ゲーム情報学 3－5
(2000. 5. 31)

ゲームのフラクタル仮説

―ゲームの面白さとは？―

吉井　裕人

概要

本論文では、ゲームのフラクタル仮説というゲームの構造にかんする仮説を提出する。この仮説を元に、ゲームが面白いとはどういうことか？について議論していく。以前行った囲碁に関するパターンの統計研究をレビューし、心理学実験の方針について提案を行う。

キーワード：フラクタル、ゲーム、囲碁

Fractal Hypothesis of Game

-What is the cause of interest in game?-

Hiroto Yoshii

Abstract

In this paper, we propose "Fractal Hypothesis of Game". Based on the hypothesis, we argue what the cause of interest in game is. The research about pattern analysis in Go is reviewed and an example of psychological experiment is introduced.

Key words：Fractal, Game, Go

1　はじめに

囲碁、将棋、チェスなどのボードゲームは世界のインテリの心を捉えて離さない。これらのボードゲームは完全情報ゲームとか、確定的ゲームとか呼ばれるゲームで、時間はかかるが、全ての手を読むことが可能である。つまり、任意の局面が与えられたとき、ゲームの神様（人間よりはるかに強い人）ならば、どちらが勝つかを的確に答えることができる。もしゲームの神様同士が対局をしたとすると、ゲームの最初で先手と後手のどちらが勝つかがわかるので、彼ら（神様）にとっては、これらのボードゲームは非常につまらないものになるだろう。(もっとも、つまるか／つまらないか、がこの論文の論点なのだが...)

こういう話しをすると、囲碁や将棋のプロは、さぞかしつまらないだろうと誤解してしまう人

がいるかもしれない。ところが、第一線で活躍しているプロはよく、「面白くてたまらない」とか「研究すればするほど、わからなくなる」とか言うのである。これに対して、場合の数の多さをもって、「人間にとっては事実上無限の探索空間があるから、これらのボードゲームはいつまでたっても未知の局面が現れ、面白いのだ。」という議論がある。しかし、プロでもわからないような難しいゲームをヘボな素人がやって、いったい本当に面白いのだろうか？やったことのある方はわかると思うが、囲碁、将棋、チェスといったボードゲームは、上達のどの段階にあっても、非常に面白いのである。では、この面白さはどこからくるのであろうか？この答えを次に述べる“ゲームのフラクタル仮説”で説明したいと思う。

2　ゲームのフラクタル仮説

まず、最初に仮説を述べる。

「ゲームの中で出現する局面の難しさを横軸、その難しさより難しい局面の数を縦軸にしてグラフを書くと、べき乗分布（フラクタル分布）になる」そして「この分布の性質が、任意の習熟度の人に対して常にゲームが面白い原因である」

皆よく体験していると思うが、講演で眠くなる時は、発表者の話しが難しすぎてわからない時か、やさしすぎて先が読める時である。予想できないような展開が含まれながらも、ちゃんと理解できる講演は聴衆の好奇心を引き付ける。これと同じように、ゲームの中で難しすぎる局面が続くといやになるし、やさしすぎる局面が続いてもいやになる。程ほどに難しい局面があるが、“ここはこの一手”という局面もちゃんと存在するようなゲームが面白いのである。この状況を具体的に表現したのが、上記のゲームのフラクタル仮説である。

