特集論文 「ネットワークが創発する知能」

局面ネットワーク特徴量とSVMを用いたHex評価関数の構築

Developing Evaluation Function of Hex using Board Network Characteristics and SVM

高田 圭
Takada Kei
北海道大学大学院情報科学研究科
Graduate School of Information Science and Technology, Hokkaido University
takada@complex.ist.hokudai.ac.jp

本庄 将也
Honjo Masaya
（同　上）
honjyo@complex.ist.hokudai.ac.jp

飯塚 博幸
Iizuka Hiroyuki
（同　上）
iizuka@complex.ist.hokudai.ac.jp

山本 雅人
Yamamoto Masahito
（同　上）
masahito@complex.ist.hokudai.ac.jp

keywords: board network, network characteristics, board game

Summary

The game of Hex is the board game with simple rules and is classified as a two-player, zero-sum, logical perfect information game. The game proceeds by putting their pieces in turn on empty cells of the board. A player wins if the player connects the two opposing sides of the board with their own color pieces. Our previous study clarified that it is effective to develop a computer Hex strategies with the network characteristics as the evaluation function to evaluate the board states from the global and local perspectives and showed that there is the best parameter to decide the ratio between global and local evaluation during a match. In order to go beyond the strategy, we hypothesize that the ratio must change during a match depending on the board states as human players differently evaluate the board states at the beginning, middle and final stages. First, we examine the hypothesis whether the better wining rate can be achieved by changing the ratio of global and local evaluation and propose a novel computer Hex program that can evaluate the board states while changing the global and local evaluation by recognizing the board states with SVM. Our proposed method is evaluated with the current world-champion program called MoHex.

1. はじめに

一般にボードゲームの盤は，駒等を配置するためのセルが規則的に近隣セルと接合することでネットワークをなしている．対局が進むことで，駒の追加や移動，セルの消滅が生じるため，盤上に自分と相手のそれぞれのネットワークが異なる形で形成される．代表的なボードゲームとしては，将棋やチェス，リバーシなどがあげられるが，これらは駒自体に価値があるゲームや，セルの位置によって価値が異なるゲームであるため，局面評価を行いやすいのでネットワークとして解析されることはない．駒とセルの価値が等価なゲームとしては囲碁や Hex があり，これらは局面評価が難しいため，ネットワーク化などにより局面の特徴を捉えることが有効である．

Hex は二人零和有限確定完全情報ゲームに分類され，1948年にJohn Nashが開発したボードゲームである [Browne 00]．使用する盤は六角形のタイルを n 行 m 列 (以後 $n \times m$) に敷き詰めたものであり，一般的に $n \times n$ の盤を使用する (図 1)．二人のプレイヤーは異なる色の石 (例えば黒と白) をもち，交互に石を打つことで対局を進行する．盤には二人のプレイヤーの色の対辺が存在し，黒プレイヤーは黒の対辺を，白プレイヤーは白の対辺をつなげたほうが勝利となる (図 2)．Hex の特徴として先手に必勝戦略が存在すること [Even 76]，引き分けが存在しないこと [Gale 79] などが知られている．具体的な必勝手順を求める研究と，必勝戦略が発見されていない大きな盤におけるコンピュータ Hex の研究が，Hex の主な研究対象である．

具体的な必勝手順を求める研究では，仮想リンクという概念の導入・発展により，人手 (計算機を使用しない) で 9×9 以下の盤での多数の初手に対する具体的な必勝手順を証明することが可能となった [三島 09]．また，人手のみではなく計算機も使用することで，2013 年には 9×9 以下のすべての盤面サイズで，すべての初手に対し

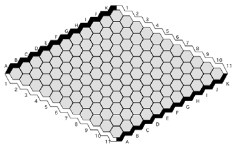

図 1　11 × 11 の盤

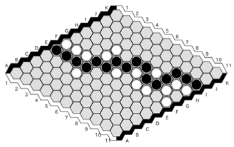

図 2　黒が勝利の局面

て必勝手順が証明されている [Pawlewicz 13].

より大きな盤サイズにおいては必勝手順は見つかっておらず，より強いコンピュータ Hex の開発のために，コンピュータ Hex の国際大会が開催されている．このコンピュータ Hex の開発研究では，局面評価のアルゴリズムやゲーム木の探索手法，枝刈り等の開発が行われており，各分野の発展に寄与してきた．2000 年の国際大会で，後述する仮想リンクの概念を導入したはじめてのコンピュータ Hex である Hexy が優勝したことにより，仮想リンクをコンピュータ Hex に導入することの有効性が示された [Anshelevich 00a, Anshelevich 00b]．2013 年の大会では仮想リンクや他の事前知識を導入している UCT(UCB applied to tree) 探索をベースにした MoHex[Huang 13] が優勝しており，著者らが開発した $\alpha\beta$ 法をベースとした EZO が準優勝している [Knuth 75, Hayward 13].

