



# AI または録画データを教師とした 融合身体を用いた運動学習効果

田北陽士<sup>1)2)</sup>, 畑田裕二<sup>1)</sup>, 鳴海拓志<sup>1)</sup>, 谷川智洋<sup>1)</sup>

1) 東京大学 (〒 113-0033 東京都文京区本郷 7-3-1, {takita,hatada,narumi}@cyber.t.u-tokyo.ac.jp)

2) 産業技術総合研究所 (〒 277-0882 千葉県柏市柏の葉 6-2-3, haruto-takita@aist.go.jp)

**概要:** 加重平均型の融合身体を運動学習に利用する研究が数多く行われている。しかし、教師が融合身体の使用に習熟する必要がある、さらに教師が学習者から悪影響を受ける可能性があるという課題が存在する。本研究では、学習者の動作データと目標位置を入力として、教師の動作を出力する AI 教師を教師あり学習を用いて開発した。その上で、教師が AI または録画データである場合、人間が教師である場合の運動学習効果を比較検証した。

**キーワード:** 融合身体, 運動学習, 機械学習

## 1. はじめに

運動学習支援の手法の一つとして融合身体が注目されている。融合身体とは、二人のユーザーの動作を加重平均して一つのアバターを操作するシステムである。このシステムは、一人称視点で教師の動作を観察でき、高い行為主体感を得ることが可能である。そのため、融合身体を用いた運動スキル学習の研究が数多く行われており、練習中のタスクパフォーマンスや練習後のスキル定着度の向上が明らかにされている [1, 2]。しかし、従来の研究にはいくつかの課題が存在する。第一に、融合身体では教師の振る舞いが学習効果を高めるために重要であり、教師は学習者の習熟度に合わせて徐々に動作を速めたり、学習者が融合アバターを自分の体と感じられるように動きを調整する必要があるため、教師に求められるものが多く、教師の負担が大きくなる。第二に、長期間にわたる学習者の未熟な動きとの融合が教師に悪影響を及ぼし、教師のパフォーマンスを低下させる可能性があるとして指摘されている [1]。したがって、融合身体を用いた指導に熟練しており、学習者の動きに応じて適切に対応しつつ、学習者の未熟な動きの悪影響を受けないような教師が必要である。

これらの課題を解決するため、私たちは人間が運動指導している動作データを機械学習させた AI を作成し、AI 教師と融合して運動スキル学習を行う手法を提案した。提案手法の有効性を検証するため、提案手法、人間の教師動作を録画したデータとの融合、および既存手法を用いた運動学習のパフォーマンスを、デュアルタスクを用いて調べた。さらに、教師 AI の作成において重要なパラメータであった学習者と教師の運動量の分析も行った。

## 2. 実験

本研究は融合身体を用いたスキル学習において、AI によって生成された動作データおよび人間の教師動作の録画デー

タとの融合が運動スキルの学習効率を向上させる可能性があるかを検証するために行われた。参加者は先行研究 [1] で使用されたデュアルタスクを AI 教師または録画データと融合して行った。この条件をそれぞれ CoAI 条件と CoRecord 条件とし、先行研究 [1] において人間が務めた教師と融合する CoHuman 条件および一人でタスクを行う Alone 条件を含む、合計 4 条件で比較を行った。運動スキル学習の効率は、タスクパフォーマンスがベースラインと比較してどれくらい向上したかによって定義された。本研究は、東京大学大学院情報理工学系研究科倫理委員会の承認を得て実施された (UT-IST-RE-220901-32)。

### 2.1 参加者

本研究では先行研究 [1] に新たに実験条件を追加する形で行った。追加した条件の参加者は 10 名 (男性 6 名・女性 4 名、平均年齢 22.7 歳、標準偏差 1.1) であった。全ての参加者の視力、または矯正視力は正常で、実験に関する事前知識はなかった。参加者の VR 経験に関しては、一度も経験がない者が 2 名、数回程度である者が 8 名であった。

### 2.2 タスク

本研究では、運動学習を評価するために一般的に用いられている手法としてデュアルタスクを採用した。デュアルタスクとは、比較的単純な 2 つの作業を同時に行う運動課題である。本実験のデュアルタスクとして、右手で七芒星を、左手で五芒星を描くタスクを実装した。五芒星および七芒星の各頂点に球を配置し、順番に頂点に触れることで図形を描かせた。正解の頂点に触った際には頂点の色が赤色に変わり、間違った頂点に触った際には色が黄色に変わること、触った球の正誤が分かる仕組みになっていた。デュアルタスクの 1 試行は、30 秒のタスク実行期間と 30 秒の休憩期間で構成された。

