

UNIVERSIDADE FEDERAL DO RIO GRANDE - FURG
CENTRO DE CIÊNCIAS COMPUTACIONAIS
CURSO DE ENGENHARIA DE AUTOMAÇÃO

Projeto de Graduação em Engenharia de Automação

Aprendizado Social entre Humanos e Agentes Artificiais

Gabriel Rocha de Souza

Projeto de Graduação apresentado ao Curso de Engenharia de Automação da Universidade Federal do Rio Grande - FURG, como requisito parcial para a obtenção do grau de Engenheiro de Automação

Orientador: Prof. Dr. Rodrigo da Silva Guerra

Rio Grande, 2026

Projeto de Graduação em Engenharia de Automação

Aprendizado Social entre Humanos e Agentes Artificiais

Gabriel Rocha de Souza

Banca examinadora:

Prof. Dr. Marcelo Rita Pias

Prof. Dr. André Prisco Vargas

À minha família, pelo amor que sustentou minha caminhada. À memória daqueles que hoje habitam a eternidade, mas que continuam vivos guiando meus passos. E, finalmente, dedico a mim, por ter vencido o cansaço e persistido até o fim, provando que sou capaz de reescrever minha própria história.

AGRADECIMENTOS

- Aos meus pais, por todo o investimento na minha educação e pelo apoio nos momentos difíceis.
- À minha família, pelo carinho, paciência e por compreenderem minhas ausências durante os períodos de estudo mais intensos. Agradeço pelo apoio e incentivo em seguir meus sonhos.
- À minha namorada, parceira e colega, por caminhar ao meu lado e, principalmente, pela paciência infinita ao servir de “teste” para os experimentos deste trabalho inúmeras vezes. Sua dedicação foi tamanha que até o orientador simpatizava com você. Saiba que sua contribuição foi a alma deste trabalho, essa conquista é nossa.
- Aos meus amigos e colegas pelo companheirismo, pelas trocas de conhecimento e pelos momentos de descontração que tornaram a jornada acadêmica mais leve.
- Aos meus professores, pela orientação e por compartilharem seus conhecimentos, tão essenciais para minha formação profissional e pessoal.
- Aos voluntários que dedicaram seu tempo e atenção para participar das sessões experimentais. A contribuição de cada um foi importante para validar as hipóteses aqui apresentadas.
- A todos que acreditam na universidade pública, gratuita e de qualidade, que me deu suporte durante os anos de graduação e que me abriu portas para realizar meus sonhos.
- Estendo minha gratidão às oportunidades vivenciadas nos projetos de Pesquisa e Desenvolvimento. Obrigado às empresas parceiras por acreditarem na pesquisa universitária e pelo incentivo ao aprendizado público de excelência. A vivência prática nesses projetos foi, sem dúvida, o diferencial que consolidou minha formação como engenheiro.

*Ninguém educa ninguém, ninguém educa a si mesmo,
os homens se educam entre si, mediatizados pelo mundo. — PAULO FREIRE*

RESUMO

SOUZA, Gabriel Rocha de . **Aprendizado Social entre Humanos e Agentes Artificiais**. 2026. 59 f. Projeto de Graduação – Engenharia de Automação. Universidade Federal do Rio Grande - FURG, Rio Grande.

Este estudo investiga, por meio de uma abordagem experimental controlada, se um agente artificial pode efetivamente participar de processos de descoberta e aprendizado coletivo. A pesquisa fundamenta-se na premissa de que o aprendizado humano é impulsionado por interações sociais e pela transmissão cultural de conhecimento, o que acelera os avanços cognitivos para além da evolução biológica. Dessa forma, a pergunta central desta pesquisa é: um agente artificial, baseado em LLM, é capaz de participar efetivamente de um processo de descoberta e compartilhamento de conhecimento? Para testar a hipótese, utilizou-se um jogo multijogador colaborativo, entre humanos e LLMs, que desafia os participantes a descobrirem de forma coletiva (sem comunicação verbal e focado na observação de ações) um objetivo inicialmente oculto, exigindo a consolidação e manutenção da estratégia. A metodologia aplicou um desenho longitudinal caracterizado pela substituição periódica dos jogadores por novos integrantes, alternando entre humanos e LLMs. Para avaliar se o conhecimento do grupo é preservado e transmitido culturalmente aos novos agentes, foram analisados as métricas de pontuação, questionários e tempo para solucionar o objetivo desconhecido. A análise buscou verificar se os agentes artificiais conseguiram se engajar em ciclos de aprendizado coletivo, utilizando indícios comportamentais para atingir metas comuns, usando das habilidades emergentes identificadas em LLMs com tarefas complexas. Este desenho experimental oferece, portanto, insights sobre as atuais limitações e desafios para que agentes artificiais se integrem e participem de dinâmicas de aprendizado social análogas às humanas.

Palavras-chave: Aprendizado Social, Agentes Artificiais, Modelos de Linguagem Amplos, Interação Humano-IA, Transmissão de Conhecimento, Evolução Cultural, Descoberta Coletiva, Cognição Coletiva, Teoria da Mente.

