

Title	トレーディングカードゲームにおける対戦中の面白さの予測を用いたゲームバランス自動調整
Author(s)	遠野, 秀駿
Citation	
Issue Date	2024-03
Type	Thesis or Dissertation
Text version	author
URL	http://hdl.handle.net/10119/18911
Rights	
Description	Supervisor: 池田 心, 先端科学技術研究科, 修士(情報科学)

修士論文

トレーディングカードゲームにおける
対戦中の面白さの予測を用いたゲームバランス自動調整

遠野 秀駿

主指導教員 池田 心

北陸先端科学技術大学院大学
先端科学技術研究科
(情報科学)

令和6年3月

Abstract

Artificial intelligence (AI) technology has made great progress in recent years and has been used for various applications in society. Games are one such application, and research has long focused on the goal of creating strong AI players. The advent of AlphaZero and Deep Q-Network provides evidence that such a goal can be achieved. Since then, it has become increasingly important to pursue other goals such as “entertaining human players” or “teaching human players.”

The role of entertaining or teaching is not necessarily played only by AI players who appear as enemies or teammates in the games. To elaborate, procedural content generation (PCG) is another important role for entertaining or teaching human players. These content generators do not directly appear in the games, but they may create levels that are fun to play or provide practice. AI technologies such as machine learning and generative AI are often used in this field as well.

In addition to fully automatically generating game content, there are some attempts to generate game content collaboratively with humans. One example is to use AI as test players to evaluate human-generated content for adjusting the game balance. This allows for reduced workload and high-quality content generation while respecting the intentions of human designers.

Collectible card games (CCG) are a game genre in which players collect cards and select a set of cards (deck) to play against other players, mainly one-on-one. Some CCGs, such as Yu-Gi-Oh! and HearthStone, have histories of more than 10 years and are widely played. Each game provides players with hundreds to over 10,000 cards. Cards have basic parameters such as mana cost, health points, and attack. In addition, many cards have special “effects” such as “attacking twice,” “taking over enemy attacks on behalf of teammates,” or “increasing teammates’ attack by one.” When combined appropriately, these effects can have a significant interaction, making players enjoy considering appropriate combinations of cards. These cards are added gradually, and the game must be attractive and balanced, taking into account the interactions between the new and existing cards. This is a challenging task and a costly collaboration between skilled game designers and a large number of test players.

In recent years, researchers have applied AI technologies to adjust the balance of card games. For example, Mesentier Silva et al. used a multi-objective optimization algorithm to obtain a set of Pareto optimal solutions (deck parameters) that satisfy the following two objectives: (1) the win rate between decks should be approximately 50%, and (2) the parameters of the decks should not differ too much from the original values in order to keep the concepts of the cards or the decks.

However, we consider it unsatisfactory to merely have 50% win rate. Not limited to card

games, there are various factors that are necessary to make games interesting to play. When considering card games specifically, the following cases are likely to cause players' dissatisfaction: "Win or loss is determined by whether or not a certain card is drawn early in the game," or "it is easy to have overwhelming wins or losses."

Therefore, in this study, we first considered what factors contribute to the enjoyment of card games. Among the many candidate factors, some of them had little to do with the adjustment of card parameters, and some were difficult to quantify by computer. More specifically, in addition to the two factors mentioned above, the following lists required factors to form good card sets: (3) Games should not end in overwhelming wins or losses. (4) Games that are too long should be few. (5) Games that are too short should be few. (6) Cards that are rarely used should be few. (7) Cards that are too powerful should be few, where "too powerful" means that the winners are determined by whether the players can draw the cards or not.

We employed a genetic algorithm to adjust the deck parameters to satisfy the above-mentioned factors. Our target game was a simplified version of HearthStone that consisted of three decks with different characteristics (aggro, control, and spell). We optimized the 16 cards in the three decks, which contained a total of 38 parameters. Since a 7-objective optimization would result in too many candidate solutions, we defined the weights for each enjoyment factor and conducted single-objective optimizations instead.

Our experiments showed that when only (1) and (2) are optimized, (3) to (7) are likely to be sacrificed, while when all of (1) to (7) are considered, many factors can be improved without sacrificing (1) and (2) too much. Among the 38 parameters, averagely 5 were changed after the optimization; thus, we concluded that the original concept of the cards or decks was not changed significantly. Looking at the optimized parameters, we found that the mana costs, i.e., costs of playing cards, in aggro decks were often increased. With such adjustments, the ratio that aggro decks won quickly against control decks reduced (factors 1, 3, and 5), which also increased the chances for the control decks to use cards with high costs (factor 6). In addition, the number of minions on the board for aggro decks was reduced, lowering the power of cards that attack all enemies in spell decks (factor 7). In this study, we investigated a small set of cards and left the following as future work: improving the algorithm to allow for larger-scale parameter adjustments and improving the evaluation function for enjoyable decks through subject experiments.

概要

人工知能 (AI) 技術は近年大いに発展しており、社会の中でいろいろな用途に使われるようになってきている。ゲームも応用対象の一つであり、強い AI プレイヤを作成する目的を中心に長年研究が行われてきた。AlphaZero や Deep Q-Network の登場によってこの目的は達成できるようになってきたが、これにより、「人間を楽しませる」「人間を教える」といった目的が重要視されるようになってきている。

楽しませたり教えたりする役割は、必ずしも敵や味方としてゲーム中に登場する AI プレイヤだけが担うわけではない。ゲーム内には直接登場しなくとも、プレイして楽しいステージを作る、プレイして練習になるステージを作るといった、コンテンツの自動生成 (Procedural Content Generation, PCG) もまた、楽しませたり教えたりするために重要な機能である。この分野でも、機械学習や生成 AI などの AI 技術がしばしば使われている。

ゲームコンテンツを完全に自動生成するやり方ではなく、人間と協力・分担して生成する試みもしばしば行われる。人間が作ったコンテンツに対して AI がテストプレイヤとして評価しバランス調整を行うなどはその一例である。それにより、人間デザイナーの意図を尊重しつつ、作業量を低減したり高品質なコンテンツを生成することができるようになる。

トレーディングカードゲーム (Trading Card Game, TCG) は、カードを集め、そこから戦いに出すカードセット (デッキ) を選び、主に 1 対 1 で戦うゲームである。遊戯王や HearthStone など、いくつかの TCG は 10 年以上の歴史を持ち、今でもさかんに遊ばれている。各ゲームには数百から 1 万を超えるカードが準備されており、利用コスト・体力・攻撃力といった基礎的なパラメータのほかに、「2 回攻撃」「味方への敵の攻撃を肩代わり」「味方の攻撃力を 1 増やす」などの“効果”を持つカードも多い。これらの効果は適切に組み合わせると大きな相互作用をもたらすこともあり、カードの適切な組み合わせを考えることが楽しみの一つである。これらのカードは徐々に追加されるのが常であり、その際には、過去のカードとの相互作用を踏まえて、魅力的ではあるがバランスを崩さないようにすることが求められる。これは難しい課題であり、熟練のゲームデザイナーと多数のテストプレイヤが協力して行うコストの高い作業となっている。

そこで近年、カードゲームのバランス調整に AI 技術を活用する研究が行われている。Mesentier Silva らは、多目的最適化アルゴリズムを用いて、(1) デッキ同士の勝率がほぼ 50% になること、(2) デッキのパラメータが、当初定めたコンセプトに合致した値とあまり変わらないこと、という 2 つの目的を満たすような Pareto 最適解集合を得ることを試みた。

しかし我々は、デッキ同士の勝率が 50% になればそれでよいという点が問題であると考えた。カードゲームに限らず、ゲームをプレイしていて面白いと思うために必要なことはさまざまにありうる。カードゲームで言えば、「あるカードが序盤で引けるかどうかで勝敗が決まってしまう」「大勝や大敗になりやすい」といったことは、不満の原因となりやすい。

そこで本研究ではまず、カードゲームの面白さにはどんな要素があるのかを考察した。多くの要素の候補の中には、カードのパラメータ調整とは関係が薄いものもあり、あるいはコンピュータによる数値化が困難なものもあった。本研究では、先述の2つに加えて、(3) 試合が完勝や完敗で終わりにくいこと、(4) 長すぎる試合が少ないこと、(5) 短すぎる試合が少ないこと、(6) めったに使えないカードが少ないこと、(7) それを引けるかどうかで勝敗が決まるような強すぎるカードが少ないこと、を良いカードセットの要件とした。

そのうえで、これらの条件が満たされるように、遺伝的アルゴリズムを用いてパラメータ調整を行った。対象ゲームはHearthStoneを簡略化したものであり、3つの特徴の異なるデッキ（速攻、妨害、魔法）からなる。最適化対象は16枚のカードであり、合計38次元の最適化となる。7目的最適化を行うと候補解が多くなりすぎるので、今回は重みを定めて単目的最適化を行った。

その結果、(1)(2)だけを最適化した場合は(3)から(7)が犠牲になりやすいこと、(1)から(7)全てを考慮した場合には(1)(2)をそれほど犠牲にせず多くの項目を改善できることが分かった。これらは38パラメータのうち平均5つのパラメータを上下させただけであり、元のデッキのコンセプトを大きく崩してはいない。最適化されたパラメータを見てみたところ、速攻型デッキのマナコスト（カードを場に出すためのコスト）が高く調整されることが多かった。これにより、妨害型デッキに高速に一方的に勝利する割合を減らし（要素1,3,5）、高コスト魔法が使われる機会を増やす（要素6）ことを達成していた。また、速攻型の場に出るミニオンが結果的に減り、魔法型の全体攻撃魔法の効果を抑制する（要素7）ことにも成功していた。本研究は小規模なカード群のパラメータ調整を行ったが、より大規模なパラメータ調整を行えるようにアルゴリズムの改良や被験者実験を通して、楽しいデッキのための評価関数を改善することが今後の展望である。

目次

第1章	はじめに	1
第2章	対象とするカードゲーム	3
第3章	関連研究	7
3.1	ビデオゲームにおけるプレイ動機	7
3.2	TCGにおけるバランスの自動調整	8
第4章	カードゲームの面白さのための要件分析	10
第5章	遺伝的アルゴリズムによる複数目的の同時最適化	14
5.1	カードとデッキの構成	14
5.2	評価関数の設計	16
5.3	遺伝的アルゴリズムによる最適化	18
第6章	最適化実験	21
6.1	実験方法と実験設定	21
6.2	最適化結果	22
6.2.1	集団全体の評価値推移	22
6.2.2	個体評価値の比較	24
6.3	$Eval_4$ についての追加実験	26
6.4	変更されたカードの分析	27
第7章	おわりに	29