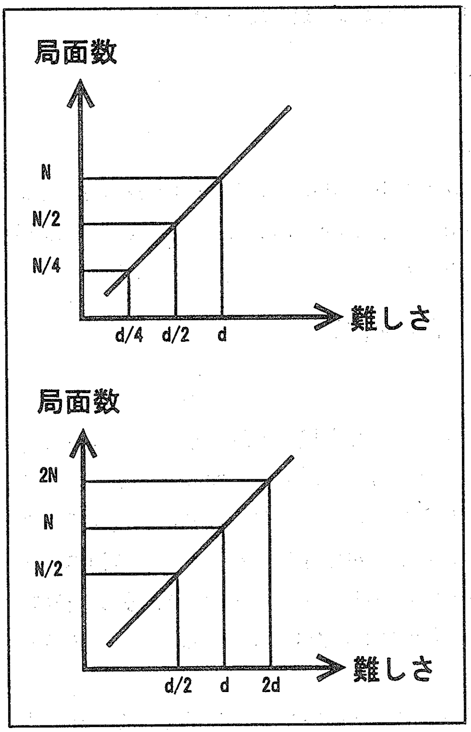

グラフを使ってこの仮説を説明しよう。左に示した2つのグラフは、それぞれ一級の人と初段の人の感じる難しさと局面数のグラフとする。一級の人の手が見える限界は、難しさdだとする。つまり、この人にとって、難しさがd以上になると、わけがわからない。この一級の人にとって、難しいが頑張れば着手が見える限界を、d/2だとする。もし、局面の難しさと局面数がZipfの法則（参考文献[1]参照）に則っていた（＝局面の難しさと局面数がべき乗分布になっている）とすると、「この人が解決可能な着手の半分が、頑張れば着手が見える局面で、残りの半分が比較的容易にわかる局面」だということになる。そして、この一級の人にとって、軽く答えがわかる難しさをd/4だとする。すると、「比較的容易にわかる局面の半分が、自明な局面で、残り半分が少し考えるがやさしい局面」だということになる。

さぁ、この一級の人が上達して、晴れて初段になったとする。その時、今まで限界だった難しさdの2

倍の難しさ2dの手まで見えるようになったとしよう。すると、これまでN個の局面しか解決可能ではなかったのが、2倍の2N個の局面が解決可能になる。この時、今まで頑張れば着手が見えていた局面は、比較的容易にわかる局面になっている。そして、比較的容易にわかる局面と同じぐらい、頑張ればわかる局面が存在する。また、比較的容易にわかる局面の半分は、この人にとっては自明な局面となっている。この局面数の分布構造はこの人が一級だった時と全く同じである。

逆に、どんなにその人の実力が変化しても、上記のような着手の難しさが同じ構造で保たれるのは、べき乗分布の場合のみである。

このように、局面の難しさと局面数がべき乗分布になっていることが、どんなレベルの人でもゲームを楽しくプレイできる必要十分条件ではないか？というのが、本論文の仮説である。

3　統計的傍証

以前、囲碁で私の行った研究（参考文献[2]）によれば、これまで述べてきた“ゲームのフラクタル仮説”と同じような分布のフラクタル性が、実際の着手データベースの中から発見された。この節ではこの実験について簡単に述べる。

方法は、実際の着手をグループ分け（クラスタリングともいう）して、それぞれのグループに難しさの尺度のようなものを割り振る。そして、横軸に難しさの尺度の対数、縦軸に実際の累積着手数をプロットする。これが直線にのれば、分布のフラクタル性があるといえる。(Fig. 9がそのグラフである)

Fig. 1, Fig. 2, Fig.3に具体的なグループ化（クラスタリング）の方法を示している。結果のグループ総数は非常に膨大で、Table1に示すように、10万から数千のオーダーとなる。

Fig. 1に示すように、現在手元にあるデータベースに合計X個の着手があったとする。(実際、実験で使用した着手総数は約700万である。) このX個の着手には、それぞれ周りのパターンが存在する。このパターンを元に着手のグループ化をするのである。

Fig. 2が実際のグループ化の結果得られるTree構造の例である。これは着手点の近傍から、注目点が（空点、黒石、白石、盤外）のいずれか？を判断して、段階的に着手をグループ分けし、Treeを成長させていく。Treeの各ノードに残っている着手数がある値（閾値）より小さくなったところで、グループ分けをストップする。注目点の例はFig. 3に示してある。