著者らは，先行研究において，局面をネットワークとしてモデル化を行い，媒介中心性や最短経路長などのネットワーク特徴量を用いた局面評価関数を作成し，局面をネットワークとして捉える有効性を示した [高田 14]．ネットワーク特徴量を用いた局面評価関数は，局所的評価と大域的評価をそれぞれ独立に行い，一定比率で 2 つの評価を組み合わせている．

本論文の目的は，ネットワーク特徴量で行う局所的・大域的評価の評価比率を対局中に動的に変化させることで，従来より優れた Hex 戦略をとるコンピュータ Hex の開発である．Hex 戦略では，対局序盤では局面を広い視点で捉え，対局中盤以降は勝敗に直結する部分を重要視することが有効であると予想できる．しかし，初手から最後まで同じ比率を用いることは，対局序盤，中盤，終盤においても局所的評価と大域的評価を同比率で同様に評価することを意味する．2 つの評価比率を一定にした対局の棋譜上の局面から，評価比率を変化させて対局を改めて行うことで，局所的・大域的評価の評価比率を動的に変化させることの有効性を明らかにする．また，評価比率を変化させることが有効な局面の特徴を複数のネットワーク特徴量で表現し，与えられた局面が評価比率を変化させるべきかどうかの識別器を SVM で作成する．SVM による識別器を使用することで，ネットワーク特徴量から局面の状態を認識し，対局中に動的に評価比率を変化するコンピュータ Hex の開発を行う．提案手法を，2011 年版の MoHex との対局により評価する．MoHex は 2011 年の優勝プログラムであり，それをベースにして更なる改良を行った 2014 年版においても，プログラムは公開されていないが世界一位を維持している．

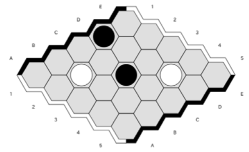

図 3　ネットワーク化の具体例

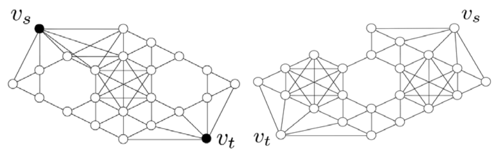

(a) 黒のネットワーク　(b) 白のネットワーク

図 4　図 3 の局面ネットワーク

2. Hex 局面のネットワーク化

本論文では，二人のプレイヤーを黒プレイヤーと白プレイヤーとし，黒プレイヤーが先手，白プレイヤーが後手とする．

Hex の任意の局面は，セルをノード，セル間の隣接関係をリンクとすることでネットワークで表現できることが知られている (図 3, 図 4)．ネットワーク化の利点は，局面の特徴を数値化して捉えることが可能になること，多数の視点から局面を分析できることである．局面ネットワークは各プレイヤーに対して作成され，黒プレイヤーの局面ネットワーク $G_B^b(V, E)$ と白プレイヤーの局面ネットワーク $G_W^b(V, E)$ が 1 局面から作成可能である．V はノード集合，E はリンク集合である．

2·1 仮想リンク

局面ネットワークを作成するにあたり，仮想リンクを付加する．仮想リンクとは，たとえその局面の手番が後手であっても，最善手を指せば数手先に必ず接続できる 2 つのセルまたはセル集合間に張られるリンクのことである．仮想リンク E は (x, A, y) と表記される．x, y は仮想リンクが張られる両端セル，またはセル集合であり，A は x と y を繋ぐ経路を構成するセル集合である．仮想リンクの多くは次の 2 つのルールを繰り返し適用することにより発見できる．ただし，空セルとは黒プレイヤー，または白プレイヤーに石が置かれていないセルのことである．

AND Deduction Rule

仮想リンク (x, A, u) と仮想リンク (u, B, y) があるとき，u が自分の色のセルかセル集合であり，$A \cap B = \phi$ ならば $(x, A \cup B, y)$ もまた仮想リンクである (図 5(a)).

OR Deduction Rule

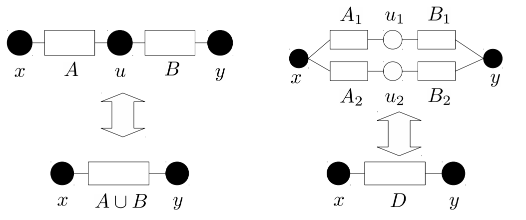

(a) AND Deduction Rule　(b) OR Deduction Rule

図 5　仮想リンクの発見手法

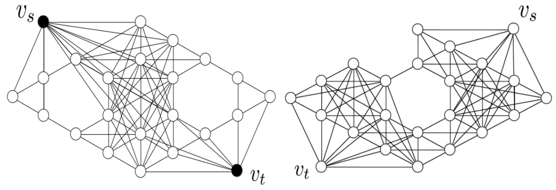

(a) $G_B^b(V,E)$　(b) $G_W^b(V,E)$

図 6　仮想リンクを付加した図 3 の局面ネットワーク

仮想リンク (x, A_k, u_k) と仮想リンク (u_k, B_k, y) があるとき，すべての k に対して，u_k が空セルであり，以下の条件をすべて満たすならば，(x, D, y) もまた仮想リンクである (図 5(b)).

$$(x \cap A_k = \phi) \text{ かつ } (y \cap B_k = \phi) \ \ \text{(for all k = 1,2,...,n)}$$
$$A_k \cap B_k = \phi \ \ \text{(for all k = 1,2,...,n)}$$
$$C_k = A_k \cup u_k \cup B_k$$
$$D = \bigcup_{k=1}^{n} C_k$$