目次

2.1	HearthStone のゲーム画面	4
5.1	実験で用いた遺伝的アルゴリズムの概念図	19
6.1	設定 1 の評価値推移	22
6.2	設定 2 の評価値推移	22
6.3	設定 1 の $Eval_{3,5,7}$ の推移	23
6.4	設定 2 の $Eval_{3,5,7}$ の推移	23
6.5	設定 1 の $Eval_{2,4,6}$ の推移	24
6.6	設定 2 の $Eval_{2,4,6}$ の推移	24

表 目 次

5.1	速攻型デッキ ATK の構成	15
5.2	妨害型デッキ BLK の構成	15
5.3	魔法型デッキ SPL の構成	15
6.1	オリジナルパラメータ, 設定 1,2 の最良個体の評価値	25
6.2	設定 1,3 の最良個体の評価値. 二つの設定での合計値も付す.	26
6.3	設定 1,3 の最良個体の x^{org} との差異	27

第1章 はじめに

近年、人工知能（AI）技術は大いに発展しており、いろいろな種類の AI が、社会の中でいろいろな用途に使われるようになってきている。ゲームは、人間の生存に必要なものではないかもしれないが、多くの人が親しみ楽しむ対象として広く受け入れられている一方、AI の研究対象としてもしばしば使われる。それは、ルールが明確であり、性能評価が比較的容易で、その一方で奥が深く知的能力を要求するからである。長い間、ゲーム研究の中心的な目的は人間のトッププレイヤーに勝てるような強い AI プレイヤを作成することであった。Alpha Zero[1] や Deep Q-Network[2] などの登場によってこの目的は達成できるようになってきたが、これに応じてさらなる目的として「人間を楽しませる」「人間を教える」といったものが重要視されるようになってきている。

いわゆる敵や味方としてゲーム中に登場する AI プレイヤにも「人間を楽しませる」「人間を教える」という機能は重要である。一方で、ゲーム内には直接登場しなくとも、プレイして楽しいステージを作る、プレイして練習になるステージを作るといった、コンテンツの自動生成（Procedural Content Generation, PCG）もまた、楽しませたり教えたりするために必要な機能である。この分野でも、機械学習や生成 AI などの AI 技術がしばしば使われている [3]。

ゲームコンテンツを完全に自動生成するのではなく、人間と協働的に生成する試みもしばしば行われる。人間が作ったコンテンツに対して AI がテストプレイヤーとして評価しバランス調整を行うなどはその一例である。あるいは、人間のラフスケッチを補完してリアルなキャラクタの画像を作る、人間が「森が多め」「凹凸は少なめ」などの統計量を数値や自然言語で定めてそれに合わせたマップを作るなどの高度な作業もできるようになっている。いずれの場合も、人間の意図にあわせてそれを尊重しつつ、作業量を低減したり高品質なコンテンツを生成するために AI が活用されている。

トレーディングカードゲーム（Trading Card Game, TCG）は、カードを集め、そこから戦いに出すカードセット（デッキ）を選び、主に 1 対 1 で戦うゲームである。遊戯王¹、Magic: The Gathering² など、現実世界のカードを用いたものがその始まりであり、近年では HearthStone³、シャドウバース⁴ など、コンピュータ

¹<https://www.yugioh-card.com/japan/>

²<https://mtg-jp.com/>

³<https://hearthstone.blizzard.com/ja-jp>

⁴<https://shadowverse.jp/>

上でのカード収集や対戦を行う TCG も流行している。それぞれ数百から1万を超える大変多種類のカードが準備されており、それぞれ基本的な効果を持つカードから、単体では効果が薄いけど別のカードと組み合わせると大きな効果をもたらすようなものまで、多種類だけでなく内容も多様である。これらのカードはゲーム公開時にはそれほど多くなく、徐々に追加されるのが常である。新しく追加されたカードは、役に立たないほど弱ければ購買意欲を刺激できず、単体または組み合わせで強すぎるならば過去のカードを陳腐化させてしまいゲームバランスを壊す。魅力的でかつ適度に新しい戦略を生むようなカードの追加は非常に難しい作業であり、ゲームデザイナーと多数のテストプレイヤーが協力して行うコストの高い作業となっている。

そこで近年、カードゲームのバランス調整に AI 技術を活用する研究が行われている。Mesentier Silva らは、NSGA2 という多目的最適化アルゴリズムを用いて、「デッキ同士の勝率がほぼ 50%になること」「デッキのパラメータが、当初定めたもの（騎士や突撃兵といったコンセプトに合致したもの）とあまり変わらないこと」という 2 つの目的を満たすような Pareto 最適解集合を得ることを試みた [4]。

しかし我々は、デッキ同士の勝率が 50%になればそれでよいという点が問題であると考えます。カードゲームに限らず、ゲームをプレイしていて面白いと思うために必要なことはさまざまにありうる。カードゲームで言えば、「あるカードが序盤で引けるかどうかで勝敗が決まってしまう」「大勝や大敗になりやすい」といったことは、不満の原因となりやすい。そこで本研究では、カードゲームの面白さにはどんな要素があるのかを考察し、それがある程度満たされるようなバランス調整を遺伝的アルゴリズムを用いて行った。その結果、単に勝率 50%を目指した最適化では、それ以外が悪い値になってしまうことが多いこと、提案手法がそれらの値を一定程度改善できることを確認した。

本論文の構成は以下の通りである。1 章の導入に続き、2 章では TCG について説明する。3 章は、プレイ動機の調査と TCG におけるバランス調整の関連研究を紹介する。4 章では、カードゲームの面白さの要素を考察する。5 章では、それらを組み込んだ遺伝的アルゴリズムを提案する。6 章は実験結果と考察である。7 章はまとめである。

第2章 対象とするカードゲーム

1章で述べたように、TCGはカードを集め、そこから戦いに出すカードの集合（デッキ）を選び、主に1対1で戦うゲームである。カードは、ゲームインストール後すぐは基本的なものがもらえるだけであり、ストーリーを進めたり、イベントをこなしたり、課金によるいわゆるガチャで入手したりする。現実世界のカードを用いたものがTCGの始まりであるが、本研究ではコンピュータ上でのものを主に扱う。現実世界のカードを用いたTCGもコンピュータ上のカードを用いたものも基本的には遊び方は似ている場合が多いが、コンピュータ上のゲームの場合は、既存カードのパラメータ調整や制限が後からでも比較的行いやすいことがデザイナーにとっては都合の良い点かもしれない。ただしその場合でも、プレイヤーが金銭や時間など、なんらかのコストを支払って手に入れたカードが絶対的または相対的に弱体化することはユーザにとって不満につながりやすく、できるだけそういった調整や制限は行わないことが望ましい。

TCGの基本ルールはゲームによって様々であり、ゲームごとになにかしら特色を持つことでユーザを惹きつけようとする。また、カードの種類が1万を超えるようなものもあり、その効果も実に様々である。どの部分が最も共通しているかというのは難しい問題だが、本章では、実験に用いるMetaStoneのもとになっているHearthStoneのゲーム画面¹（図2.1）を用いて、基本的なルールを説明する。

¹<https://hearthstone.blizzard.com/ja-jp/expansions-adventures/titans> のトレーラー 33 秒のキャプチャ（2024/1/30 閲覧）を改変したもの



図 2.1: HearthStone のゲーム画面

HearthStone は、ヒーローと呼ばれるキャラクタ同士の戦いという構図になっており、画面手前側に自分のヒーロー (①)、奥側に相手のヒーローがいる。ヒーローのイラストの右下にある数字が該当ヒーローの体力を表し、この場合自分は5、相手は30である。通常のゲームではどちらも30から始まるが、ゲームモードによってそれはさまざまである。

画面一番手前側に、自分の手札が8枚示されている (②)。カードの詳細は示されていないが、マウスカーソルを合わせれば見ることができる。見えている数字はそのカードを利用するためのマナコストであり、0から7のものが見えている。画面一番奥には相手のカードが伏せられており、枚数だけは確認できるようになっている。カード枚数は通常数枚から始まり、毎ターン1枚デッキ (③) から引くことができる。カードには大きく分けて、魔法カード、ミニオンカード、武器カードがある。

この画面は別の魔法の効果でカードを多数引いている途中をキャプチャしたものである。④はどのヒーローでも使える共通のミニオンカードであり、マナコストが4、攻撃力が3、体力が5であって、Taunt (挑発) の効果を持つ。挑発を持つカードが場にある場合、敵 (ヒーローもミニオンも) は挑発カードの中からしか物理攻撃の相手を選べないため、守りの要となる効果を持つカードである。④の下に半分隠れたカードの一番下には「Nature」という文字が記されており、これはこのヒーロー (Druid) しか使えないことを意味している。このカードはマナコスト7の魔法カードであって、攻撃力や体力はない。カード内には複雑な効果²

²次のどちらかの効果を選べる。効果1: 体力と攻撃力がともに2である Treants を5体場に出

が記されている。

概ね、強力なカードほどマナコストが高い。⑤はマナの状況を表し、最大マナは10であるがこのターンでは使い切って残り0であることが分かる。マナは毎手番開始時に最大マナ値まで回復する。最大マナ値は通常1から始まり、毎手番1増える。つまり、序盤は低コストのカードしか出せないが、徐々に高コストのカードが出せるようになってくる。このことが、デッキのコンセプトを決めるために非常に重要な点であって、序盤での決着を目指す低コストの速攻型 (aggro) デッキ、序盤をミニオン排除魔法などでなんとか乗り切って終盤の強力なカードで勝とうとする妨害型 (control) など、大きく戦略が分かれた有力デッキがあることが多い。また、マナを回復したり、最大マナ値を向上させるような魔法やカード効果もある。

ヒーローは、それぞれ固有の特技 (⑥) を持っていて、一定のマナコスト (この場合自分は2, 相手は1) を消費して利用することができる。この特技は変更することができないので、デッキは必然、特技との相性を考慮して構成されることになる。

