

機械学習手法を用いた動的難易度調整の研究事例に関する考察

A Study on Dynamic Difficulty Adjustment using Machine Learning Method

郷津優介¹⁾, 稲邑哲也¹⁾

Yusuke GOUTSU and Tetsunari INAMURA

1) 玉川大学 脳科学研究所 (〒 194-8610 東京都町田市玉川学園 6-1-1, {goutsu, inamura}@lab.tamagawa.ac.jp)

概要: 難易度調整において、ユーザーの内発的動機付けを最大化するためには、適切な難易度によるパフォーマンスの向上だけでなく、難易度調整に必要なパフォーマンスの観測回数や設定できる目標値の自由度なども深く関係してくる。本研究では、難易度調整に関してアプローチによる分類を通して体系的に整理し、様々な分野における動的難易度調整の手法に対して上記のような観点に着目して考察する。考察の結果、ユーザーの精神的負担を考慮した場合、どの機械学習手法を取り入れた DDA 手法が有望であるかを決定する。

キーワード: 難易度調整, 機械学習, ユーザーモデル, ユーザー体験

1. はじめに

ゲーム・スポーツ・リハビリ・教育の分野を中心に、タスクにおけるユーザーの内発的動機付け（エンゲージメント、モチベーションなど）を最大化するために、個々のユーザーのスキルに応じて適切な難易度を提供する手法の必要性が高まってきている。これらの中でも、個人に適応させた難易度を即時的に自動調整する動的難易度調整（Dynamic difficulty adjustment: DDA）と呼ばれる手法が注目を浴びている [1][2][3]。DDA の指針において、アメリカの心理学者 Csikszentmihalyi により提唱されたフロー理論 [4][5] に基づくものが多い。そのような難易度調整では、挫折しない程度に難易度を低く抑えつつも、タスクへの関与を促す程度に高くする、というトレードオフの状態を保とうとする。フロー理論というのは、そのようなトレードオフの状態をフローと呼び、フロー体験を通してより高度なパフォーマンスを発揮する人間へと成長・拡張していく過程を理論化したものである。これにより、精神状態がフローになるように難易度を調整して、パフォーマンスを向上させることなどに焦点を当てた研究が多くなってきている。しかし、ユーザーの内発的動機付けを高める心理要因は、難易度調整によるパフォーマンスの向上だけでなく、難易度調整に掛かるパフォーマンスの観測回数や設定できる目標値の自由度なども深く関係してくる。つまり、どんなに正確に難易度を調整できても、ユーザーの精神的負担になるコスト（ユーザーコスト）が高ければその効果が発揮されないこともあるため、上記の難易度調整の応答性や目標自由度に關することを考慮することは重要である。

本稿では、様々な分野における難易度調整をアプローチによる分類を通して体系的に整理し、その中でも DDA の研究事例に対してユーザーコストなどに着目して考察してい

く。これに関して、近年のタスクの複雑化に伴って、DDA にも機械学習手法が取り入れられるようになってきた。また、DDA を様々な場面で活用していく上で、(1) ユーザーごとに少数の観測だけで目標値まで調整できる、(2) 任意の難易度を目標値として設定できる、(3) 大規模データセットによる事前知識を必要としない、の 3 つの要素が重要視されている [6][7]。特に、(1)(2) は難易度調整の応答性や目標自由度に関係するものであり、ユーザーコストの削減に繋がる可能性がある。そのため、具体的な目的として、機械学習手法による DDA に焦点を当て、且つ (1)(2) を中心に考察していく。考察の結果、ユーザーコストを考慮した場合、どの機械学習手法を取り入れた DDA 手法が有望であるかを決定していく。しかし、学習モデルを構築する場合、計算資源・学習時間などが膨大になるだけでなく、多くの実験参加者（上記のユーザーのことではない）が必要になることもある。これは (3) に関係することである。そのため、システム開発に掛かるコスト（システムコスト）やその軽減方法に関しても考慮して決定していく。