上記の 2 つのルールを繰り返し適用し，多数の仮想リンクを発見するアルゴリズムとして H-search が提案されている [Anshelevich 02]．H-search で発見できない仮想リンクが存在することも知られており，H-search では発見できない仮想リンクのパターンが公開されている [Henderson 10b, King 14]．本論文では仮想リンクの作成方法として，H-search と公開されている仮想リンクのパターンをパターンマッチにて作成する．

2·2　局面のネットワーク化のアルゴリズム

Hex の任意の局面をネットワークとして表現するにあたり，セル i をノード v_i，ノード集合を V，リンク集合を E とする．ノードの状態を表す関数 C を定義する．C は，セル i が空セルなら $C(v_i) = 0$，セル i に黒プレイヤーの石があるなら $C(v_i) = 1$，白プレイヤーの石があるなら $C(v_i) = -1$ とする．また，自分の色の対辺をそれぞれノード v_s, v_t として，黒プレイヤーは $C(v_s) = 1, C(v_t) = 1$，白プレイヤーは $C(v_s) = -1, C(v_t) = -1$ とする．

Hex の任意の局面の $G_B^b(V,E)$ と $G_W^b(V,E)$ の作成方法を記す．$G_B^b(V,E)$ と $G_W^b(V,E)$ はプレイヤーを反転することで作成可能であるため，以下では黒プレイヤーの局面ネットワーク $G_B^b(V,E)$ の具体的な作成手順を示す．また，下記の局面ネットワーク作成は，各局面に対して行われる．

(1)　盤面上で隣接関係にあるすべてのノード v_i, v_j 間にリンク $e(v_i, v_j)$ を追加する．

(2)　一方の辺に隣接しているすべてのノード v_i と v_s 間にリンク $e(v_i, v_s)$ を追加する．その対辺に隣接しているすべてのノード v_j と v_t 間にリンク $e(v_j, v_t)$ を追加する．

(3)　白のノード $v_i(C(v_i) = -1)$ とノード v_i を含むリンク $e(v_i, v_j)$ を除去する．

(4)　この状態のネットワーク $G^b(V,E)$ に H-search アルゴリズム，パターンマッチを適用し，発見した仮想リンクをリンク集合 E に追加する．

局面ネットワークの例として，図 3 の局面ネットワークが図 6 である．仮想リンクを付加しているため，数手先の情報をもつ局面ネットワークとなる．また，局面ネットワーク上では Hex の勝敗を (v_s, v_t) 間に直接リンクがあるかどうかで判断可能であり，直接リンクがある局面ネットワークをもつプレイヤーが勝利となる．

2·3　ネットワーク特徴量を用いた局面評価

局面ネットワークから，ネットワーク特徴量を用いて局面の大域的評価と局所的評価を独立して行い，2 つを組み合わせることが有効であることが明らかになっている [高田 14]．ネットワーク特徴量を用いた先手 (黒プレイヤー) の局面評価関数 E_v は下記で定義される．

$$E_v = \frac{C_W}{C_B} + \gamma \frac{C'_W}{C'_B}, \tag{1}$$

C_B は局面ネットワーク $G_B^b(V,E)$ の平均媒介中心性であり，C_W は $G_W^b(V,E)$ の平均媒介中心性である．C'_B は $G_B^b(V,E)$ における (v_s, v_t) 間の最短経路のみで構成される最短経路ネットワーク内で，(v_s, v_t) 間の最短経路のみを考慮した媒介中心性の最大値である．同様に C'_W は $G_W^b(V,E)$ の (v_s, v_t) 間の最短経路ネットワーク内の媒介中心性の最大値である．

ノード v_i の媒介中心性 b_i は下式で計算され，平均媒介中心性は全ノードの平均値，最短経路ネットワークの媒介中心性は (v_s, v_t) 間の最短経路のみを考慮して計算する．

$$b_i = \frac{2}{(N-1)(N-2)} \sum_{k=1}^{N} \sum_{j=1}^{N} g(v_i, v_k, v_j), \tag{2}$$

N はノード数である．$g(v_i, v_k, v_j)$ はノード v_i が，v_k と v_j の最短経路に含まれているかを判断する関数であり，含まれている場合は 1，それ以外は 0 を返す．ただし，$v_i =$

v_k，$v_j = v_k$ もしくは $v_i = v_j$ のときは $g(v_i, v_k, v_j) = 0$ となる．

C_B，または C_W が小さい局面は，黒または白プレイヤーが局面内に多数の経路をもつことを意味するため，局面全体に幅広い戦略をもつ局面である．また，C'_B，または C'_W が小さい局面は，黒または白プレイヤーが勝敗に直結する (v_s, v_t) 間の経路に多様性をもつ局面であるため，勝敗に直結する戦略に幅がある局面である．C_W/C_B が局面全体を考慮する大域的評価の項であり，C'_W/C'_B が勝敗に直結する局所的評価を行う項である．E_v が大きいほど黒プレイヤーに，小さいほど白プレイヤーに有利な局面である．γ は任意定数であり，γ の値によって 2 つの評価比率が変化する．