この画面にはないが、⑦の場所に武器を装備できるヒーローもいる。武器は、武器カードを用いることで装着できる。武器カードを装着すると、ヒーローが (場合によっては効果を持った) 物理攻撃をできるようになるが、多くの場合武器には使用回数が定まっていて、その回数を使い切ると壊れる。

⑧が戦いの中心となる「場」であって、現在味方のミニオンが2体配置されている。配置されたミニオンからは消費マナコストの表示が消え、“現在の”攻撃力と体力が表示されている。④の下のカードのように、場に出ているカードの攻撃力や体力を変更するカード効果は多く、例えば攻撃力や体力が10を超えることも珍しくない。ミニオンは、配置されたターンは行動することができない (図⑧の右側のミニオンに睡眠のzzマークが付いているのはそれを表している) が、「突撃」の効果を持ったカードは例外で、配置されてすぐ相手を攻撃することができる。

ミニオンは通常、ミニオンかヒーローを選んで攻撃でき、自分の攻撃力分、相手の体力を減らすことができる。ミニオン同士の戦いでは、一方的に相手の体力を減らすのではなく、相手のミニオンの攻撃力分自分の体力も減る。「挑発」を持ったミニオンが相手にはいる場合には、それらしか攻撃対象に選べない。体力が0以下になったミニオンは死んで場から排除され、ヒーローの体力が0以下になれば負けである。この物理攻撃以外にも体力を減らす (または増やす) 手段はさまざまにある。

ミニオンの攻撃、カードの利用、ヒーローの特技の利用、ヒーローの物理攻撃は、基本的には全て自由な順番に行うことができ、対象が複数ある場合にはそれを選択することもできる。このため1ターンにできる行動の数は手札や場のミニオンの数に応じて膨大なものとなり、コンピュータプレイヤーにとっても人間にとっ

せる。効果2: 場に出ている1体のミニオンの攻撃力を+2, 体力を+4したうえで、挑発を付与する。

ても、このゲームを考え甲斐のあるものになっている。

ここでは突撃と挑発という基本的な効果を説明した。これらを持ったカードは実際に多いが、ゲーム中にはより複雑な条件や効果を持ったカードが多数存在する。組み合わせとして分かりやすいものを挙げておくと、例えば「場に出ている魔法カードのダメージを+1する」ようなミニオンがいる。このカードは、「敵1体に7ダメージを与える」魔法カードよりも、「敵全体に1ダメージを与える」魔法カードと相性が良い。このような組み合わせを考慮し、さまざまな敵デッキを想定しつつそれらに対処できるようなデッキを構築することは、難しくまた楽しいものである。この手のゲームの真の楽しみは実際の戦闘よりもデッキ構築であると考えられるプレイヤーも一定数いる。

MetaStoneは、HearthStoneとほぼ同じルールとカードからなる、いわばコピーゲームである。MetaStoneの目的は、HearthStoneのコンピュータプレイヤーとしてより強いもの、より人間らしいものを作る研究を支援することであったり、本研究のようにカードのパラメータ調整を行う研究を支援することである。そのために、MetaStoneのソースコードは全て公開されており³、多くのコンピュータプレイヤーがデフォルトで使えるようになっている。また、GUIでのコンピュータプレイヤーと人との対戦もできる一方で、GUIなしでコンピュータプレイヤー同士が高速に対戦を行うこともでき、研究開発のための環境が整備されている。これまで多くの優れた研究がMetaStoneを用いて行われてきた [5, 6]。本研究でもこれを用いて、パラメータ調整のための研究を行う。

³<https://github.com/demilich1/metastone>

第3章 関連研究

プレイヤーのプレイ動機の調査は学术界と産業界を問わずに多く行われている。プレイ動機を知ることで、新しいゲームの設計にも既存のゲームの内容更新（例えば新しい機能の追加や期間限定イベントの開催）にも、ゲームを魅力的にする面で役に立つ。TCGにおいて新しいカードを追加し、ゲームバランスを調整することは、後者の既存のゲームの内容更新に該当する。本章では、オンラインTCGを含むビデオゲームにおけるプレイ動機を調査した研究と、TCGにおけるゲームバランスを自動で調整する研究を紹介する。

3.1 ビデオゲームにおけるプレイ動機

ゲーム会社の起業に参加した経験を持つ Bartle は、ビデオゲームにおけるプレイスタイルの4つの分類を提唱した [7]。この分類法は「バートルテスト」と呼ばれている。本節でのバートルテストの紹介は、Musubu ライブラリの記事 [8] を一部参考して構成したものである。Bartle はプレイヤーが「何と」「どのように」ゲームを楽しむかにより、「達成者 (achiever)」「探検家 (explorer)」「社交家 (socializer)」「殺し屋 (killer)」という4種類に分類した。

達成者は、ゲーム自体への関心が高く、ゲーム内を一人で行動し楽しみたいプレイヤーである。探検家は、ゲーム自体への関心が強く、ゲームの世界の登場人物やオンライン上の相手と関わりながらゲームを進めたいプレイヤーである。社交家は、ゲーム自体への関心は低く、他のプレイヤーへの関心が高いプレイヤーである。殺し屋は、単独行動を好み、競争心が非常に高く、他のプレイヤーよりも自分が優れていることに喜びを感じる傾向のあるプレイヤーである。Bartle は、この4種類のプレイヤーの数が“均衡状態”になることが重要であることも提唱した。ここでの均衡状態は、4種類の人数が同じであることでなく、時間が経過しても各種類の人数割合がほぼ一定であることを指す。

オンラインTCGに限定したプレイ動機の調査には Turkay らの研究がある [9]。彼らは2つの人気オンラインTCGのHearthstoneとEternalから856名のプレイヤーを集め、アンケートでプレイ動機を調査し、これらの動機を「immersion seeker」「competitor」「socializer」「smarty-pants」といった4種類に大別した。

Immersion seeker はゲームのストーリーに没入することを好み、ゲーム内でさまざまなことを試したがるプレイヤーである。バートルテストの「探検家」に近いと

言える。Competitor はほかのプレイヤーを勝ち越すためにプレイするプレイヤーである。バトルテストの「殺し屋」に当てはまる。なお、TCG は基本的には1対1の対戦となり、そもそも仲間が存在しない点から、単独行動を好むかどうかどちらとも言えないかもしれない。Socializer はバトルテストの社交家に当てはまる。Smarty-pants は頭が良くなるためにプレイするプレイヤーであり、バトルテストの4種類のいずれも当てはまらない。

Turkay らの4種類の動機の中、856名のうち多かったのは immersion seeker と competitor の2つだった。TCG におけるキャラクタやストーリーの豊富性からすると、immersion seeker は納得できる結果である。また、TCG は対戦ゲームであることからすると、competitor のプレイ動機はわかりやすい。これらの動機は4章で紹介する、面白さの要件にもつながる。

3.2 TCG におけるバランスの自動調整

2章で紹介した通り、TCG には数百から1万を超えるカードが準備されており、プレイヤーはクエストをクリアしたり課金したりすることでカードを集め、そこから戦いに出すデッキを構築し、ほかのプレイヤーと対戦する。ゲームバランスの自動調整を行うためにも似たような流れで、(1) 集まったカードからデッキを自動で構築する機能、(2) AI プレイヤーの自動対戦などでデッキを評価する機能、(3) カードのパラメータなどを自動で調整する機能がいずれも望ましい。

デッキの自動構築には Fontaine らの研究がある [10]。彼らは Multi-dimensional Archive of Phenotypic Elites (MAP-Elites) という最適化手法を改良し、HearthStone におけるデッキの自動構築を行った。MAP-Elites は多様かつ評価の高い解を出力する進化的アルゴリズムの1つであり、ロボットのナビゲーション問題に適用され成功を収めた [11]。Fontaine らは sliding boundaries という概念を MAP-Elites に導入し、MAP-Elites with Sliding Boundaries (MESB) という手法を提案した。彼らは MESB を HearthStone のデッキ構築に適用し、速攻や妨害など異なるコンセプトにおいて多様かつ勝率の高いデッキを作った。カードのパラメータを手動で調整し、構築されたデッキはどう変化するかという分析も行い、強すぎるカードの検出に役に立つことを示した。

カードのパラメータ自動調整には Mesentier Silva らの研究がある [4]。彼らはデッキが与えられると仮定したうえで、各カードのコスト、攻撃力（ミニオンカードのみ）、体力（ミニオンカードのみ）、耐久性（武器カードのみ）というパラメータの最適化を行った。目的関数はデッキ同士の対戦の勝率がそれぞれほぼ50%になることを目指したもので、最適化には進化的アルゴリズムが用いられた。Fontaine らが作った12個のデッキで実験した結果、勝率がほぼ50%になるという目的を満たすことが確認された。さらなる発展として、「当初定めたカードコンセプトに合致した値とあまり変わらない」という2つ目の目的を加え、多目的最適化も行った。

単目的最適化の結果に比べて、勝率がほぼ50%になるという面であり劣化せず、オリジナルのパラメータからの変更が大幅に小さくなった。

第4章 カードゲームの面白さのための要件分析

カードゲームに限らず、一つのゲームソフトが面白いと判断される、あるいは販売や課金に繋がるための要素というのはさまざまである。面白いゲームであっても、有名なゲームソフト会社製ではなかったり、宣伝が不十分であれば評判にはならないかもしれない。あるいは、グラフィックが綺麗であること、音楽が優れていること、声優が豪華であること、マンガ等別のコンテンツとコラボレーションしていること、操作 (GUI) が直感的で爽快であること、バグが少ないこと、計算やネットワーク処理が軽快であること、ユーザー対応が誠実であること、定期的に行われるイベントが魅力的であることなど、さまざまな要素がゲームの評価に関連している。上に例を挙げた要素はどちらかといえば囲碁や麻雀などどんなゲームにもあるような“ゲームプレイの中心部分”の外側に位置すると捉えることができる。これらは重要なことではあるが、我々はこういった要素は考慮にいれず、もっぱら“ゲームプレイの中心部分”について考えることにする。