2. 難易度調整

まずは、DDA というものが難易度調整の中でどういった調整カテゴリに入るのかを示す。次に、機械学習手法を取り入れたいくつかの DDA 手法に関して、それらの研究内容を説明した上で比較していく。

2.1 アプローチによる分類

図 1 は、難易度調整に関してアプローチによる分類を通して体系化したものである。オフラインのカテゴリは、事前に定義されたタスクの難易度設定（easy, normal, hard など）から難易度を選択し、固定された難易度をユーザーに提供するものである。これとは逆に、リアルタイムのカテゴリにおける難易度は、タスクの試行中に変更される。この

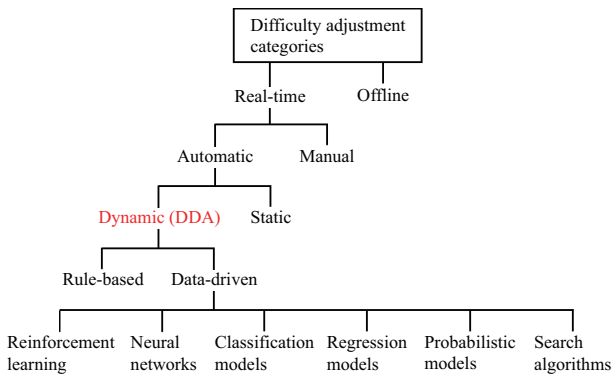


図 1: 難易度調整のアプローチによる分類

変更方法は手動と自動の2つのカテゴリに分類できる。手動のカテゴリでは、例としてユーザー指向型の難易度調整として知られるものがあり [8], ユーザーはタスクの難易度を変更できる。一方、自動のカテゴリは静的と動的の2つのカテゴリに分類できる。前者では、ユーザーのスキルに関係なく、タスクの進行に伴う移動時間・距離などに基づいて難易度が変化していく。後者では、難易度はユーザーに対して個別化されるべきであるとして、ユーザーのスキルや感情状態に基づいて難易度を提供する。この調整カテゴリを DDA と呼ぶ。DDA 手法は、ルールに基づいてタスクの難易度を変化させるルールベースと機械学習問題として定式化したデータドリブンの2つのカテゴリに分類できる。これらに関して、次節で詳細に説明していく。

2.2 動的難易度調整 (DDA)

難易度調整に関する多くの研究が、ユーザーのスキルや感情状態に基づいて自動的に且つ即時的に難易度を調整する DDA 手法を開発している。

2.2.1 ルールベース DDA

ルールベース DDA では、タスクの難易度を変更するために、予め簡単なルールを定義しておく。ルールはユーザーのパフォーマンスに対するスコアや応答時間などに基づくものであり、タスク試行中に特定のルールが適用されると、タスクの難易度を変更される。多くの研究が、ルールベース DDA 手法と非適応なものを比較して、ユーザーのパフォーマンスなどに与える影響を調査している。

2.2.2 データドリブン DDA

データドリブン DDA では、タスクの難易度を調整するために、統計的な機械学習の技術を利用することでユーザーの行動や経験をモデル化する。機械学習は、コンピュータやシステムが明示的なプログラミング無しにデータからパターンや法則を自動的に見出すためのものである。データドリブン DDA 手法では、ユーザーのスキルだけでなく感情や性格特性などもモデル化されており、ユーザーの行動や経験のいくつかの側面を予測している。本稿では、図 1 に示すように、データドリブン DDA 手法を取り扱っている機械学習手法により 6 種類に分類する：強化学習、探索アルゴリズム、分類モデル、回帰モデル、確率モデル、ニューラルネットワーク。以下では、参考として、それぞれの種類

における DDA 手法の研究事例をいくつか列挙しておく。

強化学習 (Reinforcement learning: RL): Pagalyte [12]