グループ分けをストップする閾値を大きくすると、最終的なグループ数は小さくなると同時に、Tree も小さくなる。逆に閾値を小さくすると、グループ数は大きくなり、Tree も大きくなる。Table 1に示したnumber of leaf nodesというのがグループ数にあたり、thresholdが閾値にあたる。

グループのパターン例をFig. 4に示す。グループAは非常に大きなパターンに対応していて、グループBは左下の小さなパターンに対応する。Table 1に示した3種類の規模のTreeにおいて、Treeの深さを横軸、leaf nodeの数を縦軸にプロットしたのが、Fig. 5である。

さて、次にこの着手点のパターングループに、難しさの尺度みたいなものを割り振りたいのであるが、これは以下のようにする。

これまで述べてきたパターンは着手点の周りの模様に基づいて行ってきた。しかし、実際は非

着手点の周りにも模様があるはずである。つまり、ほとんどいたる空点の周りの模様はグループのいずれかに属して、着手点だけが実際のゲームの中で選ばれている。ここに着目して、着手された回数を着手されなかった回数で割ることによって、そのパターンの緊急度が得られる。これを難しさの尺度と同一視しようというのである。

実際この緊急度をもとに着手を決定した場合の正解率を示したのが、Fig. 6 と Fig. 7 である。この結果をまぁまぁとみるか、全然だめかと見るかは意見の分かれるところだと思うが、パターンのみで行った着手決定の中ではトップクラスの結果が得られたと思う。

最後に示す Fig. 8 と Fig. 9 が、それぞれ Tree の中のグループ集合と、着手点グループの集合における、緊急度と累積数の両対数プロットである。真中の部分で直線に乗った分布が見られる。

4　心理学実験例の提案

前節で述べてきた研究は心理学実験ではなくて、囲碁の着手の形に対する統計的な研究である。よって、この結果はあくまでもフラクタル仮説の妥当可能性を示しているに過ぎない。本来は、“ゲームのフラクタル仮説”で出てきた“人間の感じる難しさ”という尺度を心理学実験を通して計測する必要がある。

心理学実験としてまず考えられるのが、第2節の内容をそのまま実験する以下の方法である。

1 いろんなレベルの人を数人（10人ぐらい）集めて、実戦で出てくるような局面に関する大量（1000問ぐらい）の問題を解いてもらい、回答時間を計測すると同時に、着手の難しさを例えば5段階で評価してもらう
2 データを集計して、まず、正解率で人のレベルをランク付けする
3 縦軸に累積の問題数、横軸に（できれば）回答時間、もしくは難しさの評価を取って、直線にのるかどうかチェックする（ここでは直線に乗る様に横軸の目盛りを操作してもよい。なぜならば難しさの尺度は絶対的ではないからである。）
4 1年後に全く同じ被験者に全く同じ問題を解かせて、データを集計する
5 各被験者の今年の正解問題と1年前の正解問題の包含関係をチェックする（理想的には、ランクの上がっている人は、昔解けた問題は解けて、昔解けなかった問題の一部も解けるようになっていてほしい）
6 3で作ったグラフの分布がどのように変化しているか観察する（横軸を3で作ったグラフの目盛りを固定しておいて、縦軸に累積問題数をプロットしていく。これが直線になるかどうかが一番の問題だ！）
7 毎年、4～6を繰り返す

この方法は非常にコストが必要となる大規模実験なので、実際はもっと簡略化した方法を工夫しなければいけないだろうと思う。また、この実験はもちろん囲碁に限定したものではなく、将棋やチェスでも行える実験である。

参考文献

[1] 高安秀樹、「フラクタル」、朝倉書店
[2] Hiroto Yoshii, “Move Evaluation Tree System”, Complex Games Lab Workshop, 1-6, 1998.11