囲碁や麻雀のような例を考えると、あまねくゲームにはありうる状態・取りうる行動・状態遷移・勝利条件などを定めた「基本ルール」がある。そのうえで、ルールの一部、例えば囲碁のコミ（先手番有利を相殺するためのハンデキャップ、日本では通常6.5目）や麻雀のローカルルール（ポンやチーをした場合のタンヤオ役が認められるかなど）などの「パラメータ」が定められる。ドラゴンクエストのように、フィールド上を歩くようなゲームでのマップ、敵が出るようなゲームでの敵の体力や攻撃力、などもパラメータの一部と言える。これら基本ルールやパラメータが適切に定められていなければ、ゲームが面白くならないのは明らかである。さらに、デジタルゲームにおいて敵キャラ（例えば囲碁の相手）を人間が操作しない場合、その代役をしてくれる「コンピュータプレイヤ」も、ゲームプレイの中心部分に位置する。例えば囲碁の対戦ソフトでは、基本ルールやパラメータはすでに十分に魅力的であるため、コンピュータプレイヤが適切な強さを持っているか、着手は自然であるか、多様な戦略を用いてくるか、などがその囲碁ソフトの最も重要な評価点になる。

2章で述べたように、カードゲームは10年以上の長期にわたってほぼ同じ基本ルールのままサービスされ、その間、頻繁に新しいカードが投入され続けることも珍しくない。新しいカードはしばしば、それまで築き上げられたデッキの優劣関係に影響を与える。特定のカードや効果を中心に築かれた有力なデッキに対し、

それを無力化しやすいカードが投入されれば、そのデッキは優勢でいられないだろう。逆に、これまであまり顧みられることのなかったカードや効果が、新しいカードとのシナジーによって一気に注目を浴びることもある。これらの影響は、度を過ぎなければ好ましいものであり、影響がないなら新しいカードが投入されることに意味はない。一方で、1万を超えるようなカードが存在するゲームに新しいカードを投入する場合、そのシナジーを調べ、どのようなデッキが有力または無力になるのか事前に想定、評価することは容易ではない。そこで、それをAIに行わせるための研究が行われており、我々の研究もその一環である。前段落の議論に沿って言えば、我々の研究は同じ「基本ルール」や「コンピュータプレイヤー」を想定したうえで、「パラメータ」に関する部分の面白さのための要件分析を行うものであると言える。

我々は、いくつかの文献調査、聞き取り調査、被験者実験および自身の経験に基づき、どのようなときにカードゲームを面白いと思うか、また逆につまらないと思うかを考察した。これらの意見は必ずしも「全プレイヤーがそう思う」というものとは限らない。窪木らは、対局が楽しかったかどうかを採点できる囲碁サイトでのログを分析し、例えば「大勝であるほど楽しい」という人と「大勝はつまらなくて互角に近いほど楽しい」という反対の人が存在することを明らかにした[12]が、我々の聞き取り調査でも似たような傾向があった。以下に示すのは、いわゆる多数派の意見である。

カードゲームには、カードセットの中からデッキを構築するフェイズと、あるデッキで敵と戦うフェイズの2つがある。この二つを完全に切り離すことはできないが、まず前者については以下のような要件があると考える。

- [R1] デッキやカードに、何らかのコンセプトが感じられると良い。利用に前提条件のある有力なカードを出すために他のカードがサポートするなど、特色や相互作用があるほうがよい。
- [R2] カードが表すキャラクタに沿ったパラメータ設定であると良い。例えば突撃兵と重装兵では前者のほうが攻撃力が、後者のほうが体力が高い方が自然だろう。
- [R3] 多様なデッキが構築できる、多様な戦略がとれるカードセットであると良い。特定の戦い方や、特定のカードだけが採用されるようでは考える余地がなくつまらないということである。

一方で、後者については以下のような要件があると考える。

- [R4] 各ターンでとれる戦術の選択肢が多いほうが楽しい。殆ど機械的にプレイできてしまうデッキよりは、状況に応じて適度に悩むような試合のほうが楽しく感じられるということである。

- [R5] なんらかの意味で「思い通り」になると楽しい。たとえばデッキのコンセプト通りのプレイが出来たときや、相手のミニオンを一掃する魔法をタイミングよく放てたときなどには爽快感を覚えるプレイヤーが多い。これはそもそもそのようなデッキ・カードが作られていなければいけないという意味では[R1][R3]にも関連する。
- [R6] 相手プレイヤーとの駆け引きが感じられると楽しい。たとえばブラフを張って相手の行動を誘導できたり、逆にそれを見抜かれて負けた時などは、人間相手でもAI相手でもカードゲームの醍醐味を感じられることが多いだろう。当然、この前提として、相手プレイヤーは適度な強さと自然さを持っていないとまらない。
- [R7] 互角の試合展開やシーソーゲーム、意外な逆転などがあると楽しい。これは好みも分かれるところだが、あっけない完勝や、手の施しようのない完敗は、つまらないと思われることが多い。デッキには相性がある場合が多いが、「デッキAはデッキBにはまず勝てるが、デッキCにはまず勝てない」ような関係があることは望ましくない。
- [R8] “勝敗は運しだい”ではつまらない。これは[R4]や[R7]とも関係するが、例えば特定のカードが序盤に引ければほぼ勝利、引けなければほぼ敗北ということはパラメータ設定によってはあり得る（このようなカードはパワーカードと呼ばれる）。プレイヤーはそのカードを引ければあとは機械的なプレイで済み、そうでなければ不利を戦術で補うこともできず負けるということになれば、楽しくプレイすることは難しい。ランダム性はこういったゲームに多様な展開をもたらす大事な要素ではあるが、度を過ぎてはいけないということである。
- [R9] 使えないカードが少ないほうが良い。デッキには相性があり、あるマッチングでは特定のカードが殆ど役立たないということはあるし、仕方ないことである。しかし、それが過度になると、パワーカードと同様なことが生じる。つまり、序盤に役立たないカードばかり引けば、勝つことひいては楽しむことが難しくなる。
- [R10] 勝敗が決するまでのターン数が適度である方が良い。2章で述べたようにデッキには「速攻型（アグロ）」「防御・妨害型（コントロール）」などのタイプがあり、勝敗が決するまでのターン数がさまざまであることは自然である。とはいえ、短すぎる試合はあっけないうえに一方的であることが多く[R7]を満たしづらい。一方長すぎる試合は緊張感や爽快感を損ねることも多い。

これらのうちいくつか、例えば[R1]や[R5]はゲームデザインに強く依存するところであり、パラメータだけで改善するのは難しい。またいくつか、例えば[R6]

や [R7] の前半は相手をするコンピュータプレイヤーに強く影響される場所である。我々は次章で、デッキやコンピュータプレイヤーは固定したうえで、パラメータのみを調整することでこれらの要件のいくつかを同時に改善することを試みる。

第5章 遺伝的アルゴリズムによる複数目的の同時最適化

4章では、カードゲームがどのような場合に面白いと感じられるか、「基本ルール」「パラメータ」「コンピュータプレイヤ」に絞って考察した。本章では、このうち基本ルールとコンピュータプレイヤについては固定したうえで、要件のいくつかを満たすように「パラメータ」だけを調整する方法について論じる。

本来、大規模なTCGでは、数百枚から1万枚を超えるカードがあり、そこからどのような有力デッキが構成されうるかを考えてパラメータが調整されなければならない。しかし我々は計算資源の都合上、カード枚数は16枚に限定し、それらからなる3つのデッキの構成も固定することにした。そのうえで、カードのマナコスト、ミニオンカードの場合それに加えて攻撃力と体力の最大3種類のパラメータを、遺伝的アルゴリズムを用いて最適化する。なお、このようにカードを限定、デッキを固定して最適化を行うのは、3章で紹介した Mesentier Silva らの直接の先行研究も同じである。

続いて5.1節では用いる16枚のカードと3つのデッキの構成を、5.2節では面白さの要件を考慮した評価関数の設計を、5.3節では遺伝的アルゴリズムの手続きを述べる。

5.1 カードとデッキの構成

本研究に用いたカードとデッキは、実験に用いた MetaStone 環境のもとになっているゲーム HearthStone をはじめ、多くのゲームに登場する代表的なデッキコンセプトを参考に、簡略化したものである。被験者を用いた予備実験の結果、これらのカードとデフォルトパラメータは、プレイしてある程度楽しいものであることが分かっている。

カードは全部で16種類あり、うち11種類がミニオン、5種類が魔法である。デッキは速攻型の ATK、妨害型の BLK、魔法中心の SPL の3種類があり、それぞれが6種類ずつのカードを計15枚ずつ持つ。表5.1はATKデッキのカードの枚数、名前、マナコスト、攻撃力、体力、効果をまとめたものである。表5.2はBLKデッキについて、表5.3はSPLデッキについてまとめたものである。パンチはATKとSPL、嵐はBLKとSPLに共有されており、調整の際には同時にパラメータが変動するので注意が必要である。

表 5.1: 速攻型デッキ ATK の構成

枚数	名前	コスト	攻撃力	体力	効果
3	斥候	0	1	1	
3	双剣士	1	1	1	2回攻撃する
2	狙撃兵	1	1	1	ヒーローには +1 ダメージ与える
2	指揮官	1	1	1	場に出たとき味方1人の攻撃力を+1
3	パンチ	1	-	-	ヒーローかミニオンを選んで1ダメージ
2	速攻兵	2	2	1	速攻 (場に出てすぐ攻撃できる)

表 5.2: 妨害型デッキ BLK の構成

枚数	名前	コスト	攻撃力	体力	効果
3	サソリ	2	1	1	ミニオンに攻撃すると破壊する
3	盾兵	2	1	1	挑発 (味方への攻撃を代わりに受ける)
3	不幸な事故	3	-	-	ランダムな敵ミニオンを1体破壊
2	嵐	3	-	-	全ての敵ミニオンに2ダメージ
2	聖騎士	3	2	2	場に出たときヒーローの体力を3回復
2	海竜	5	3	4	場に出たとき全ての敵に2ダメージ

表 5.3: 魔法型デッキ SPL の構成

枚数	名前	コスト	攻撃力	体力	効果
3	乱気流	1	-	-	ランダムな敵ミニオンに2ダメージ
3	パンチ	1	-	-	ヒーローかミニオンを選んで1ダメージ
2	魔術師	2	1	3	場に出ていると呪文ダメージ+1
2	預言者	2	2	2	場に出たときカードを1枚引く
3	嵐	3	-	-	全ての敵ミニオンに2ダメージ
2	爆発魔法	4	-	-	合計4ダメージをランダムな相手に振り分け