らは、RL のフレームワークを用いてターン制格闘ゲームに DDA 手法を導入した。エージェントには SARSA (State-Action-Reward-State-Action) アルゴリズムによる制御設計が組み込まれており、ユーザーのスキルに合わせた行動の選択により難易度を増減させることで、格闘ゲームにおける勝敗のバランスを取っている。Zhang [13] らは、教育システムのための視覚記憶ゲームにおいて、DDA を RL 問題として定式化するために、多腕バンディットとブートストラップ方策勾配 (Bootstrapped policy gradient: BPG) の RL フレームワークを検討した。クラスタリングに基づくアプローチとユーザーの最新のプレイ履歴から個人に合わせたタスクの難易度ランキングを逐次的に更新しており、そのランキングに基づく方策により確率的に難易度を調整する。

探索アルゴリズム: モンテカルロ木探索 (Monte Carlo tree search: MCTS) は、ヒューリスティックな探索アルゴリズムであるため、短時間での応答が必要な格闘ゲームにおいて効果的に適用されている。例えば、対戦相手のプレイスキルに応じた DDA において、対戦相手と互角に戦えるように行動選択方針を学習する AI エージェントの設計に用いられている。Ishihara [15] らは、ユーザーのプレイ意欲が損なわれないように、MCTS による行動選択において AI エージェントの不自然な行動を抑制する DDA 手法を提案した。Moon [16] らは、ユーザーのゲーム体験を向上させるために、ユーザー状態予測モデルを利用した MCTS により AI エージェントの次の行動を選択する DDA 手法を提案した。

分類モデル (Classification model: CM): Blom [9] らは、ユーザーの感情状態とゲーム内の難易度設定の関係に焦点を当てることで、個々のユーザーに最適な難易度に収束させる DDA 手法を提案した。頭部の姿勢を考慮した表情分析から感情データを取得し、ランダムフォレスト分類器 (Random forest classifier: RFC) を用いてユーザーの挑戦レベル (知覚された難易度) をオンラインで予測する。また、この時に得られる予測値に対する確率分布により、ゲーム内の難易度を調整する。

回帰モデル (Regression model: RM): Fernandes [7] らは、ロジスティック回帰により特定の失敗確率に直接的に難易度を適応させる DDA 手法を提案した。最初のステップでは、難易度を上下変動させる単純な DDA アルゴリズムに依存する。しかし、その中で必要最小限のデータポイントを収集すると、ロジスティック回帰に切り替わる。ロジスティック回帰では、特定の失敗確率に対応する単一のメタ変数を推定する。

確率モデル (Probabilistic model: PM): Elo レーティングシステムは、各プレイヤーに評価 (レーティング) を割り当てて、同じようなレーティングのプレイヤー同士を対戦させて、各対戦後にレーティングを更新するものである。教育システムなどを中心に Elo ベースの DDA が開発されており、その場合には教材に対する生徒の答えを生徒と教

表 1: DDA 手法のユーザーコストとシステムコストに関する項目の詳細

Reference	Category	Method	Dataset collection	Target of DDA	Iterations for convergence
[7]	RM	δ -logit	One participant	Specific state	15
[9]	CM	RFC	Many participants	Balanced state	12
[10]	PM	GPDM	One participant	Specific state	14
[11]	PM	Glicko rating	One participant	Balanced state	10
[12]	RL	SARSA	One participant	Balanced state	Several to a dozen times
[13]	RL	BPG	Many participants	Balanced state	20
[14]	NN	Affective model	Many participants	Balanced state	10

材の対戦として解釈している。Schadenberg [11] らは、子供とロボットのインタラクションを向上させるために、子供とゲーム課題を対象にしたレーティングシステムにより、ゲーム課題の難易度を子供のスキルに適応させる DDA 手法を設計した。両者のレーティングの推定には、Elo の拡張としてレーティングの不確実性を考慮した Glicko レーティングシステムを利用する。Goutsu [17][10] らは、VR 環境におけるけん玉タスクにおいて、難易度と成功確率の関係を確率的に捉えることにより、特定の成功確率に対応する難易度を取得する手法を提案した。難易度と成功確率の関係のモデル化には、ガウス過程動的モデル (Gaussian process dynamical model: GPDM) を利用している。