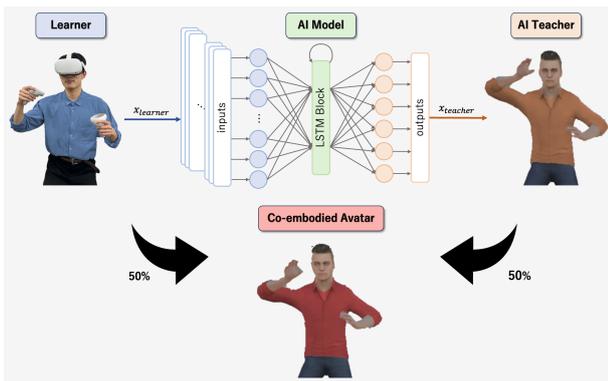


図 1: LSTM を使用して作成された AI 教師は、学習者の動きが入力されると教師の動きを出力した。参加者は、AI 教師と融合して運動タスクを実行した。

### 2.3 システム

本研究で使用された融合身体システムは、Unity (バージョン 2020.3.2f1) を用いて開発された。CoAI 条件では、同一の PC で Unity による融合身体システムと Python による教師動作の推論が行われ、OSC を介して両者の通信が実施された。

ユーザの頭部と両手の 3 点は、HMD とコントローラを用いてトラッキングされ、得られた位置と姿勢から逆運動学計算によってその他の身体部位の位置・姿勢が推定された。逆運動学の計算には、Unity 向けの逆運動学計算ライブラリである Final IK が用いられた。融合身体システムにおいては、二人の位置・姿勢から融合したアバタの位置・姿勢が計算された。融合身体アバタの手の位置 ( $x_{fusion}$ ) は、学習者の手の位置 ( $x_{learner}$ ) と、教師の手の位置 ( $x_{teacher}$ ) を学習者の制御割合 ( $\omega$ ) を用いて加重平均することで計算された。これらは以下の式で表される。

$$x_{fusion} = \omega x_{learner} + (1 - \omega) x_{teacher} \quad (0 \leq \omega \leq 1)$$

教師の手の位置 ( $x_{teacher}$ ) に関して、CoAI 条件においては、第 2.4 節で説明される AI モデルを用いて、毎フレームでの教師の手の位置を推論し、そのデータが使用された。CoRecord 条件では、CoHuman 条件下での人間教師の動作が録画され、教師の手の位置データとして使用された。ただし、学習者が目標位置に到達していない場合に教師が先に進むのを防ぐため、目標位置に到達するまで録画の再生を停止し、到達後に再生を再開するという手法が取り入れられた。また、ユーザーの視界が意図に反して動くことによって不快感を感じることを防ぐために、先行研究 [3] に従い、頭部の融合は行わなかった。さらに、ユーザーが頭部を後方に移動させた際にアバターの頭部が視野に入り没入感を損なう問題を防ぐため、先行研究 [1] に倣い、アバターの頭部を透明化してユーザーの視界に入らないようにした。

### 2.4 AI モデル

本研究では、融合身体を活用した運動学習における教師の動作を生成するための AI モデルを開発した。この AI モデルには、長期的な時系列データを扱う能力が要求されるため、

Long Short-Term Memory (LSTM) を採用した。LSTM は、Recurrent Neural Network (RNN) の一種であり、運動データの予測に適している。

本モデルでは、学習者の両手の 3 次元座標、目標点までの距離、両手の速度、学習者の運動量、五芒星と七芒星の頂点位置を示すワンホットベクトルを含む 32 次元の入力データを、過去 50 フレーム分用いた。モデルの中間層には、64 個のニューロンを持つ LSTM 層を 1 層設け、出力層では教師の両手の 3 次元座標を出力した。モデルの構造をまとめたものを図 1 に示す。また、モデルの学習時には、CoHuman 条件下での 21 名の参加者から得られたデータを用い、20 名分のデータでモデルを訓練し、残り 1 名のデータでテストを行った。損失関数には平均二乗誤差 (MSE) を、最適化手法には Adam を使用した。本モデルを 100 エポックまで学習を行った結果、訓練誤差は 0.0011m、テスト誤差は 0.0014m まで収束した。

### 2.5 条件

本実験は混合デザインを用いて実施された。参加者間要因は学習方法であり、CoAI、CoHuman、CoRecord、Alone 条件の 4 水準であった。参加者内要因は試行回数であり、13 水準 (10 回の練習と 3 回のテスト) であった。