速攻型デッキ ATK のカードは6枚中5枚がコスト1以下であり、序盤から場に出すことができる。能力はそれほど高くないが、相手が後半重視のデッキの場合、それらのカードが出る前に相手を圧倒することも多い。指揮官の効果は特に2回攻撃の双剣士との相性が良く、ダメージを2回分、計2増やすことができる。

妨害型デッキ BLK は逆に全てのカードがコスト2以上であり、例えば最初のターンは引きに関わらず何もできない。一方で、相手のカードを破壊することに優れ、場に出てしまえば強いカードも多い。

魔法型デッキ SPL は、15枚中11枚が魔法カードであり、ミニオンカードは4枚

しかない。ミニオンも魔法を強化したり別のカード引いたりと補助的なものであって、主に魔法ダメージのみで相手を倒すことを狙う。

第6章で述べるように、これらのデッキには、ATKはBLKにかなり強く、BLKとSPLは互角であるが、SPLはATKにかなり強いという、いわゆる三すくみに近いバランスの悪さがある。もし $ATK > BLK > SPL$ などという半順序的な関係があれば、ATKの弱体化とSPLの強化という対応でバランス調整が比較的容易であるが、そのような簡単な状況ではない。

5.2 評価関数の設計

本研究の実験における最適化対象 $x \in X$ は、11種類のミニオンのmanaコスト・攻撃力・体力と、5種類の魔法のmanaコスト、合計38個の整数値である。各デッキのカードの枚数や効果については、本来調整可能な値ではあるものの、オリジナルのデッキのコンセプトをあまり変えないように、最適化対象とはしない。manaコストはオリジナルの値 ± 1 を値域とし、0を認める。攻撃力と体力はオリジナルの値 ± 1 を値域の基本とするが、0に減らすことは認めず、またもとの値が3以上の場合には $-1 \sim +2$ することを認める。可能な組み合わせは全部で $2^{15} \cdot 3^{20} \cdot 4^3$ 通りであり、しらみつぶしに調べられるような数ではない。

パラメータ x に対し、評価関数 $f(x) \in \mathbb{R}$ を定める必要があるが、我々はこれを7つのサブ評価関数 $Eval_1 \sim Eval_7$ に分け、その和 $f(x) = \sum_{j=1}^7 Eval_j(x)$ で計算することにした。各パラメータ x を評価するためには、3つのデッキを n_{btl} 戦ずつ総当たりで計 $3 \cdot n_{btl}$ 戦、コンピュータプレイヤー同士で戦わせ、その統計量を利用する。 $Eval_1$ から $Eval_7$ をそれぞれ、4章で述べた要因と関連させて説明する。

$Eval_1$ は、デッキ間の勝率が五分に近いことを高く評価する、バランス調整の基盤となる関数である。面白さの要因 [R3] では、多様なデッキが構築できる必要があるとしている。そのためには、特定の方向性のデッキばかりが強くてはいけない。また、要因 [R7] では、デッキ間の相性が極端ではいけないとしている。これらのことから、各コンセプトのデッキ同士が互角に近い戦績となると高い評価となるように $Eval_1$ を定める。具体的には、3つのデッキを総当たりで $3 \cdot n_{btl}$ 回戦わせ、デッキ ATK のデッキ BLK に対する勝率を $w_1 \in [0, 1]$ 、デッキ BLK のデッキ SPL に対する勝率を w_2 、デッキ SPL のデッキ ATK に対する勝率を w_3 としたとき、 $Eval_1$ は以下の式で計算する。 w_m が全て 0.5 のとき最大の値 300 を取り、すべて 0 または 1 のとき最小の値 0 を取る。

$$Eval_1 = \sum_{m=1}^3 \{100 - 400(w_m - 0.5)^2\}$$

$Eval_2$ は、パラメータベクトル x がオリジナルのパラメータベクトル x^{org} と離れていることに対するペナルティである。面白さの要因 [R1][R2] では、デッキや

カードにはコンセプトがあり、キャラクタに沿った設定であることが求められるとしている。オリジナルのパラメータはコンセプトを踏まえ、キャラクタ名に沿った数値がつけられているはずであり、そこから値を変えることは多かれ少なかれ望ましくない。実際には望ましくなさはカードごとパラメータごとに異なると考えるが、今回は以下のように、二つのパラメータベクトルの単純なマンハッタン距離にペナルティ -5 をかけたもので定義した。

$$Eval_2 = -5 \sum_{k=1}^{38} |x^{org} \text{の } k \text{ 番目の値} - x \text{の } k \text{ 番目の値}|$$

$Eval_3$ は、完勝・完敗に対するペナルティである。面白さの要因 [R7] では、これらの一方的な展開が望ましくないとしている。具体的には、最初 10 ずつだったヒーローの体力が、終了時点で片方が 10 のままだった場合、それを完勝・完敗と定義した。実際には、場のミニオンの数などの意味で、体力 7 でも完勝だったり、体力 10 でも危うい勝ちだったりすることもあるだろうが、本研究では簡単のためこのような定義とした。 $Eval_3$ はこのような試合の割合に -50 をかけたもので定義した。

$$Eval_3 = -50(\text{勝利側ヒーローの体力が終了時 } 10 \text{ の試合数}) / (\text{全体の試合数} = 3 \cdot n_{btl})$$

$Eval_4$ と $Eval_5$ は、長すぎる、あるいは短すぎる試合に対するペナルティである。面白さの要因 [R10] では、ターン数が適切であることを望ましいとしている。その閾値を適切に定めることは容易ではないが、本研究では以下のように定義し、そのような試合の割合に -50 をかけたもので $Eval_4$ と $Eval_5$ を定義した。

$$Eval_4 = -50(23 \text{ ターン以上かかった試合数}) / (\text{全体の試合数} = 3 \cdot n_{btl})$$

$$Eval_5 = -50(6 \text{ ターン以下で終わった試合数}) / (\text{全体の試合数} = 3 \cdot n_{btl})$$

$Eval_6$ は、めったに使われないカードがあることに対するペナルティである。面白さの要因 [R9] では、マナコストの意味で、あるいはコストパフォーマンスの意味で、使えないカードが少ないほうが良いとしている。そこで、各デッキの組み合わせごとに、「8割以上の試合で一度も使われていない」カードを数え、それに -10 をかけることで $Eval_6$ を定義した。

$$Eval_6 = -10 \sum_{m=1}^3 (n_{btl} \text{ 戦中}, 0.8 \cdot n_{btl} \text{ 戦以上使われていないカードの数})$$

$Eval_7$ は、勝敗を左右する強すぎるカードがあることに対するペナルティである。面白さの要因 [R8] では、勝敗が運次第であることは望ましくないとしている。運が影響する要素はさまざまにあるが、特定のカードが早めに引けるかどうかということは勝敗を分けるランダム要素になりやすい。例えば、あるカード c につ

いて、勝った3試合ではそれを1,3,3ターン目で引き、負けた4試合ではそれを5,5,5,7ターン目でようやく引いていたとしよう。これはつまり c が3ターン以内に引ければ勝ち、そうでなければ負けであったと解釈でき、 c は勝敗に影響しすぎるカードであるということになる。そこで、各デッキの組み合わせ m とカード c ごとに、勝ち試合におけるカード c の平均初登場ターン $t_{m,c}^{win}$ と、負け試合におけるそれ $t_{m,c}^{lose}$ を計算する。そして、前者が後者よりも3.0以上小さいようなカードの枚数を数え、それに -10 をかけることで $Eval_7$ を定義した。

$$Eval_7 = -10 \sum_{m=1}^3 (t_{m,c}^{lose} - t_{m,c}^{win} > 3.0 \text{ となるカードの数})$$

4章最後に述べたように、面白さの要因 [R1][R5][R6][R7] のうちいくつかの部分は、ゲームデザインやコンピュータプレイヤに強く影響され、パラメータの調整だけでは改善しにくい。[R4] は例えば各ターンの可能行動数などで機械的に定義することができるかもしれないが、予備実験を行ったところ、人間の考える「戦術の選択肢」と、機械的な定義の候補は相関が弱く、今回は評価関数化することを断念した。

また、上記各定義の中にある定数値は何らかの根拠やデータに基づいて調整されたものではなく、我々が適当に定めたものである。本来は、例えば被験者実験を行い、各要素が人間の感じる面白さにどの程度寄与するのかを踏まえて定めるべきものであり、今後の課題である。

5.3 遺伝的アルゴリズムによる最適化

4章ではカードゲームの面白さの要因として、主に基本ルール・パラメータ・コンピュータプレイヤに関するものを10個提示した。5.2節ではそのうちパラメータ調整で改善できると思われる項目を $Eval_1$ から $Eval_7$ の7つの評価関数で定式化した。本研究では、これを一つの評価関数 $f(x) = \sum_{j=1}^7 Eval_j(x)$ にまとめ、5.1節で述べた16種類のカードが持つ38次元のパラメータ x を単目的最適化する。

先行する Mesentier Silva の研究 [4] では、 $Eval_1$ と $Eval_2$ に相当するもの、つまり「デッキ間の勝率が五分に近いこと」と「オリジナルパラメータとの差が小さいこと」を加算せずに扱い、多目的最適化を行っていた。多目的最適化を用いる利点は、どちらかという $Eval_1$ を重視した解、 $Eval_2$ を重視した解、あるいはどちらもほどほどに優れる解など、さまざまな解が得られる点である。特に人間がデザインしたデッキやカードのパラメータを調整する場合、目線の異なる複数の優れた解から最終的にデザイナーが最も好ましいと思うものを選べることは便利である。