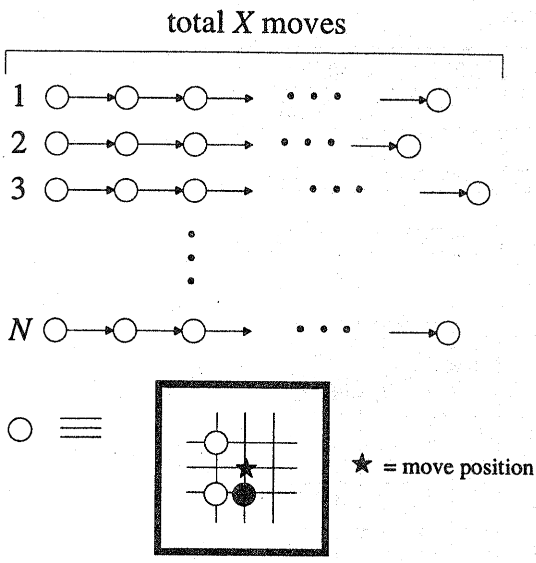

Fig. 1
Training data consists of N game records and X moves.
A circle in the figure means an information
which consists of a game state and a move position.

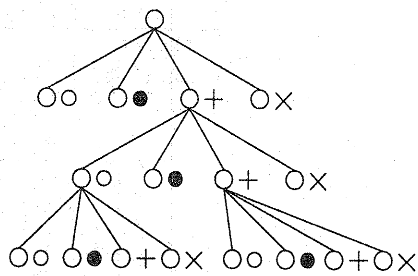

Fig. 2
Circles with lines indicate "nodes",
the apex node is "root node",
states of nodes are shown
right side of circles
(white, black, empty,
and out of board from left to right).
This illustration is an example,
and trees are more large
in depth and in width indeed.

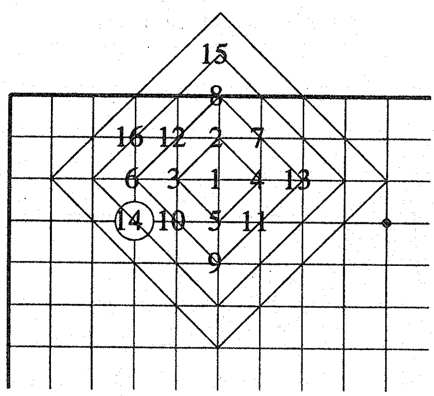

Fig. 3
Target position is "kakari" against "hoshi".
Positions are grouped in terms of Manhattan distances.
Numbers of positions are an order for watching for example.

Table 1

	METS A	METS B	METS C
threshold	50	500	5000
tree size (byte)	16,260,496	1,540,668	129,280
number of leaf nodes	558,785	70,705	7,022

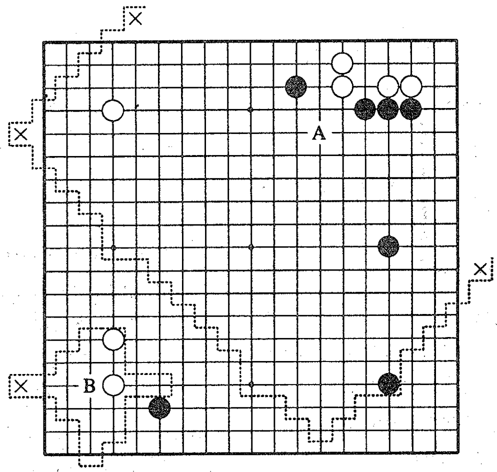

Fig. 4
Examples of leaf nodes; a pattern around position A is classified to a leaf node #536959 and B to #314275.
Areas closed by dotted lines indicate areas to watch in each leaf nodes.