ニューラルネットワーク (Neural network: NN): Chanel [14] らは、ユーザー適応にはゲームのパフォーマンスだけでなくプレイ中の感情状態も重要であるとして、テトリスゲームに感情モデルを用いた DDA 手法を提案した。深層学習を用いた感情モデルは、ユーザーの生理学的信号から不安と退屈を検出し、それらの境界線の感情状態になるような適応戦略を取ることで難易度を調整する。

3. 動的難易度調整の研究事例に関する考察

表 1 は、前章で説明した DDA 手法に対して、ユーザーコストとシステムコストに関する項目をまとめたものである。ユーザーコストに関しては 5,6 列目の項目が、システムコストに関しては 4 列目の項目がそれぞれ対応している。ただし、前章での論文において当該項目に関する記載がなかったものは除外している。

3.1 ユーザーコストの観点からみた考察

表中の “Iterations for convergence” の項目は、難易度調整の目標を達成するまでに必要になったパフォーマンスの観測回数を表しており、先述の難易度調整の応答性に関するものである。表から分かるように、観測回数の範囲は、少ない時は 10 前後で多い時は 20 前後になっている。また、[11] と [14] は、比較的観測回数が少ないことが分かる。ただし、この項目の数値は、個々の研究で扱っているタスクや観測するパフォーマンスの種類にも依存するため、単純にそれらを比較することで優劣を決定できるという訳ではない。例えば、[10] は毎回同じけん玉タスクで且つ身体動作を観測するが、[11] は異なる算数課題で且つ計算処理を観

測するものである。そのため、難易度変更にかかる時間や難易度が収束するまでの時定数など、他の項目も加味して比較する必要がある。これは今後の課題になる。

また、表中の “Target of DDA” の項目は、先述の難易度調整の目標自由度に関するものである。この項目より、大半の DDA 手法が難易度をバランスの取れた状態 (成功/失敗確率 50%) に導くためのものであり (Balanced state)、特定の成功/失敗確率を目標とする研究 (Specific state) は少ないことが分かる。しかし、ユーザーのモチベーションを高めるためには、勝率は半々よりも少し高くすることが良いと知られており [6][18]、特定の目標値への調整は必須なものである。これに関連して、ゲームプレイヤーの行動や経験を予測するためのプレイヤーモデリングは、DDA 手法と統合することにより、ゲームの難易度をプレイヤーごとに調整できるために有望である [3]。プレイヤーモデルにおいて、プレイヤーとゲーム状態の間をマッピングする近似関数の表現力が高ければ、特定の目標値への調整はさらに正確になる。そのため、ゲーム分野におけるいくつかの研究が、プレイヤーモデリングに NN を中心とした機械学習技術を使用している [19][20]。また、プレイヤーの行動モデリングにおける様々な手法との比較の中で、NN を用いた深層学習が個々の行動予測や行動表現という点で最適であることが示されている [21]。格闘ゲームにおいて、プレイヤーの行動を個々に表現することができれば、元のプレイヤーとほぼ同じスキルを持ったエージェントの行動を生成することができる。実力が拮抗した自分自身に挑戦することは、自分自身の行動に適応し克服しなければならないことで、継続的で強力な DDA を促進する。以上のことは、格闘ゲームでの話に限らず、様々な分野の DDA に応用できると考えられる。

3.2 システムコストの観点からみた考察

表中の “Dataset collection” の項目は、それぞれの機械学習手法で用いられたデータセットが、一人の実験参加者から収集されたものか (One participant)、或いは多くの実験参加者から収集されたものか (Many participants) を表している。多くの実験参加者から学習データを収集する必要がある場合、それらの手法はシステムコストが高くなるという懸念点がある。[9] と [14] は異なるスキルを持つ複数の実験参加者からの表情データを学習器の入力とするため