**CoAI** : 参加者は AI 教師と融合して練習を行った。

**CoHuman** : 参加者は人間の教師と融合して練習を行った。

**CoRecord** : 参加者は人間の教師動作の録画データと融合して練習を行った。

**Alone** : 参加者は一人で練習を行った。

CoAI、CoHuman、CoRecord 条件では、制御割合を 50% に設定した。

### 2.6 手順

まず最初に、チュートリアルとして参加者は HMD を装着し、正しい頂点に触れると頂点が赤くなること、間違った頂点に触れると頂点が黄色くなること、また、頂点に触れた際にコントローラーが振動することを確認した。次に、ベースライン測定として 1 人でデュアルタスクを 1 回試行した。続いて、練習時には参加者がそれぞれ割り当てられた条件 (CoAI、CoHuman、CoRecord、Alone) でタスクを 5 回行い、3 分間の休息後に同じ条件でさらに 5 回試行を行った。最後に、テストとしてタスクを一人で 3 回行った。

### 2.7 評価指標

#### 2.7.1 Improvement

タスクパフォーマンスとして、参加者が正しい頂点に触れた回数を評価した。まず、最初に参加者が 1 人でタスクパフォーマンスを測定し、それを参加者のベースラインとした。各試行について、その時点のタスクパフォーマンスからベースラインを引いたものを *Improvement* と定義し、学習効果の測定に使用した。

#### 2.7.2 Learner Momentum Contribution

アバタの手の速度を各試行で積分し、運動量として算出した。さらに、融合アバタの運動量に対する学習者の運動量

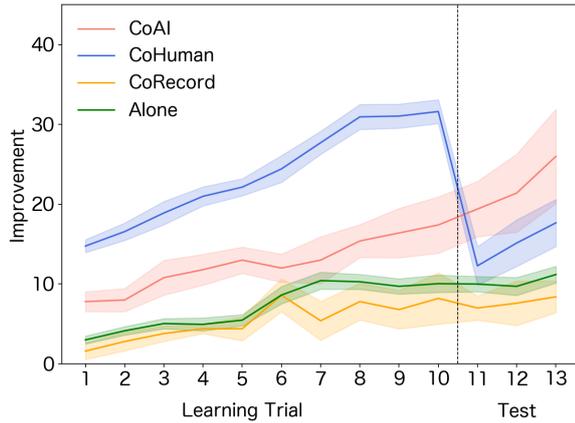


図 2: 学習試行とテスト試行における *Improvement*. *Improvement* は参加者が正しい頂点に触れた回数がベースラインと比較してどれだけ増加したかを表している。いくつかの学習試行では、CoAI 条件が CoRecord 条件および Alone 条件より有意に高かった。テスト試行では CoAI 条件が CoRecord 条件および Alone 条件より有意に高く、CoHuman 条件より有意に高い傾向にあった。

の割合を *Learner Momentum Contribution* と定義し、学習者が主体的に動いている程度を評価するために使用した。

## 2.8 仮説

CoAI 条件では先行研究 [1] における CoHuman 条件の教師の動きを学習した AI が教師を務めた。このため、CoAI 条件では、学習者の動きに応じて適切な支援を教師 AI が提供することが期待される。その結果、学習者は教師の動作フィードバックを受け取ることが可能であり、教師の動作が融合身体アバタに直接反映されるため、単独でタスクを行うよりも AI 教師と融合してタスクを行った方がタスクパフォーマンスが向上すると予測される。

$H_1$ : 練習時の *Improvement* は CoAI 条件のほうが Alone 条件よりも大きい。

また、教師の支援があることで練習の効率が向上するだけでなく、学習者の動きに応じて AI が適切な指導を行うことにより、学習者が必要とする際に適切な量の支援を提供する。これにより、練習が効果的に身につく、テスト試行のタスクパフォーマンスも向上すると考えられる。

$H_2$ : テスト時の *Improvement* は CoAI 条件のほうが Alone 条件よりも大きい。

## 3. 結果

本節では、第 2.7 節で説明された評価指標の統計的検定結果について述べる。有意水準は  $p < 0.05$  で設定された。

### 3.1 学習試行における *Improvement*

図 2 は、全試行における *Improvement* の折れ線グラフを示している。本節では、学習試行 (図 2 の試行 1~10) における *Improvement* について説明する。学習方法 (4 水準: CoAI, CoHuman, CoRecord, Alone) を参加者間要因、試行回数 (10 水準: 1 回目, 2 回目, ..., 10 回目) を参加者内要因とする二元配置分散分析を行った。二元配置分散分