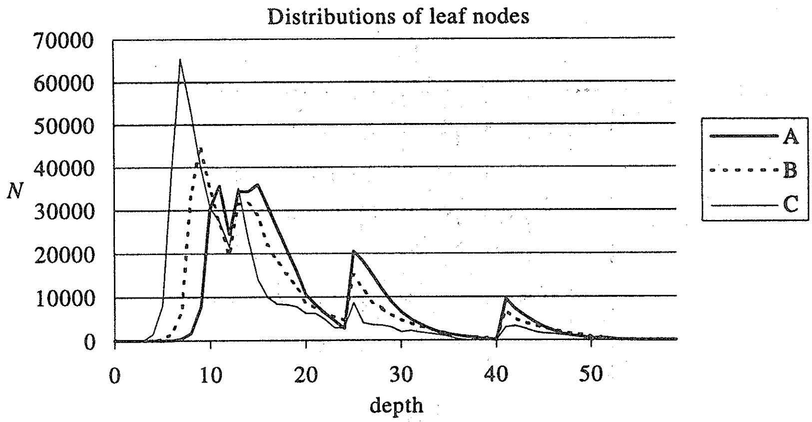

Fig.5
The vertical axis is the number of leaf nodes in each METS, and the horizontal axis is depth of leaf nodes.
Distributions of METS B and METS C are scaled down for comparison with the distribution of METS A.

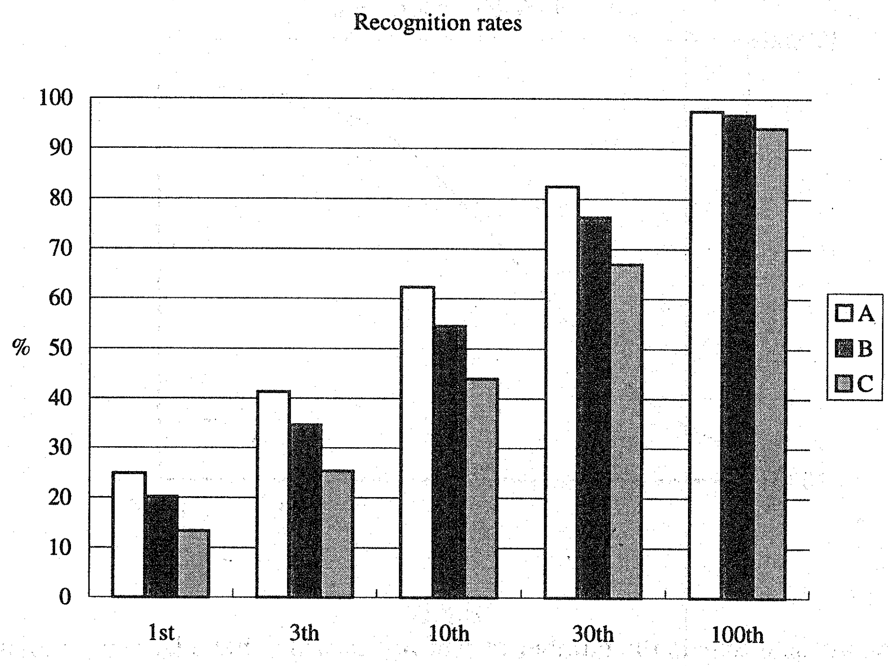

Fig. 6
In the graph, a recognition rate of n-th indicates
a ratio in which move positions are within n-th candidates.