に, [13] は収集データから構築された複数クラスタを用いてユーザーに最適なタスクの難易度ランキングを取得するために, それぞれシステムコストを負担している. しかし, システムコストを削減するために, データ拡張と呼ばれる学習データを水増しする手法がある. 例えば, 深層強化学習を用いた VR エクサゲームの DDA 手法において, シミュレーション上で作成した膨大な人工データを NN の事前学習に利用している事例がある [22]. また, 大量の人工データに一人のユーザーから取得した少量データを加えたデータセットを用いることで, 高速ユーザー適応のための NN を学習している事例もある [23]. 上記手法においても, データ拡張技術を取り入れることで, 将来的にはシステムコストを削減できると考えられる.

4. おわりに

DDA と呼ばれる動的難易度調整において, 適切な難易度によるパフォーマンスの向上だけでなく, ユーザーの精神的負担になるコストを考慮することも重要である. そのため, 機械学習手法を取り入れたいくつかの DDA 手法に対して, 難易度調整の応答性や目標自由度に関するユーザーコストを中心に, 学習モデルの運用に必要な実験参加者数に関するシステムコストも含めて調査及び考察した. 考察の結果, ニューラルネットワークを用いた DDA 手法に対して, 以下の 3 点を結論付けることができた: さらに詳細な調査及び考察が必要になるが, 他の手法と比べて比較的少ないパフォーマンスの観測回数で DDA の目標に収束できること, ユーザーの行動や経験のモデリング技術が発展してきており, ユーザーモデルの予測性能や表現力が高まることで難易度調整の目標値が自由に設定できるようになること, データ拡張技術を取り入れることで必要な実験参加者数を削減できること. したがって, ユーザーコストを考慮した場合, ニューラルネットワークを用いた DDA 手法が有望であると考えられる.

謝辞 本研究は, JST【ムーンショット型研究開発事業】グラント番号【JPMJMS2034】の支援を受けたものです.