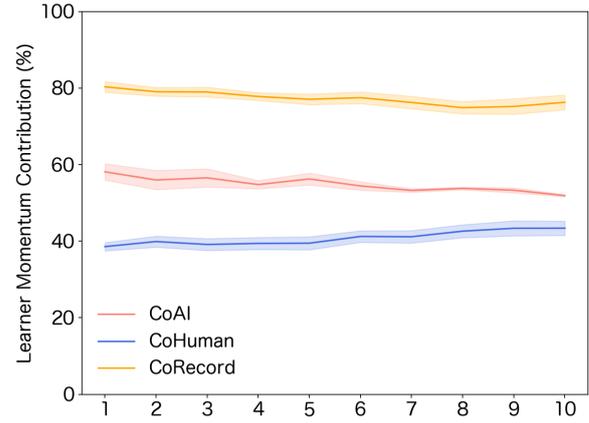


図 3: 学習試行における *Learner Momentum Contribution*. *Learner Momentum Contribution* は、融合アバタの運動量に対する学習者の運動量の割合を表している。*Learner Momentum Contribution* CoRecord 条件, CoAI 条件, CoHuman の順で有意に高かった。

析の結果、学習方法の主効果は有意であり ( $F(3, 48) = 68.9, p < .001, \eta_p^2 = 0.81$ )、試行回数の主効果も有意であった ( $F(9, 432) = 82.1, p < .001, \eta_p^2 = 0.63$ )。また、学習方法と試行回数との交互作用が有意であった ( $F(27, 432) = 5.43, p < .001, \eta_p^2 = 0.25$ ) ため、ボンフェローニ法を用いて調整したウェルチの t 検定による事後検定を行った。

試行回数ごとの学習方法の単純主効果について、多くの試行において CoHuman 条件の *Improvement* は CoAI 条件に比べて有意に高かった ( $p < .01$ )。また、いくつか試行において CoAI 条件の *Improvement* は CoRecord 条件および Alone 条件に比べて有意に高かった ( $p < .05$ )。全ての試行において CoRecord 条件と Alone 条件の *Improvement* に有意差はなかった。

### 3.2 テスト試行における *Improvement*

本節では、テスト試行 (図 2 の試行 11~13) における *Improvement* について説明する。学習方法 (4 水準: CoAI, CoHuman, CoRecord, Alone) を参加者間要因、試行回数 (3 水準: 1 回目, 2 回目, 3 回目) を参加者内要因とする二元配置分散分析を行った。二元配置分散分析の結果、学習方法の主効果は有意であり ( $F(3, 48) = 3.73, p < .05, \eta_p^2 = 0.19$ )、試行回数の主効果も有意であった ( $F(2, 96) = 6.37, p < .01, \eta_p^2 = 0.12$ )。また、学習方法と試行回数の交互作用効果は有意ではなかった ( $F(6, 96) = 0.95, p = .47, \eta_p^2 = 0.06$ )。学習方法の主効果が有意であったため、ボンフェローニ法を用いたウェルチの t 検定による事後検定を行った。

その結果、CoAI 条件の *Improvement* は CoRecord 条件および Alone 条件より有意に高く ( $p < .01$ )、CoHuman 条件より有意に高い傾向にあった ( $p = 0.06$ )。また、CoHuman 条件の *Improvement* は CoRecord 条件より有意に高かった ( $p < .01$ )。さらに、CoRecord 条件の *Improvement* は Alone 条件より有意に高い傾向にあった ( $p = 0.06$ )。

### 3.3 Learner Momentum Contribution

本節では、融合アバタの運動量に対する学習者の運動量の割合について説明する。図3には、学習試行における *Learner Momentum Contribution* の折れ線グラフが示されている。学習方法 (3水準: CoAI, CoHuman, CoRecord) を参加者間要因、試行回数 (10水準: 1回目, 2回目, …, 10回目) を参加者内要因とする二元配置分散分析を行った。二元配置分散分析の結果、学習方法の主効果は有意であり ( $F(2,28)=78.3$ ,  $p < .001$ ,  $\eta_p^2=0.85$ )、試行回数の主効果は有意でなかった ( $F(9,252)=2.32$ ,  $p = 0.18$ ,  $\eta_p^2=0.08$ )。また、学習方法と試行回数の間の交互作用が有意であった ( $F(18,252)=5.67$ ,  $p < .001$ ,  $\eta_p^2=0.29$ ) ため、ボンフェローニ法を用いて調整したウェルチの  $t$  検定による事後検定を行った。