3. 局所的局面評価と大域的局面評価の切り替え

Hex 戦略において，対局序盤では局面全体を見渡して戦略の幅を広げる大域的な戦略をとり，対局が進むにつれ，勝敗が直結する一部分を重要視して勝利を目指す局所的な戦略をとることが有効であると予想される．E_v の γ を大きくすることで，局所的評価をより考慮することが可能であるため，対局中に γ を大きくすることで前述の戦略をとることが可能である．E_v の γ を対局途中に大きくすることが，対局中固定にしているものに比べ優れていることを確認することで，対局中に局所的評価をより考慮する評価関数に変更することが有効であるかどうかを明らかにする．

E_v を局面評価関数とし γ を固定したコンピュータ Hex は，現在世界一位の MoHex と対局させると，多くの対局で勝利できるが，敗北する対局が存在する．敗北する対局の棋譜上に現れる局面を利用し，敗北する対局の途中から γ を大きくして改めて対局を行うときに，勝利できるならば，対局中に γ を大きくすることで，より優れた Hex 戦略をとることが可能になる．

3·1 γ を対局中一定にした際の MoHex との対局

E_v を局面評価関数，ゲーム木探索として $\alpha\beta$ 法を採用するコンピュータ Hex(以後 CH_{E_v} とする) と，MoHex との対局を行う．MoHex は 2009 年から現在まで世界 1 位のコンピュータ Hex であり，UCT 探索をベースにしているため，評価関数型とは異なり着手が一意に定まらない．MoHex は [http://benzene.sourceforge.net/] から手に入れた 2011 年版であり，探索時間は 10 秒となっている．

ゲーム木探索に用いる $\alpha\beta$ 法は Minimax 法の高速化手法である [Knuth 75]．Minimax 法では深さ 1 では 1 手先，深さ 2 では 2 手先に想定される全局面を評価するため，評価局面数は深さに応じて指数的に増加する．$\alpha\beta$ 法は Minimax 法と同じ探索結果になるが，Minimax 法に効率的な枝刈りを導入することで，短時間で探索が可能となる．

対局の勝敗判定には，DFPN(Depth First Proof Number) 探索アルゴリズムを使用する [Arneson 11]．DFPN 探索アルゴリズムは詰め将棋で発展したアルゴリズムであり，高速にゲーム木探索を行うことで，必勝手順を探索するアルゴリズムである．DFPN 探索を 10 秒行い，必勝手順を指せば勝利できるプレイヤーを勝利プレイヤーとする．DFPN 探索を使用することで，実際に勝敗がつく前に勝敗を判定することが可能である．使用している DFPN 探索アルゴリズムは MoHex と同様 [http://benzene.sourceforge.net/] から手に入れたものである．

対局条件は下記のとおりである．

- 11×11 の盤を使用する
- CH_{E_v} は深さ 2 の $\alpha\beta$ 探索を行う
- CH_{E_v} が先手，MoHex が後手であり，100 対局行う
- $\gamma = 0.1$ であり，対局中固定である
- MoHex の探索時間は 10 秒である
- 勝敗判定は DFPN 探索を 10 秒間行い，決定する

深さ制限は探索時間を考慮したものであり，探索時間は 11×11 盤の初手で，深さ 2 のとき約 40 秒，深さ 3 のとき約 714 秒となっているため，深さ 2 とした．使用した計算機は，Phenom II X6(コア数 6，クロック周波数 2.9GHz) を使用している．$\gamma = 0.1$ は γ 固定時における最適パラメータとは限らないが，予備実験から，他の γ に比べて遜色ないパラメータであることは確認済みである．

対局結果は，CH_{E_v} の勝率が 82% となった．次節で，敗北した 18 対局に対して，γ を大きくすることによる対局への影響を明らかにする．

3·2 MoHex との対局で敗北した対局の分析

$\gamma = 0.1$ に固定した CH_{E_v} と MoHex との対局で CH_{E_v} が敗北した 18 対局について，対局中に局所的評価をより考慮する評価関数への変更，つまり γ を大きくすることによる対局への影響を分析する．18 対局内にまったく同じ棋譜が存在するため，同じ棋譜は 1 つの対局として扱い，計 16 対局を分析する．

盤に石が偶数個置かれている局面を棋譜内の局面から抽出し，抽出した局面から，$\gamma = 0.1$ と $\gamma = 1.0$ で固定した CH_{E_v} でそれぞれ 10 対局行う．盤に石が偶数個置かれている局面は次手が先手 (CH_{E_v}) である．つまり，盤に石が偶数個置かれている局面から上記の対局を行うことは，記譜上に現れる CH_{E_v} の手番すべてに対して，γ を 0.1 と 1.0 のどちらで対局を進めることが有効なのかを検証することになる．

3·3 分 析 結 果

各局面から $\gamma = 0.1$ で固定したときの CH_{E_v} の勝利回数を $R_{0.1}$，$\gamma = 1.0$ で固定したときの CH_{E_v} の勝利回数を $R_{1.0}$ とする．$R_{0.1}$ と $R_{1.0}$ の差 R $(-10 \leq R \leq 10)$ を