一方で我々は、7つの項目を線形で重みづけして加算した単目的最適化を採用する。その理由は、多目的最適化では一般に目的関数の数が増えるほど、解と解の

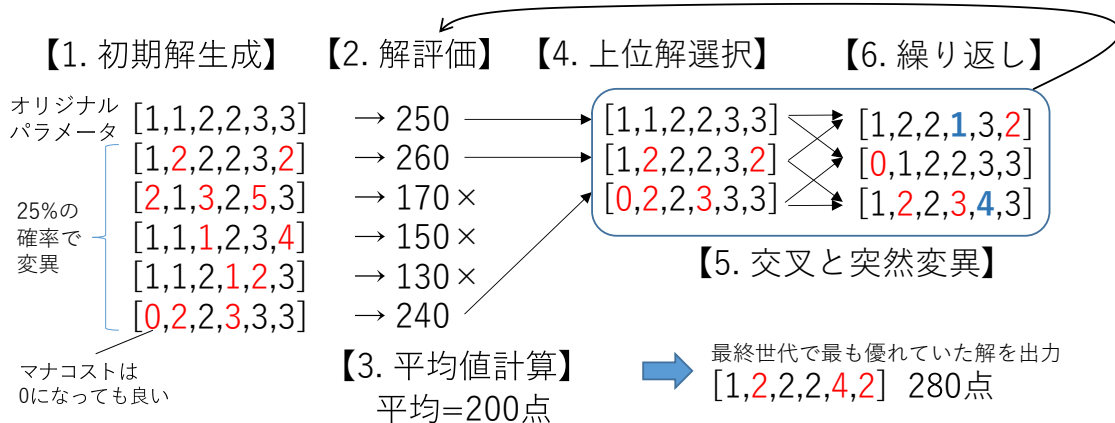


図 5.1: 実験で用いた遺伝的アルゴリズムの概念図

間に優越関係（厳密ではないが簡単に言うと、全ての目的関数で片方が優れること）が生じることが少なくなり、最適化が遅滞することが知られているからである [13]. 単目的最適化では目線の異なる多様な解が得られにくいという点については、線形和の重みをいくらか変動させて最適化を複数回行うという手段もある。

遺伝的アルゴリズムは、解表現、交叉、突然変異、世代交代などの概念をさまざまに実装する枠組みであり、解く問題の性質、求められる解の品質、使える計算資源などに合わせて具体的な実装が定められる。本研究では、(1) 探索空間はそれほど大きくないこと、(2) 最適解ではなく満足解を得られればよいこと、(3) 1つの解の評価に多くの戦闘シミュレーションを要するなど時間コストが高いこと、(4) 評価結果にランダム性からくるノイズが乗ることなどをふまえて、これらの条件に比較的適していると考えられる以下の遺伝的アルゴリズム（図 5.1 参照、ただし次元数は 6 としてある）を用いることにした。

1. n_{pop} 個の初期個体（解 $x \in X$ ）を生成する。解のうち一つはオリジナルパラメータ x^{org} とする。それ以外の解は、38 次元の数値を一旦 x^{org} と同じにしたあと、各次元を 25 % の確率で値域内のランダムな整数値に変異させる。図内ではオリジナルとの差異部分を赤字で表示している。
2. 各解 x_i について、3 つのデッキの総当たり、各 n_{bt} 戦ずつ対戦させ、評価値 $f(x_i)$ を求める。
3. 評価値の平均 $av = \sum_{i=1}^{n_{pop}} f(x_i) / n_{pop}$ を求める。
4. 平均値よりも高い評価値を持つ解の集合 $S^{sup} = \{x_i | av < f(x_i)\}$ を求める。これらは相対的に優れた解である可能性が高いので、次世代にそのまま残す（エリート戦略と呼ばれる）。
5. $av \geq f(x_i)$ となる解については削除し（図では×印で表示）、その代わりに、 S^{sup} から選ばれた 2 個体を一様交叉し、突然変異を加えたものを集団に戻す。

一様交叉とは、38次元の数値それぞれについて、親個体のどちらかからランダムに引き継ぐ操作である。突然変異では、一様交叉で得られた各次元の値について、5%の確率で値域内のランダムな整数値に変異させる（図では青い太字で表示）。

6. ステップ2. から5. を n_{gen} 世代繰り返す。最終世代のステップ2. で最も高く評価された解を出力して（図右下）、終了する。

このアルゴリズムは n_{gen} 世代行われ、それぞれの世代で n_{pop} 個体が評価され、それぞれの評価のためには $3 \cdot n_{btl}$ 戦のコンピュータ同士のシミュレーションが行われる。それ以外の部分の計算量は無視できるものであるから、およそ $n_{gen} \cdot n_{pop} \cdot n_{btl}$ に比例するだけの時間を要することになる。一般に n_{gen} が少ないと学習途中で終了してしまう恐れがあり、 n_{pop} が少ないと集団内の多様性が早期に失われ局所的な解しか見つけられず、 n_{btl} が少ないと解評価のノイズが大きくなって進化が安定しないという傾向があり、計算資源に合わせてそれぞれ適切に定める必要がある。

また、ステップ2. で、新規に作られた解のみならず S^{sup} に属してそのまま残された解も含めて評価しなおすことは無駄に見えるかもしれない。しかしもし解の再評価を行わないと、評価のランダム性のために「たまたま本来の質よりも大きく過大評価された平凡な解」が発生したまま、これを新しい解が上回るものが困難になる。この問題についてはいくつかの解決法があるが、本研究では単純に全てを毎回再評価することにした。

第6章 最適化実験

本章ではTCGにおけるゲームバランスの自動調整を行うための最適化実験の設定、結果、考察を述べる。6.1節では実験方法や実験設定、遺伝的アルゴリズムに用いたハイパーパラメータを説明する。6.2節では、主に評価値 $f(x)$ やサブ評価値 $Eval_1 \sim Eval_7$ がどう推移したのかを述べる。6.3節では、評価値計算の重みづけを変えた場合の追加実験について簡単に述べる。6.4節では、最適化されたカードのパラメータについて、どのような傾向があったか、どうやって各サブ評価値を改善しているのか考察する。

6.1 実験方法と実験設定

本研究は2章で紹介した MetaStone 環境を実験に用いる。MetaStone 環境にはいくつかのコンピュータプレイヤーが備わっており、カードのパラメータを調整することも容易であり、グラフィック表示なしに対戦を高速に行う機能もあるためである。

具体的には、高速対戦用の `gui/SimulationMode` クラス群を複製、変更することで `gui/BalancingMode` クラス群を作成した。あまり Java の標準的なクラス設計技法に則ったものではないが、`EvaluationGamesCommand` クラス内に、評価値計算機能や交叉機能、世代交代モデルなどを実装した。対戦の上流部分は `game/GameContext` クラスに実装されているので、ここに評価値計算に必要な情報を保存して評価関数部分に渡す機能を追加した。16枚のカードは `metastone/cards` 以下に、3つのデッキは `metastone/decks` 以下に既定フォーマットに沿って配置した。高速化のため、CPUのコア数スレッド数に応じて、複数の試合を並行して走らせる仕様としている。

コンピュータプレイヤーとしては、十分な速度と人間から見て不自然ではないほどの強さを持った `GameStateValueBehaviour` クラスを採用した。ただ、予備実験の結果、例えば `FlatMonteCarlo` クラスなど別のアルゴリズムによるコンピュータプレイヤーを採用した場合には、デッキの組み合わせによってはゲームの展開がかなり変わり、勝敗も場合によっては2~3割変わることが分かっている。人間プレイヤーにもさまざまな技量や好みの方がおり、「初中級者が楽しめるバランス調整」と「上級者が楽しめるバランス調整」は違うことが予想される。将来的には、コンピュータプレイヤーにも用途に合わせさまざまなものを採用すべきかもしれない。

遺伝的アルゴリズムのハイパーパラメータとしては、世代数 $n_{gen} = 20$ 、個体数 $n_{pop} = 20$ 、マッチングあたり対戦数 $n_{btl} = 100$ とした。1 試行あたり、12 万ゲームが行われることになる。実験に用いた標準的な PC での実行時間は 1 試行あたりおよそ 1 時間であった。もし性能が物足りなければ、世代数や個体数、対戦数をそれぞれ数倍程度にすることは支障ない程度の計算時間であると言える。ただし、現実的な規模のカード数（数百以上）や考慮すべきデッキ数（数十以上）を考えると、なんらかの工夫は行わないといけなかもしれない。遺伝的アルゴリズムが、勾配法やシミュレーテッドアニーリングなどに比べて優れる点として、並列化の容易さが挙げられる。5.3 節で述べた手続き 2.、つまり全個体の評価は、個体数分のマシンに振り分けて並列化すればほぼ線形の効果期待できる。今後はそのような実験も行っていきたい。

6.2 最適化結果

5.3 節前半で述べた通り、本研究では $Eval_1$ から $Eval_7$ の評価関数を加算した評価関数 $f(x) = \sum_{j=1}^7 Eval_j(x)$ を用いて、単目的最適化を行う。これを設定 1 と呼ぶことにする。

一方、Mesentier Silva らの先行研究 [4] では、 $Eval_1$ と $Eval_2$ に相当するもののみを用いて多目的最適化を行っていた。単目的最適化と多目的最適化の結果を直接比較することは困難なため、本節では加算対象を限定した評価関数 $f^{lim}(x) = \sum_{j=1}^2 Eval_j(x)$ を用いた単目的最適化の結果を比較することにする。これを設定 2 と呼ぶことにする。

6.2.1 集団全体の評価値推移




図 6.1: 設定 1 の評価値推移




図 6.2: 設定 2 の評価値推移

それぞれの設定は2試行ずつ行い、その推移を描いたものである(2試行平均)。図6.1と図6.2は、横軸を世代数に取り、縦軸に、集団内の最良評価値(青)、平均評価値(橙)、および平均の $Eval_1$ (緑)を取ってその推移を描いたものである。 $Eval_1$ を先に比較すると、どちらも220前後から始まり280前後に収束し、図6.2のほうがやや高い値となっていることが分かる。設定2で用いた評価関数 $f^{lim}(x)$ は特定の“良さ”のみを最適化するため、ある意味それらに特化した解を得られやすい。一方で設定1は7つの評価関数を総合的に最適化しなければならないハンデを持っているが、評価値の差はわずかである。

どちらの図でも、緑の線と橙の線は概ね連動して動いている。これはどちらも全個体の平均値をとっている(青は異なる)ことに加え、全ての評価関数の中で $Eval_1$ が最も影響力を大きく設定されているからである。左右の図で比較したとき、緑の線は概ね似た値であるが、青や橙の線は異なる。これは、設定1では $Eval_3$ から $Eval_7$ までがペナルティとして負の値をとって評価値に加算されるためである。つまり、設定1のほうが全体的に下にあるからといって、設定1が最適化に失敗しているわけではない。

最後に、最良評価値(青)の推移をみると、どちらも世代10前後で頭打ちとなっていることが分かる。今回用いたGAの設定では、世代数 $n_{gen} = 20$ は十分な値であったということを示している。