試行回数ごとの学習方法の単純主効果について、全ての試行において、*Learner Momentum Contribution* は CoHuman 条件, CoAI 条件, CoRecord 条件の順に有意に高かった ( $p < .01$ )。

## 4. 考察

### 4.1 Improvement

いくつかの学習試行において、CoAI 条件の *Improvement* は Alone 条件よりも有意に高かった。この結果は、仮説  $H_1$  を部分的に支持しており、人間の教師動作を学習させた AI が、融合相手として適切に学習者を支援できたことを示している。またテスト試行において、CoAI 条件の *Improvement* は Alone 条件よりも有意に高く、CoHuman 条件よりも有意に高い傾向にあった。この結果は、仮説  $H_2$  を支持する。この理由として、学習者が必要なときだけ支援を受けていた可能性が考えられる。運動課題の学習を行う際に支援的な力を受け続けた状態で練習をすると、学習者はその力に頼った運動制御を行うようになり、学習効果が阻害されることが報告されている。ただし、学習者の上達に合わせて支援的な介入を減らしていく「Assist-as-needed」と呼ばれる方策を取ることによって、この現象を抑制しながら学習効率を上げることができる。CoAI 条件で学習者が融合した教師 AI モデルは、学習者の動作を入力に取っているため、学習者の動きに合わせて適切なタイミングで支援できていた可能性がある。また、学習者の運動量も入力として与えており、CoAI 条件の *Learner Momentum Contribution* が CoHuman 条件よりも有意に大きいことから、支援を適切に抑え、学習者が主体的にタスクの練習を行っていたと考えられる。

### 4.2 AI モデル

本研究において作成した教師 AI モデルの振る舞いについて詳しく考察する。モデルは HumanCo 条件の教師と学習者の動作データを学習しており、理論上は教師 AI は人間の教師と同じ動きをし、*Improvement* も HumanCo 条件と AICo 条件で同じになるはずである。しかし、実際の結果としては HumanCo 条件と AICo 条件で *Improvement* の推移が異なっていた。これは、AI モデルの設計が原因である

と考えられる。モデルの構成上、学習者の動作を入力にして教師の動きを出力するため、学習者が動かない間はモデルへの入力に変化がなく、出力も同一になり、教師も動かないという振る舞いが見られた。この性質により、学習者が手を動かした時にだけ教師がそれを支援するという方策になっており、意図せず「Assist-as-needed」な支援につながっていた可能性がある。しかし、この性質は必ずしも良い方向にのみ働くわけではない。手をあまり動かさない学習者の場合、教師 AI は動かず、結果として支援を行うことができなくなる。特に、本モデルでは過去 50 フレーム (1秒) のデータを入力していたため、学習者が 1 秒以上動かないと、教師 AI も動かなくなる。したがって、例えば過去のデータを入力する時間幅を 250 フレーム (5 秒) に変更することで、「学習者が 3 秒止まっていたら教師は動き始める」という振る舞いを教師 AI モデルに期待することが可能となるため、入力するデータの時間幅についても最適解を調査する必要がある。

## 5. 結論

本研究は、学習者の運動量をパラメータに持つ AI 教師との融合および人間の教師の録画データとの融合を運動スキル学習に適用した初めての研究である。私たちは、AI が学習者の動きに応じて適切に運動実行を支援することにより、運動スキルの学習と定着が向上すると仮定した。本研究では、CoAI, CoHuman, CoRecord, Alone の 4 つの学習方法を比較した。参加者は各条件で 10 回のデュアルタスクを実践し、その後テストとして単独で 3 回の課題を実施した。学習効率をベースラインと各試行のタスクパフォーマンスの差に基づいて評価された。結果から、AI と融合して練習を行うことで、学習試行およびテスト試行において単独でのタスク実行に比べてパフォーマンスが向上することが示された。また、学習者の運動量の貢献度が融合する教師の種類によって大きく異なっていたため、これが学習内容の定着にとって重要である可能性が示された。

**謝辞** 本研究の一部は、科研費 基盤研究 (S)(19H05661), 科研費 基盤研究 (A)(24H007061), および JST ムーンショット型研究開発事業 (JPMJMS2013) の支援を受けて行われた。

## 参考文献

- [1] Daiki Kodama, et al.: Effects of Collaborative Training Using Virtual Co-embodiment on Motor Skill Learning, 2023.
- [2] Haruto Takita, et al.: Effects of Virtual Co-embodiment on Declarative Memory-Based Motor Skill Learning, 2023.
- [3] Fribourg Rebecca, et al.: Virtual Co-Embodiment: Evaluation of the Sense of Agency While Sharing the Control of a Virtual Body Among Two Individuals, 2021.