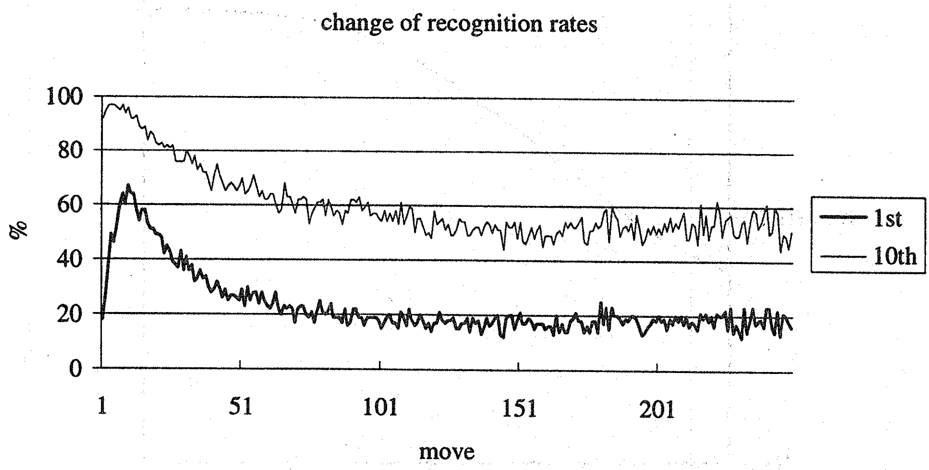

Fig.7
Changes of reconition rates are plotted.
The reconition rate at move X means an average of reconition rates
at move X of each training data.

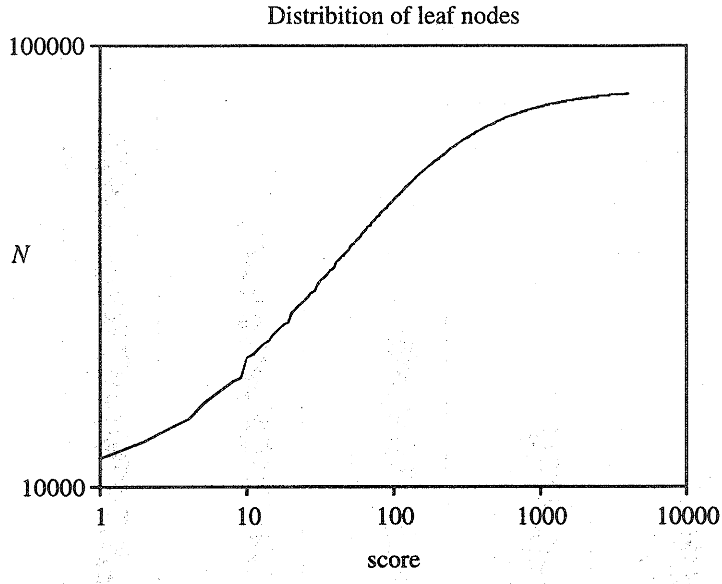

Fig.8
The vertical axis is the number of leaf nodes which have less score than the score in the horizontal axis. For good presentation, the number of leaf nodes is scaled down 1/7 times. Both axes are log-scaled.

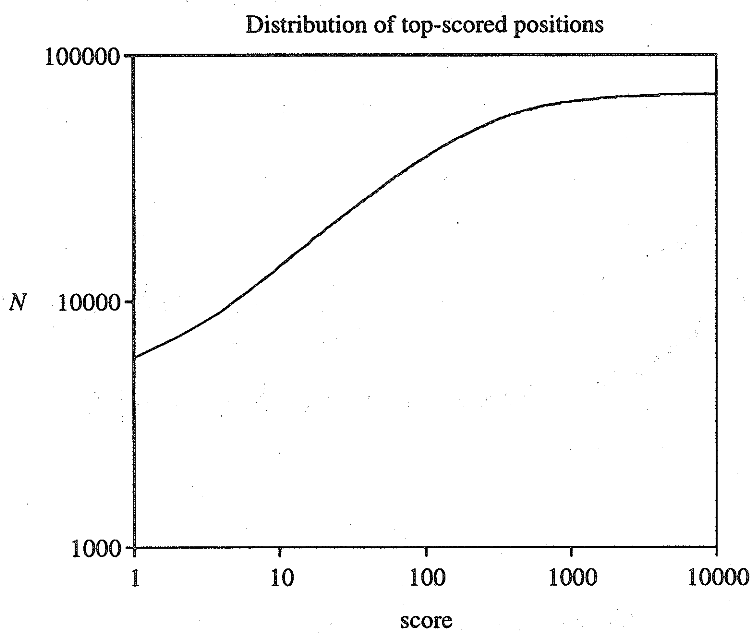

Fig.9
The vertical axis is the number of top-scored positions which have less score than the score in the horizontal axis. Both axes are log-scaled.