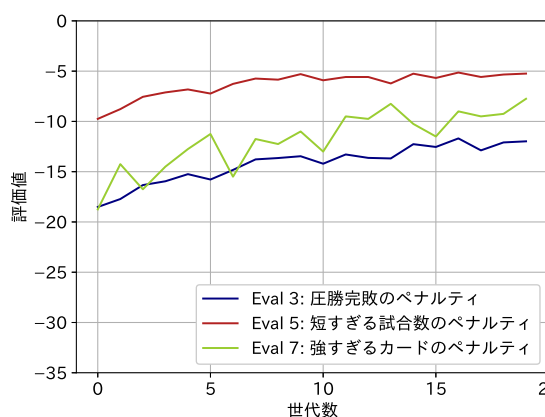


図 6.3: 設定1の $Eval_{3,5,7}$ の推移




図 6.4: 設定2の $Eval_{3,5,7}$ の推移

次に、 $Eval_1$ 以外のサブ評価関数の推移について見てみる。図6.3と図6.4は、横軸を世代数、縦軸に集団の平均の $Eval_3$ (紺)、 $Eval_5$ (赤)、 $Eval_7$ (黄緑)を取ってその推移を描いたものである。設定1ではこれらの値は全体的に世代を経るごとに向上しているのが分かる。一方設定2では概ね最初から最後まで上昇傾向が見られず、最終的な値も設定1に比べ3から6程度劣る。設定2ではこれらの値は進化の際の生存選択・複製選択に関与していないので、改善しないのは仕方のないことである。




図 6.5: 設定 1 の $Eval_{2,4,6}$ の推移




図 6.6: 設定 2 の $Eval_{2,4,6}$ の推移

続いて、図 6.5 と図 6.6 は、横軸を世代数、縦軸に集団の平均の $Eval_2$ (水色)、 $Eval_4$ (朱色)、 $Eval_6$ (緑) を取ってその推移を描いたものである。 $Eval_2$ はどちらもやや悪化傾向が見られ、設定 1 のほうが 5 程度劣る。これは、少数の評価関数だけを最適化すればよい設定 2 に比べ、設定 1 は多くの評価関数を最適化する必要がある、そのためにはより多くの (5.5 個くらいではなく 6.5 個くらいの) パラメータ調整が必要になったということである。 $Eval_4$ についてはどちらも大きな変化はなく、十数パーセントの試合で 23 ターン以上かかっている。この点については、6.3 節で追加の実験を行っている。 $Eval_6$ についてはどちらも進化序盤で性能向上したあとはそれほど値が変わっていないが、平均的には設定 1 のほうが数ポイント優れる。

平均評価値を見る際に注意すべきなのは、5.3 節で説明した世代交代モデル (ステップ 4. から 5.) の場合、交叉や突然変異など解の質を大幅に落とす可能性のある操作を行ったあと、生存選択を行わずにそのまま集団に戻す点である。すぐに淘汰されるような悪い個体が複数含まれる場合、その平均評価値だけでは挙動を正しく分析できない場合がある。これは、親を選び、子を複数生成し、親と子の中から優れたものだけを残すタイプの世代交代モデル [14] とは違う点である。

6.2.2 個体評価値の比較

本項では、集団全体の傾向しか分からない平均評価値ではなく、実際に利用される可能性のある一つ一つの個体の評価値を比較する。具体的には、オリジナルパラメータ (4 回評価)、設定 1 と 2 の最終世代最良個体 (2 試行ずつ、それぞれ 1 回評価)、計 8 つを見ていく。表 6.1 に、各個体の評価結果を示す。左から、3 つのデッキマッチごとの勝率 (w_1 が ATK 対 BLK, w_2 が BLK 対 SPL, w_3 が SPL 対 ATK)、 $Eval_1$ から $Eval_5$ 、使われないカード ($Eval_6$ はこの枚数に -10 をかけた

もの), 強すぎるカード (同 $Eval_7$) である. 使われないカードと強すぎるカードはデッキマッチごとに計算されているので, 一部, 同じカードが2回以上出てくることがある. 使われないカードの後ろには, $n_{btl} = 100$ 戦中何試合で使われていないかが記載されている. 強すぎるカードの後ろには, $t^{lose} - t^{win}$ が記載されている.

表 6.1: オリジナルパラメータ, 設定 1,2 の最良個体の評価値

個体	$w_1/w_2/w_3$	$Eval_1$	$Eval_2$	$Eval_3$	$Eval_4$	$Eval_5$	使われない カード	強すぎる カード
x^{org}	0.82/0.51/0.79	225.4	0.0	-18.7	-7.8	-8.7	-	嵐 4.1, 嵐 3.7
	0.76/0.52/0.78	241.4	0.0	-19.3	-7.2	-9.2	不幸な事故 85	嵐 3.8, 預言者 4.0
	0.80/0.57/0.75	237.0	0.0	-19.2	-8.0	-10.7	聖騎士 81, 不幸な事故 84	嵐 4.0
	0.77/0.53/0.79	236.8	0.0	-17.2	-7.2	-9.7	不幸な事故 84	嵐 3.2, 預言者 3.1
設定 1	0.44/0.55/0.66	287.3	-25.0	-11.0	-7.8	-3.3	-	-
	0.43/0.51/0.62	292.2	-20.0	-11.7	-6.7	-4.3	-	-
設定 2	0.61/0.51/0.60	291.1	-20.0	-17.2	-5.5	-8.2	不幸な事故 83	聖騎士 3.1, 嵐 4.1
	0.55/0.53/0.57	296.7	-25.0	-12.7	-6.8	-6.0	不幸な事故 82	聖騎士 3.0, 嵐 3.1, 預言者 3.3

まずオリジナルパラメータ x^{org} について見てみると, ATK デッキが BLK デッキに強く, SPL デッキが ATK デッキに強く, それぞれ勝率 w_1 と w_3 が 8 割程度とバランスが悪いことが分かる. $Eval_3$ は -19 程度であり, つまり 4 割程度の試合で勝利側ヒーローの HP は 10 のままである. $Eval_5$ は -9.5 程度で, つまり 2 割程度の試合が 6 ターン以下で終わってしまう. そして, 不幸な事故や聖騎士はあまり使えない場合が多く, 嵐や預言者は早め引くと勝ちやすく, 引けなければ負けやすいパワーカードとなっている.

次に設定 1 をとばして設定 2 を見てみると, 勝率 w_1 から w_3 はかなり五分に近づいていると同時に, オリジナルのパラメータから 4 または 5 項目を変更するだけで済むことが分かる ($Eval_2$). $Eval_3$ から $Eval_5$ は微妙に改善しているが, 使われないカード・強すぎるカードについては傾向に違いはない.

最後に, 提案手法である設定 1 を見ると, 設定 2 にはやや劣るが勝率 w_1 から w_3 を五分に近づけられていることが分かる. 図 6.5 と図 6.6 の比較の際の分析とは異

なり、最良解の比較では変更パラメータ数は同じであった ($Eval_2$)¹. $Eval_4$ の値はむしろ設定2よりも悪くオリジナルとほぼ変わらないが、 $Eval_3$ と $Eval_5$ は明確に改善できている. そして、使われないカードと強すぎるカードを1枚もなくしている点は特筆すべきことである. どのようにしてこれら多数の評価関数を調整しているのかについては、6.4節で述べる.

6.3 $Eval_4$ についての追加実験

6.2節の実験結果から提案手法(設定1)は、数個のパラメータ変更によって $Eval_1$, $Eval_3$, $Eval_5 \sim Eval_7$ をオリジナルパラメータ x^{org} に比べて大きく改善できることが分かった. 一方で、 $Eval_4$ すなわち長すぎるゲーム数に関するペナルティについては、集団の平均の推移(図6.5朱色)でも、最良個体(表6.2)でも殆ど改善が見られなかった. この理由としては、試合が長引く状況を回避するための手立てが限られ、しかもそれが他の評価値(例えば、試合が短すぎるペナルティ)に影響を及ぼしやすいということが予想される.

本節では、このように改善が難しい項目(サブ評価値)があった場合に、それを重視するように重みづけを変えた総評価値を用いることで事態を改善できるかを確かめる. 5.2節最後で述べたように、 $Eval_4$ の重み -50 は適当に定めたものである. もし長すぎるゲームがプレイヤーの不満度に大きな影響を与えることが今後分かったとしたら、その重みを増やしてみることは合理的な手立てである.

そこで、設定3として、 $Eval_4$ の重みを4倍の -200 にした場合の最適化も2試行行ってみた. 表6.2に、設定1(重み -50) と設定3それぞれの最終世代最良個体の評価値を示す. 使われないカード ($Eval_6$), 強すぎるカード ($Eval_7$) はどちらも一枚も存在しなかったので省略する.

表 6.2: 設定 1,3 の最良個体の評価値. 二つの設定での合計値も付す.