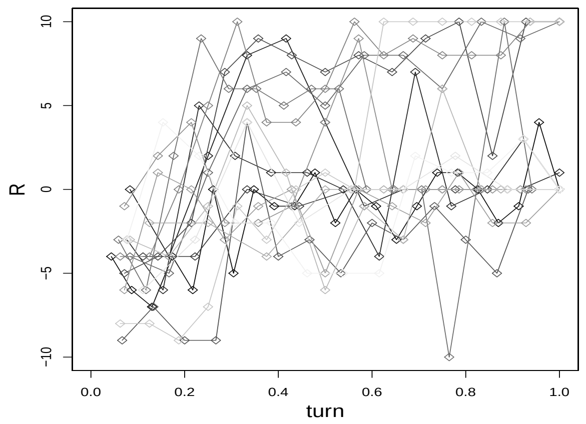

図 7　R の推移

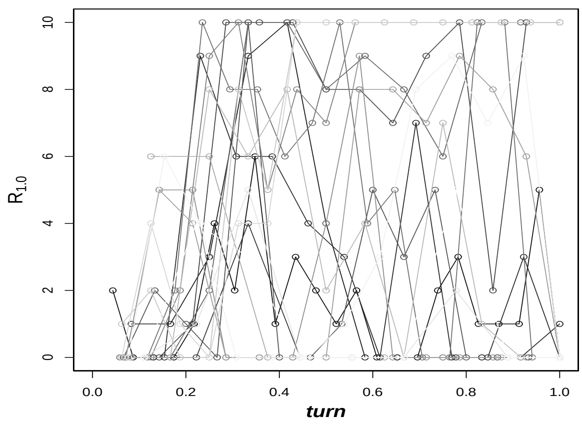

図 8　$R_{1.0}$ の推移

下記で定義する．

$$R = R_{1.0} - R_{0.1}, \tag{3}$$

R が大きい局面は，R が大きくなる局面までの対局を $\gamma = 0.1$ で行い，それ以降 $\gamma = 1.0$ で対局を行うことで，$\gamma = 0.1$ に固定していたときより優れた Hex 戦略をとることが可能になる局面である．つまり，局所的評価の影響度を対局中に増加することで，固定時よりも優れた Hex 戦略をとることが可能になる局面である．R が小さい局面は，$\gamma = 1.0$ にすることで対局に悪影響を与える局面であり，$\gamma = 0.1$ の固定のまま対局すべきである局面である．$R = 0$ のときは，γ を変更してもしなくても変化がない局面である．

R を縦軸，横軸をターン数として示したのが図 7 である．横軸は各ターン数を対局の終了ターン数で正規化している．対局序盤では，R が 0 より小さいことが確認できるため，対局中 γ を固定にするならば，$\gamma = 0.1$ のほうが優れていることが分かる．対局中盤以降では R が大きい局面が確認できる．$R = 10$ の局面は，本来敗北する対局でも，$\gamma = 1.0$ に上げることにより，10 対局中 10 対局勝利することが可能になる局面であり，$\gamma = 0.1$ の固定のままでは勝利することが難しい局面である．

以上から，序盤には局所的評価の影響度を大きくしないほうが良いこと，および，局所的評価の影響度を大きくすることで勝利可能な局面が多数存在することが明らかになった．

4.　γ を大きくすることが有効な局面の分析・分類

図 7 より，R が大きい局面，つまり局所的評価をより考慮することが有効な局面が存在することが確認できた．しかし，3 章でわかることは，対局中に γ の値を 0.1 のまま固定したときと 1.0 に変更するときでは，1.0 に変更したほうが勝率が上昇することがあるというだけで，いつ，どのようなときに γ を大きくすべきかは不明のままである．γ を大きくすることが有効である局面の特徴を複数のネットワーク特徴量から同定し，γ を大きくするべき局面であるかどうかを分類する識別器を設計する．

4·1　分析するネットワーク特徴量

R が大きい局面の特徴を捉えるために各プレイヤーの，局面ネットワークの平均媒介中心性 C_B, C_W，(v_s, v_t) 間の最短経路長 d_B, d_W，(v_s, v_t) 間の最短経路ネットワーク内の媒介中心性の最大値 C'_B, C'_W に注目する．

それぞれのネットワーク特徴量により捉えられる特徴は，平均媒介中心性が大域的に戦略の幅が広いかどうか，(v_s, v_t) 間の最短経路長がどれほど勝利に近づいているか，最短経路ネットワーク内の媒介中心性の最大値が勝敗に直結する局所的戦略の幅が広いかどうかである．これらの特徴をもつネットワーク特徴量を二人のプレイヤーの局面ネットワークに対して独立して計算することで，片方のプレイヤーが他のプレイヤーに比べて，どの程度良い特徴をもつ局面なのかを分類できる．また，Hex では対局が進むにつれて盤に置かれている石が増加することから，局面ネットワークのノード数が減少していくため，対局が進むことによるネットワーク特徴量の変化が生じる．対局が進むことで生じる自然な特徴量の変化も含まれるため，対局の進み具合も 6 つの特徴量で分類できる．

4·2　分 類 す る 局 面

γ を大きくするべき局面は，対局途中に $\gamma = 1.0$ にすることで，高い勝率を得られる局面であるため，3.3 節の $R_{1.0}$ に注目する．$R_{1.0}$ は，与えられた局面から $\gamma = 1.0$ に固定して対局を行ったときの 10 回中の勝利回数である．$R_{1.0}$ の推移を図 8 に示す．図 8 の $R_{1.0}$ が 9 以上，勝率 90%以上の局面を $\gamma = 1.0$ に変更するべき局面とする．

