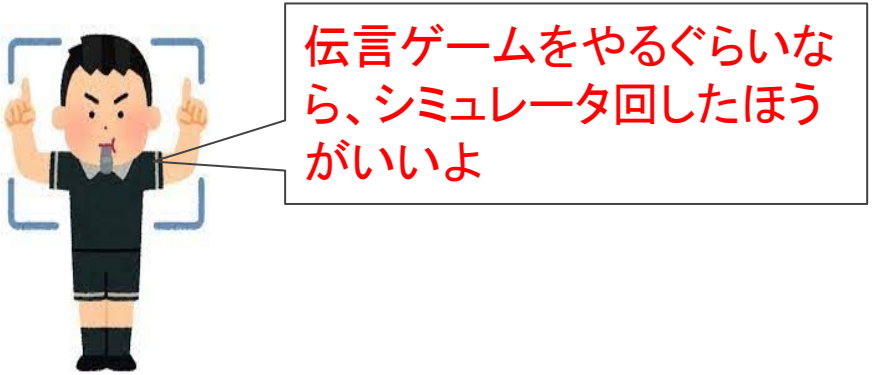

- train/validationはfloodgateの棋譜から生成したデータを利用（train:2000万、test:10万）
- MuZeroは「局面」ではなく「棋譜」のデータが必要で既存教師データを流用できない
- 教師の数としては正直頼りなくはある

原著論文と実験結果の違いに関する考察

AlphaZeroとMuZeroとでは学習環境が厳密には一致していない。伝言ゲームが足を引っ張っていたとしても他の部分で強くなっていた可能性がある

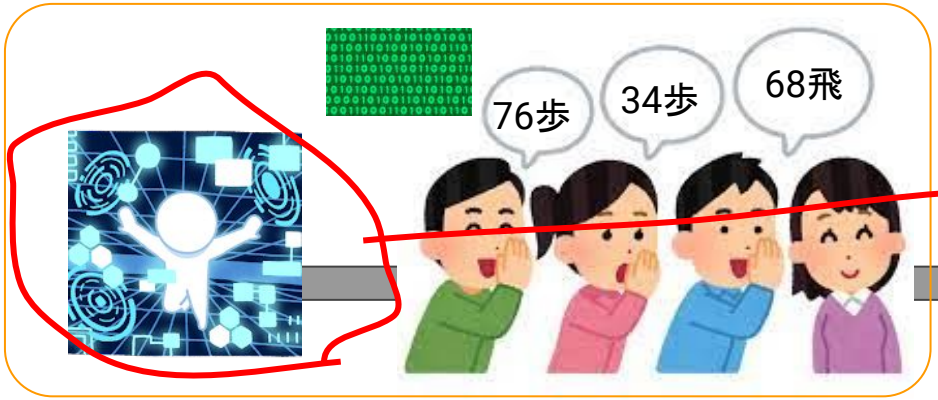

MuZero

MuZeroAlphaZeroより強いと言っても、ここが強くなっただけかもしれない

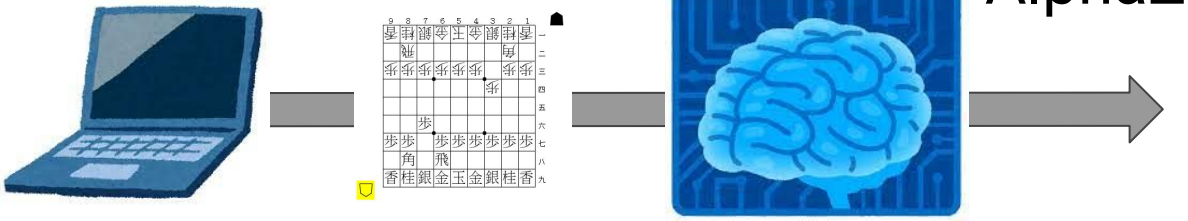

AlphaZero

（rsawadaの考える）原著論文の問題点

AI3号（原著論文でいうdynamics）が盤面評価の精度にどの程度影響を与えているかを評価するべきだった

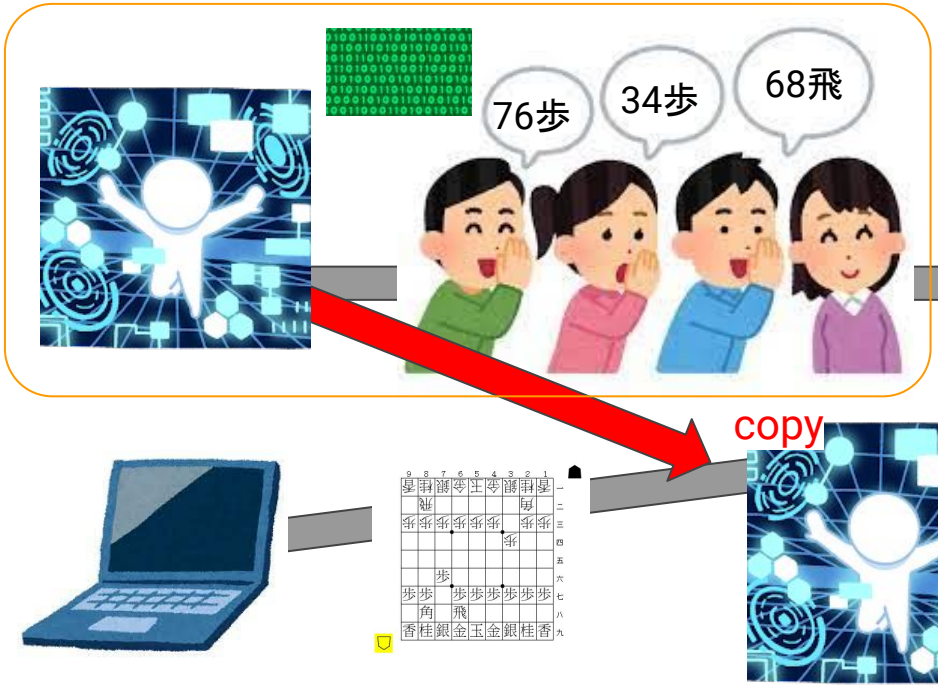

MuZeroはAlphaZeroを内包してるのだから出来るはず。つか、学習ログ解析すれば生成できるよね、論文のレフェリーは居眠りでもしてたの？

原著論文と実験結果の違いに関する考察（論文を擁護）

- そもそもrsawadaの再現実装が失敗している
  - 学習の条件に敏感な手法であるとか、教師の数が少ないとか
  - とくに、伝言ゲームのネットワークが浅すぎた（伝言ゲームがシミュレータの質を超えるにはある程度のlayer数が必要）はありそう

- シミュレータ不要であることが売りであり、そもそも強さは売りにしてない
  - 原著論文では囲碁でAlphaZeroより強いことをあまり推してない（かも）
    - いや、abstractでもガッツリ触れてるな

- 大会が終わったらソースコードを公開するので遊んでみて欲しい
  - ~~コメント内に書き込んだDM社への悪口を消さないと~~

困ったぞ、出すものがない

この時期にコンテンツが
何もないのは数年ぶりだ

- 今から頑張って飛車を振る
  - ~~負けても振り飛車のせいにできる~~
- 実況を頑張る
  - 実況ツールの公開もやらないと（linuxはともかく、windowsで動かない）
- 別に負けてもいいやとMuZeroを放り込む
  - これ面白いか……？
  - 教師データの生成から学習ルーチン、探索部まで創っておいてお蔵入りするのも癪だけど
  - ~~もう全部、論文のレフェリーが悪い~~