個体	$w_1/w_2/w_3$	$Eval_1$	$Eval_2$	$Eval_3$	$Eval_4$	$Eval_5$	合計(重み -50換算)	合計(重み -200換算)
設定1 試行1	0.44/0.55/0.66	287.3	-25.0	-11.0	-7.8	-3.3	240.2	216.8
設定1 試行2	0.43/0.51/0.62	292.2	-20.0	-11.7	-6.7	-4.3	249.5	229.4
設定3 試行1	0.41/0.39/0.62	286.2	-20.0	-10.5	-20.0	-3.5	247.2	232.2
設定3 試行2	0.49/0.55/0.70	283.0	-35.0	-15.2	-20.7	-3.0	224.6	209.1

$Eval_4$ に着目すると、見かけの数値としては設定3のペナルティが大きいですが、300試合中の長すぎる試合数に換算すれば、平均43.5試合から平均30.5試合に減らされており、設定3の目的自体はある程度達成されている. 設定3の1試行目と2試行

¹これは試行数が2と少ないので、たまたまなのかは不明である

目は大きく評価値が異なっており、1 試行目は合計の評価値でも設定 1 に負けない値であるが、2 試行目は、7つのパラメータ変更を要し、 $Eval_3$ すなわち短すぎる試合に対するペナルティも大きくなってしまっている。ある程度定量的な評価を行うためには 10 試行程度は行う必要があるだろうが、基本的には、設定 1 では重み -50 換算の合計値が良い値に、設定 3 では重み -200 換算の合計値が良い値になる傾向があると考えられる。

6.4 変更されたカードの分析

本節では、設定 1, 設定 3 で得られたパラメータについて、どのような機序で評価値を改善させているのかを論じる。これは対戦ログのいくつかを目視で追って分析したものであって、統計的な分析ではない。まず表 6.3 に、設定 1, 設定 3 で得られた解の x^{org} からの変更をまとめる。

表 6.3: 設定 1,3 の最良個体の x^{org} との差異

個体	ATK デッキの変更	BLK デッキの変更	SPL デッキの変更
設定 1 試行 1	双剣士コスト+1	海竜コスト-1	魔術師体力+2, 預言者体力-1
設定 1 試行 2	-	盾兵と聖騎士コスト-1, 不幸な事故コスト+1	魔術師体力+1
設定 3 試行 1	指揮官とパンチ コスト+1	盾兵コスト-1	預言者体力+1
設定 3 試行 2	双剣士とパンチと 速攻兵コスト+1	-	魔術師攻撃力+1 体力+2, 預言者攻撃力-1

オリジナルパラメータの課題はおおまかに、(1)ATK デッキが BLK デッキに勝ちすぎる、(2)SPL デッキが ATK デッキに勝ちすぎる、(3)不幸な事故が使われにくい、(4)嵐と預言者が強すぎる、といった点である。

例えば設定 1 の ATK デッキと BLK デッキの変更を見ると、どちらの試行でも、ATK デッキが維持または弱化しており、BLK デッキは強化されている。これによって、(1)の課題を解消しようとしている。BLK デッキが強化された分、SPL デッキも強化しなければ、BLK デッキと SPL デッキの勝率が崩れるため、SPL デッキも強化されている。このとき、魔術師の体力が向上することは、ATK デッキよりも BLK デッキに対して効果的である点が、三すくみを緩和するポイントとなっている。魔術師は魔法カードのダメージを 1 増やすが、ATK デッキのカードはもともと体力が低くこの効果がなくても一撃死するため、存在価値が ATK デッキに対しては相対的に小さいのである。

全体的に見ると、4つの解はそれぞれ異なるものの、ATK デッキのコストを上げるものが多い、BLK デッキのコストを下げるものが多い、魔術師の体力を上げるものが多いという特徴がある。魔術師の体力については前段落で述べた通りであるが、他の2つについては、ATK デッキと他のデッキの典型的な戦闘のかけひきに関連している。ATK デッキは、全体的にコストが低く、序盤からミニオンを多数出す“ことができる”。この勢いは他のデッキがミニオンで対抗できるようなものではないが、一方でBLK デッキとSPL デッキには、嵐というコスト3で全ての敵ミニオンに2ダメージを与える（つまりATK デッキのミニオンは全て倒す）魔法カードがある。ATK デッキのプレイヤーが多くのミニオンを場に出して次ターンの総攻撃を狙った瞬間に嵐を持っていれば、場を一掃してBLK/SPL デッキのプレイヤーは優位に立つことができる。そのため、15枚中2枚または3枚の嵐を序盤に引けるかどうか、対ATK 戦では極めて重要になる。これが嵐が強すぎると判定されるゆえんである。

さて、調整後のATK デッキでは、コストが上がっている場合が多い。コストが上がるということは、オリジナルパラメータほど序盤からカードを多く場には出せないということである。これは間違いなく弱化であるのだが、結果的に、嵐の効果を緩和することができる場合が多い。つまり、全てのカードを場に出した瞬間に嵐で一掃されるよりも、何枚か被害が小さく済み残った手札で勝負を続けることができるのである²。この効果によって、弱化されたはずのATKは、SPLに對しある程度勝てるようになり、(2)の課題が緩和されていると考える³。そして、嵐、および嵐を引くチャンスを与える預言者について、その効果が減じるために、(4)の課題も緩和される。

ATK デッキのコストが上がりBLK デッキのコストが下がることは、勝率の面で両者を互角にすること以上の効果がある。特にBLKが嵐を序盤で引けない場合、オリジナルパラメータではATKが序盤で圧倒して、5ターン前後で体力10のまま完勝してしまうことも珍しくない。これが、ATKの攻勢を遅らせ、BLKの対応を早めることで、多少なりとも試合が長引くことが増え、完勝完敗のペナルティ $Eval_3$ や短すぎる試合のペナルティ $Eval_5$ の改善に繋がっている。同時に、試合が長引くことは、引けるカードの枚数やカードを使うチャンスを増やすことになり、(3)の課題の緩和にも繋がっている。

以上、少ない試行数や目視のログ分析に基づくものであり、またある程度納得性の高い説明ができるものについてだけ述べたが、おおむね一定の合理性がある結果であると考えている。

²熟達したプレイヤーであれば、オリジナルパラメータの場合でもわざと数枚を手札に残して嵐の効果を緩和する戦い方もできるであろうが、本実験で採用した GameStateValueBehaviour クラスではそれが上手にはできていなかったようである。

³なお、設定1 試行2ではATK デッキのカードに変化がないのにATK デッキのSPL デッキに対する勝率が0.22から0.38に改善する。この理由は本文で述べた理屈では説明できず、未解明である。

第7章 おわりに

HearthStoneなどのトレーディングカードゲームは、数百枚以上のカードから相性を考えて組み合わせたデッキによって相手と戦うゲームである。10年以上サービスされカードが徐々に追加されているゲームもあるが、「新しいカードが魅力的であること」と「新しいカードが強すぎないこと」は本質的に対立する要請であり、ゲームデザイナーにとって常に難しい問題になっている。

人工知能（AI）技術の発展に伴い、ゲームバランス調整をAIに行わせる研究も進んできた。HearthStoneのパラメータ調整の先行研究として、あるカード群とデッキ群を固定したうえで、各カードのパラメータを「(1) デッキ間の勝率ができるだけ五分に近づくように」かつ「(2) もとのカードからの調整箇所ができるだけ少ないように」進化的アルゴリズムで最適化するものがある。我々は、この2つの方向性の重要性は認めたとうえで、楽しいゲームプレイのためにはもっと他の要素も必要であると考え、これらも含めて10個の要件を提案した。

そのうえで、パラメータ調整だけで達成ができると考えた要件について、(1)(2)を含めて計7つのサブ評価関数を定義し、この7つを同時に最適化するための遺伝的アルゴリズムを実施した。この結果、(1)(2)だけを目的関数として最適化を行う場合に比べ、それほど(1)(2)を劣化させることなく、残りの5つの評価関数をかなり改善することができた。さらに、パラメータが変更されたカードを分析することで、どのようにして7つのサブ評価関数が改善されているのか、一定程度納得のいく説明をつけることができた。

本研究は、7つの評価関数の重みづけが特に根拠なく決められたものであること、実験の試行回数が少ないこと、得られたデッキでの被験者実験がないことなど、いくつかの意味で未熟な研究であり、今後の課題としたい。将来的には、どのような試合やデッキが面白いのかを被験者実験のデータから教師あり学習することでより高度な評価関数を作ったり、デッキ自動作成機能を組み合わせてカードセット全体の最適化したりといった展開も視野に入っている。

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] Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D. and Riedmiller, M.: Playing atari with deep reinforcement learning, *arXiv preprint arXiv:1312.5602* (2013).
- [3] Liang, Y., Li, W. and Ikeda, K.: Procedural content generation of rhythm games using deep learning methods, in *Entertainment Computing and Serious Games: First IFIP TC 14 Joint International Conference, ICEC-JCSG 2019, Arequipa, Peru, November 11–15, 2019, Proceedings 1*, pp. 134–145Springer (2019).
- [4] Mesentier Silva, de F., Canaan, R., Lee, S., Fontaine, M. C., Togelius, J. and Hoover, A. K.: Evolving the hearthstone meta, in *2019 IEEE Conference on Games (CoG)*, pp. 1–8IEEE (2019).
- [5] Da Silva, A. R. and Goes, L. F. W.: Hearthbot: An autonomous agent based on fuzzy art adaptive neural networks for the digital collectible card game hearthstone, *IEEE Transactions on Games*, Vol. 10, No. 2, pp. 170–181 (2017).
- [6] García-Sánchez, P., Tonda, A., Squillero, G., Mora, A. and Merelo, J. J.: Evolutionary deckbuilding in hearthstone, in *2016 IEEE Conference on Computational Intelligence and Games (CIG)*, pp. 1–8IEEE (2016).
- [7] Bartle, R.: HEARTS, CLUBS, DIAMONDS, SPADES: PLAYERS WHO SUIT MUDS, <https://mud.co.uk/richard/hcde.htm>: (Accessed on 01/27/2024).
- [8] バートルテストとは | 概要やビジネスにおける利用方法を紹介します, <https://library.musubu.in/articles/37972>(Accessed on 01/27/2024).

- [9] Turkey, S. and Adinolf, S.: Understanding online collectible card game players' motivations: a survey study with two games, in *Proceedings of the 30th Australian Conference on Computer-Human Interaction*, pp. 501–505 (2018).
- [10] Fontaine, M. C., Lee, S., Soros, L. B., Mesentier Silva, de F., Togelius, J. and Hoover, A. K.: Mapping hearthstone deck spaces through map-elites with sliding boundaries, in *Proceedings of The Genetic and Evolutionary Computation Conference*, pp. 161–169 (2019).
- [11] Mouret, J.-B. and Clune, J.: Illuminating search spaces by mapping elites, *arXiv preprint arXiv:1504.04909* (2015).
- [12] Kuboki, K., Hsueh, C.-H. and Ikeda, K.: Factor Analyses on Positive and Negative Evaluations of Games against Go Programs, in *The 28th International Conference on Technologies and Applications of Artificial Intelligence (TAAI 2023)* (2023).
- [13] Ikeda, K., Kita, H. and Kobayashi, S.: Failure of Pareto-based MOEAs: Does non-dominated really mean near to optimal?, in *Proceedings of the 2001 congress on evolutionary computation (IEEE Cat. No. 01TH8546)*, Vol. 2, pp. 957–962IEEE (2001).
- [14] 佐藤浩, 小野功, 小林重信: 遺伝的アルゴリズムにおける世代交代モデルの提案と評価, *人工知能*, Vol. 12, No. 5, pp. 734–744 (1997).