表 1 各コンピュータ Hex の先手の勝率

	提案手法	$CH_{E_v}(\gamma = 0.1)$	Wolve	MoHex
提案手法 (先手)	100%	100%	100%	93%
$CH_{E_v}(\gamma = 0.1)$(先手)	100%	100%	0%	82%
Wolve(先手)	100%	100%	100%	78%
MoHex(先手)	90%	92%	50%	84%

4·3 SVM による分類

高精度な二値分類器として，サポートベクタマシン (Support Vector Machine, SVM) が知られている [Cortes 95]．SVM は機械学習における教師あり学習の 1 つであり，学習用データと学習用データのラベルをセットに学習することで，未知のデータに対応するラベルを推定するものである．

本論文では，探索局面が γ を 0.1 から 1.0 に変更するべきかどうかの分類を行う．1 局面から，上記 6 つのネットワーク特徴量を計算し，6 次元の特徴ベクトルを作成する．図 8 の $R_{1.0} \geq 9$ の局面の特徴ベクトルを $\gamma = 1.0$ と対応付け，それ以外の局面の特徴ベクトルを $\gamma = 0.1$ と対応付けて SVM の学習を行う．$R \geq 9$ を満たす局面は，局所的評価をより考慮することで高い勝率となる局面，つまり数手で対局の決着がつく可能性がある局面である．$R_{1.0} \geq 9$ を満たす局面は 55 局面，それ以外の局面が 187 局面であるため，合計 242 局面の特徴ベクトルで SVM の学習を行う．SVM の学習は，統計解析ソフト R の “kernlab”ライブラリを使用し，カーネル関数を用いた非線形分類で行う．学習した結果，学習データに対する識別率は 90.7%である．

5. 数値計算実験

4 章の SVM で作成した識別器を使用し，対局中に動的に γ を変更するコンピュータ Hex の開発を行い，γ を固定した CH_{E_v} と，従来のネットワーク特徴量を使用しない局面評価関数を利用したコンピュータ Hex との比較を行う．

5·1 提 案 手 法

提案するコンピュータ Hex は，(1) 式で示した E_v を局面評価関数とし，深さ 2 の $\alpha\beta$ 法によるゲーム木探索を行う．E_v の γ は $\gamma = 0.1$ から開始し，探索開始時に探索局面のネットワーク特徴量を計算し，識別器が $\gamma = 1.0$ を出力したら γ を 1.0 に変更する．γ を 1.0 に変更した後は，その値で一定とする．

5·2 実 験 条 件

4 つのコンピュータ Hex を用いて性能比較を行う．使用するのは，提案手法，γ を 0.1 に固定した CH_{E_v}，ネットワーク特徴量を使用しない局面評価関数を使用したコンピュータ Hex である [Henderson 10a]，および，MoHex である．Wolve の局面評価関数は局面全体を電気回路として捉える手法であり，全体の抵抗値を評価値として扱う．この局面評価関数は 2000 年優勝の Hexy，2006 年優勝の Six[Hayward 09] なども採用しているものであり，従来使用されている最も優れた局面評価関数である．Wolve は 2008 年に国際大会で優勝しており，使用する Wolve は，MoHex と同様 [http://benzene.sourceforge.net/] から手に入れた 2011 年版である．MoHex 同様，Wolve の探索時間は 10 秒以内である．Wolve は Minimax 法の発展形である反復深化深さ優先探索をゲーム木探索として用いる．また，Hex 特有の知識，パターンマッチを利用して効率的な枝刈りを行うことで，10 秒の探索で深さ 3 以上の探索を可能にしている．

実験条件は下記のとおりである．局面評価関数を用いたコンピュータ Hex は，常に局面に対して一意に手が定まりこれらの対局結果は毎回同じになるため，提案手法，CH_{E_v}，Wolve 同士は各 1 対局しか行わない．

- 11×11 の盤を使用する
- 局面評価関数を用いたコンピュータ Hex 同士は各 1 対局行う
- MoHex と他のコンピュータ Hex の対局は各 100 対局行う
- MoHex,Wolve の探索時間は 10 秒である
- 勝敗判定は DFPN 探索アルゴリズムを用いる

局面評価関数 E_v は，先手/後手にかかわらず評価値の最大化を各プレイヤーにとって最良とするために，先手 (黒) の場合は (1) 式を使用し，後手 (白) の場合は (1) 式の分母と分子を入れ替えた局面評価関数を用いる．

5·3 実 験 結 果

実験結果を表 1 に示す．提案手法の先手では，CH_{E_v} と Wolve に勝利できており，MoHex に対しても最も高い勝率が得られていることがわかる．提案手法が先手，MoHex が後手の対局において，γ を対局中に変化させた対局は，100 対局中 67 対局である．γ を変更させた 67 対局中 65 対局で MoHex に勝利し，2 対局で敗北している．また，γ を変更しなかった 33 対局中 28 対局が MoHex に勝利し，5 対局が敗北している．この結果から，SVM に使用したネットワーク特徴によって，正しく γ を変更すべき局面を同定することができ，勝率が上昇していることがわかる．提案手法の後手においても，γ を固定した CH_{E_v} に比べて MoHex に対する勝率が上昇しており，勝利した 10 対局中 4 対局で γ を変更して勝利している．