参考文献

- [1] F. Mortazavi, H. Moradi, and A.-H. Vahabie, "Dynamic difficulty adjustment approaches in video games: A systematic literature review," *Multimedia Tools and Applications*, pp. 1–48, 2024.
- [2] P. D. Paraschos and D. E. Koulouriotis, "Game difficulty adaptation and experience personalization: A literature review," *International Journal of Human-Computer Interaction*, vol. 39, no. 1, pp. 1–22, 2023.
- [3] M. Zohaib, "Dynamic difficulty adjustment (DDA) in computer games: A review," *Advances in Human-Computer Interaction*, vol. 2018, no. 1, p. 5681652, 2018.
- [4] M. Csikszentmihalyi, *Flow: The psychology of optimal experience*. Harper & Row New York, 1990.
- [5] M. Csikszentmihalyi, S. Abuhamdeh, and J. Nakamura, "Flow," *Flow and the Foundations of Positive Psychology*, pp. 227–238, 2014.
- [6] A. Schütt, T. Huber, I. Aslan, and E. André, "Fast dynamic difficulty adjustment for intelligent tutoring systems with small datasets," in *Proceedings of the 16th International Conference on Educational Data Mining*, 2023, pp. 482–489.
- [7] W. R. Fernandes and G. Levieux, " δ -logit: Dynamic difficulty adjustment using few data points," in *Joint International Conference on Entertainment Computing and Serious Games*. Springer, 2019, pp. 158–171.
- [8] D. Ang and A. Mitchell, "Representation and frequency of player choice in player-oriented dynamic difficulty adjustment systems," in *Proceedings of the annual symposium on computer-human interaction in play*, 2019, pp. 589–600.
- [9] P. M. Blom, S. Bakkes, and P. Spronck, "Modeling and adjusting in-game difficulty based on facial expression analysis," *Entertainment Computing*, vol. 31, p. 100307, 2019.
- [10] Y. Goutsu and T. Inamura, "Instant difficulty adjustment using user skill model based on gpdn in vr kendama task," in *2024 IEEE International Conference on Artificial Intelligence and eXtended and Virtual Reality (AIxVR)*. IEEE, 2024, pp. 138–146.
- [11] B. R. Schadenberg, M. A. Neerincx, F. Cnossen, and R. Looije, "Personalising game difficulty to keep children motivated to play with a social robot: A bayesian approach," *Cognitive systems research*, vol. 43, pp. 222–231, 2017.
- [12] E. Pagalyte, M. Mancini, and L. Climent, "Go with the Flow: Reinforcement learning in turn-based battle video games," in *Proceedings of the 20th ACM international conference on intelligent virtual agents*, 2020, pp. 1–8.
- [13] Y. Zhang and W.-B. Goh, "Personalized task difficulty adaptation based on reinforcement learning," *User Modeling and User-Adapted Interaction*, vol. 31, no. 4, pp. 753–784, 2021.
- [14] G. Chanel and P. Lopes, "User evaluation of affective dynamic difficulty adjustment based on physiological deep learning," in *International Conference on Human-Computer Interaction*. Springer, 2020, pp. 3–23.
- [15] M. Ishihara, S. Ito, R. Ishii, T. Harada, and R. Thawonmas, "Monte-carlo tree search for implementation of dynamic difficulty adjustment fighting game ais having believable behaviors," in *2018 IEEE Conference on Computational Intelligence and Games (CIG)*. IEEE, 2018, pp. 1–8.
- [16] J. Moon, Y. Choi, T. Park, J. Choi, J.-H. Hong, and K.-J. Kim, "Diversifying dynamic difficulty adjustment agent by integrating player state models into monte-carlo tree search," *Expert Systems with Applications*, vol. 205, p. 117677, 2022.
- [17] Y. Goutsu and T. Inamura, "Instant difficulty adjustment: Predicting success rate of VR Kendama when changing the difficulty level," in *Proceedings of the Augmented Humans International Conference 2023*, 2023, pp. 346–348.
- [18] S. Demediuk, M. Tamassia, W. L. Raffe, F. Zambetta, X. Li, and F. Mueller, "Monte carlo tree search based algorithms for dynamic difficulty adjustment," in *2017 IEEE conference on computational intelligence and games (CIG)*. IEEE, 2017, pp. 53–59.
- [19] J. Pfau, A. Liapis, G. Volkmar, G. N. Yannakakis, and R. Malaka, "Dungeons & replicants: Automated game balancing via deep player behavior modeling," in *2020 IEEE Conference on Games (CoG)*. IEEE, 2020, pp. 431–438.
- [20] J. Pfau, J. D. Smeddinck, I. Bikas, and R. Malaka, "Bot or not? User perceptions of player substitution with deep player behavior models," in *Proceedings of the 2020 CHI conference on human factors in computing systems*, 2020, pp. 1–10.
- [21] J. Pfau, J. D. Smeddinck, and R. Malaka, "Towards deep player behavior models in MMORPGs," in *Proceedings of the 2018 Annual Symposium on Computer-Human Interaction in Play*, 2018, pp. 381–392.
- [22] T. Huber, S. Mertes, S. Rangelova, S. Flutura, and E. André, "Dynamic difficulty adjustment in virtual reality exergames through experience-driven procedural content generation," in *2021 IEEE Symposium Series on Computational Intelligence (SSCI)*. IEEE, 2021, pp. 1–8.
- [23] H.-S. Moon and J. Seo, "Dynamic difficulty adjustment via fast user adaptation," in *Adjunct Proceedings of the 33rd Annual ACM Symposium on User Interface Software and Technology*, 2020, pp. 13–15.