5·4 考 察

本研究では，$\gamma = 0.1$ で固定した CH_{E_v} で MoHex と対局を行い CH_{E_v} が敗北した対局の局面を特徴ベクトルで表して，SVM により局面の識別器を作成した．γ を大きくすべきかどうかの識別器について 2 つの考察を行う．

1 つ目は訓練データとして用意する局面に，特徴の偏りがある点についてである．図 7 の対局中盤以降において，R が小さい局面，局所的評価をより重要視することが対局に悪影響を与える局面が少ないことがわかる．的確に局面を分類するためには，多数の特徴的な局面から分類器を作成する必要があるため，γ を大きくすることが悪影響を与える局面も用意する必要がある．MoHex との対局で敗北した棋譜のみを分析するのではなく，勝利する棋譜に対しても同様の手順で分析を行い，γ を上げることが悪影響を与える局面を学習用データとして用意し SVM で学習を行うことで，より的確に局面を分類できる分類器を作成できることが期待できる．

2 つ目は，γ を上げることが有効な局面には，使用した 3 つのネットワーク特徴量では捉えきれない特徴が存在する可能性についてである．本研究で SVM を行うために用意した局面の特徴を表す 6 次元特徴ベクトルでは，大域的な戦略の幅，局所的な戦略の幅，勝敗が決定するまでの近さ，対局の進み具合を捉えることが期待できる．しかし，大域的な特徴を捉えるために平均媒介中心性を使用しているため，各ノードの媒介中心性を平均化してしまうため，媒介中心性の分布などの失われている局面特徴も存在する．局面をネットワーク化する利点を利用して，他のネットワーク特徴量を用いて多様な視点から局面の特徴を捉えることができれば，局面の特徴をより正確に捉えることができると期待できる．

実験で先手の提案手法が敗北した対局では，γ を大きくせずに敗北した対局が 5 対局，動的に変化させたにもかかわらず負けた対局が 2 対局である．これらの敗北した対局では，γ によらず敗北する対局であることが考えられる他に，前述した 2 点から，γ を大きくするべき局面で大きくできなかったことや，大きくしてはならない局面で大きくしてしまったことなどが考えられる．

本論文では，提案手法が先手である場合を想定した分析をしている．先手を想定した分析だが，局所的評価関数 E_v は先手/後手を同等に評価する局面評価関数であるため，先手で局所的評価をより考慮することが有効であることは，後手も同様である．実際に表 1 の実験結果から，先手/後手両方で提案手法が γ を対局開始から終了まで固定するのに比べて高い勝率が得られており，γ を変更して勝利した対局が存在するため，後手においても対局中に局所的評価の影響度を大きくすることが有効であることも示されている．

従来手法との比較においては，提案手法は先手で Wolve より高い勝率が得られている．Wolve は Hex の知識やパターンマッチなどを利用し 10 秒以内で，深さ 3 以上の探索が可能であるため，提案手法より先読みした局面を評価している．それよりも高い勝率を示すことは，局面評価に電気回路として捉える手法に比べて，局面をネットワークとして捉えることがかなり有効であることがわかる．これは，局面ネットワークからネットワーク特徴量を用いることで，多様な視点からの局面の分析，特徴の数値化ができるためであると考えられる．しかし，提案手法の後手では MoHex に対して Wolve ほどの勝率が得られていないが，これは適切な γ が先手/後手で異なるためである．先手の戦略は必勝手順が存在する局面から，必勝手順からはずさない手を打ち続けることであり，後手の戦略は，先手に必勝手順がある局面からいかに先手にとって難しい局面に推移させるかであるため，根本的に先手の戦略と後手の戦略は異なる．後手で最適な γ を発見することで，勝率が高くなることは十分期待できる．

本研究では，$\gamma = 0.1$ から対局を開始し，より局所的評価を考慮する値として $\gamma = 1.0$ を用いている．$\gamma = 0.1$ は，対局開始から終了まで γ を固定した場合に最適なパラメータである．$\gamma = 1.0$ は，大域的評価と局所的評価を同じ割合で評価するのではなく，大域的/局所的評価では値の分布が異なるため，$\gamma = 0.1$ よりは局所的評価を考慮する値を意味する．もし，γ をさらに大きくした場合は，最終的に局所的評価の項のみで次手が決定することになり，事前実験から，$\gamma = 0.1$ から対局を開始し途中で局所的評価のみで局面評価を行うのは対局途中から $\gamma = 1.0$ に変更するより低い勝率 (84%) になることが判明している．$\gamma = 0.1$ から大きくする値として $\gamma = 1.0$ 以外に最適な値がある可能性があるが，γ を大きくする際には，大域的/局所的評価両方を考慮する γ の値を選択する必要がある．

6. おわりに

ネットワーク特徴量を用いて大域的･局所的評価を行う局面評価関数について，局所的評価の影響度を決定するパラメータ γ を，対局中に動的に大きくするコンピュータ Hex の提案をした．γ を大きくすることが有効な局面を発見し，それらの局面の特徴をネットワーク特徴量を用いて特徴ベクトルで表した．局面の特徴ベクトルを用いて SVM で γ を大きくすべきかどうかの識別器を作成した．作成した識別器を使用し，対局中に動的に γ を大きくするコンピュータ Hex が，γ を対局中固定のコンピュータ Hex に比べて優れていることを示した．今後，学習用データとして扱う局面を多様化すること，他のネットワーク特徴量で局面の特徴を分析することを進め，さらに優れた Hex 戦略をとることが可能なコンピュータ Hex の開発を目指す．

◇参 考 文 献◇

[Anshelevich 00a] Anshelevich, V. V.: The game of Hex: An automatic theorem proving approach to game programming, *Proc AAAI-2000, Austin, TX, AAAI Press, Menlo Park, CA/The MIT Press, Cambridge* (2000)

[Anshelevich 00b] Anshelevich, V. V.: Hexy Wins Hex Tournament, *The ICGA Journal*, Vol. 23, No. 3, pp. 181–184 (2000)

[Anshelevich 02] Anshelevich, V. V.: A hierarchical approach to computer Hex, *Artificial Intelligence*, Vol. 134, No. 1-2, pp. 101–120 (2002)

[Arneson 11] Arneson, B., Hayward, R., and Henderson, P.: Solving Hex : Beyond Humans, *Conputers and Games 2010*, Vol. 6515 of LNCS, pp. 1–10 (2011)

[Browne 00] Browne, C.: *Hex Strategy:Making the Right Connections*, A K Peters Ltd (2000)

[Cortes 95] Cortes, C. and Vapnik, V.: Support vector networks, *Machine Learning*, Vol. 20, pp. 273–2971 (1995)

[Even 76] Even, S. and Tarjan, R. E.: A Combinatorial Problem Which Is Complete in Polynomial Space, *Journal of Assocuation for Computing Maxhinery*, Vol. 23, No. 4, pp. 710–719 (1976)

[Gale 79] Gale, D.: The Game of Hex and the Brouwer Fixrd-Point Theorem, *The American Mathematical Monthly*, Vol. 75, No. 10, pp. 818–827 (1979)

[Hayward 09] Hayward, R., Arneson, B., and Henderson, P.: Mohex wins hex tournament, *The ICGA Journal*, Vol. 32, No. 2, pp. 114–116 (2009)

[Hayward 13] Hayward, R., Arneson, B., and Huang, S.: Mohex Wins Hex Tournament, *The ICGA Journal*, Vol. 36, No. 3, pp. 180–183 (2013)

[Henderson 10a] Henderson, P.: Playing and solving the game of Hex, *Doctoral Dissertation*, pp. 1–149 (2010)

[Henderson 10b] Henderson, P., Arneson, B., and Hayward, R.: Hex, braids, the crossing rule, and XH-search, *Advances in Computer Games Lecture Notes in Computer Science*, Vol. 6048, pp. 88–98 (2010)

[Huang 13] Huang, S., Arneson, B., Hayward, R., Miller, M., and Pawlewicz, J.: MoHex2.0 : A Pattern-Based MCTS Hex Player, *Computer and Games*, pp. 60–71 (2013)

[King 14] King, D.: *Hall of Hexagons*, http://www.drking.org.uk/hexagons/hex/index.html (2014)

[Knuth 75] Knuth, D. and R.W.Moore, : An analysis of alpha-beta pruning, *Artificial Intelligence*, pp. 293–326 (1975)

[Pawlewicz 13] Pawlewicz, J. and Hayward, R.: Scalable Parallel DFPN Search, *Computers and Games* (2013)

[高田 14] 高田 圭, 本庄 将也, 飯塚 博幸, 山本 雅人：ネットワーク指標を用いたコンピュータ Hex 戦略の開発, 情報処理学会論文誌, Vol. 55, No. 11, pp. 2421–2430 (2014)

[三島 09] 三島 建：Hex の必勝手順に対する新証明技法について, 情報処理学会論文誌, Vol. 50, No. 2, pp. 893–903 (2009)

〔担当委員：山本 仁志〕

2014 年 10 月 7 日 受理

著 者 紹 介

高田 圭

1992 年生. 2014 年北海道大学工学部情報エレクトロニクス学科卒業. 同年, 同大学院情報科学研究科修士過程入学. 専門はコンピュータプログラミング. 情報処理学会 会員.

本庄 将也

1987 年生. 2010 年北海道大学工学部情報エレクトロニクス学科卒業. 2012 年同大学院情報科学研究科修士課程修了. 同年, 同大学院博士後期課程入学. 複雑ネットワーク, オペレーションズ・リサーチの研究に従事. 精密工学会 会員.

飯塚 博幸（正会員）

2004 年東京大学大学院総合文化研究科博士課程修了 (博士 (学術)). 2005 年日本学術振興会特別研究員 (PD, はこだて未来大学) , イギリスサセックス大学客員研究員, 2008 年大阪大学大学院情報科学研究科 助教. 2013 年北海道大学大学院情報科学研究科 准教授. 専門は人工生命, 複雑系科学, 人間情報工学.

山本 雅人（正会員）

1968 年生. 1996 年北海道大学大学院工学研究科システム情報工学専攻博士後期課程修了. 同年, 日本学術振興会特別研究員 (PD). 1997 年北海道大学大学院工学研究科助手. 2000 年同大学院工学研究科助教授. 同大学院情報科学研究科助教授, を経て 2012 年同大学院教授. この間, 科学技術振興機構さきがけ研究員, デューク大学客員研究員. 博士 (工学). ゲームプログラミング, 複雑ネットワークの研究に従事. 情報処理学会, 計測自動制御学会, などの各会員.