ABSTRACT

SOUZA, Gabriel Rocha de . **Social Learning between Humans and Artificial Agents.** 2026. 59 f. Projeto de Graduação – Engenharia de Automação. Universidade Federal do Rio Grande - FURG, Rio Grande.

This study investigates, through a controlled experimental approach, whether an artificial agent can effectively participate in processes of collective discovery and learning. The research is grounded in the premise that human learning is driven by social interactions and the cultural transmission of knowledge, which accelerates cognitive advancements beyond biological evolution. Thus, the central question of this research is: is an LLM-based artificial agent capable of effectively participating in a process of discovery and knowledge sharing? To test the hypothesis, a collaborative multiplayer game involving humans and LLMs was used, challenging participants to collectively discover (without verbal communication and focused on the observation of actions) an initially hidden objective, requiring the consolidation and maintenance of a strategy. The methodology applied a longitudinal design characterized by the periodic replacement of players with new members, alternating between humans and LLMs. To assess whether group knowledge is preserved and culturally transmitted to new agents, scoring metrics, questionnaires, and the time taken to solve the unknown objective were analyzed. The analysis sought to verify whether the artificial agents managed to engage in collective learning cycles, utilizing behavioral cues to achieve common goals, leveraging the emergent abilities identified in LLMs within complex tasks. Therefore, this experimental design offers insights into the current limitations and challenges for artificial agents to integrate into and participate in social learning dynamics analogous to human ones.

Keywords: Social Learning, Artificial Agents, Large Language Models, Human-AI Interaction, Knowledge Transmission, Cultural Evolution, Collective Discovery, Collective Cognition, Theory of Mind.

LISTA DE FIGURAS

1	Diagrama da Teoria do Aprendizado Social de Albert Bandura.	18
2	Demonstração de LLMs atuando como “Máquinas de Padrões Gerais”. A imagem ilustra como o modelo consegue identificar a lógica e as sequências abstratas para completar o padrão corretamente apenas observando os exemplos fornecidos no contexto.	23
3	Comparação de desempenho na resolução cooperativa do problema do carregador de piano entre humanos e formigas.	26
4	Captura de tela do jogador azul em dois estados distintos: (a) momento inicial com peças dispersas (0,0% de progresso) e (b) momento final com peças alinhadas (100% de progresso).	32
5	Fluxograma da dinâmica de Transição de Grupos. Cada bloco representa a composição do grupo em um intervalo de ciclos. A cor azul indica os membros detentores do conhecimento original e a laranja indica os novos integrantes que dependem do aprendizado social. Em verde o grupo final que recebera o conhecimento do grupo intermediário.	35
6	Comparativo entre o IoU tradicional e a métrica adaptada (Equação 2) para $n = 4$ agentes. O gráfico evidencia a “zona morta” de aprendizado na métrica tradicional (vermelho) quando as peças estão dispersas, em contraste com o feedback linear e contínuo fornecido pela abordagem proposta (azul).	38
7	Diagrama ilustrando a arquitetura multithread do sistema. À esquerda, as instâncias dos clientes; à direita, a arquitetura do servidor com threads dedicadas para gestão de conexão e a thread principal para gerenciamento do estado global.	38
8	Diagrama do fluxo de dados do agente artificial (LLM).	43
9	Evolução da pontuação do grupo A, comparativo entre a fase de descoberta (Ciclo 1) e a fase de consolidação (Ciclo 2).	48
10	Evolução da pontuação na transição de grupos: performance de 3 Veteranos (Grupo A) interagindo com 1 novo integrante (Grupo B). O aprendizado cultural acelera a estabilização da pontuação.	48
11	Momento em que os jogadores veteranos (amarelo, azul-escuro e rosa) já haviam posicionado suas peças, enquanto o novo integrante (azul claro) processava a informação para, em seguida, posicionar a sua.	49
12	Ciclo com 2 humanos (grupo A) e dois agentes artificiais (grupo B). O progresso permaneceu estagnado em um sub-ótimo local.	50

13	Ciclo com 2 participantes humanos do grupo A e dois participantes humanos do grupo B. A estagnação não aconteceu e o objetivo foi realizado. . .	50
14	Gráficos resultantes da transição do grupo A (humanos) para o grupo B (artificial) do Cenário 2	51

LISTA DE TABELAS

1	Comparativo entre trabalhos relacionados e a presente pesquisa.	30
2	Imagens das peças presentes no jogo.	34
3	Exemplo de transição de grupos em um cenário. A_i representa os agentes que iniciam no Grupo A; B_i representa os agentes que iniciam no Grupo B. A natureza de cada agente (seja A_i ou B_i) pode ser humano ou <i>LLM</i> , e é definida conforme o cenário experimental específico, descrito na Tabela 4. .	35
4	Descrição dos cenários experimentais e da natureza dos grupos.	36
5	Descrição das perguntas “Pré-Esclarecimento” enviadas ao participante . .	41
6	Descrição das perguntas enviadas “Pós-Esclarecimento” ao participante . .	42
7	Descrição das entidades de um agente artificial.	43
8	Comparativo entre intenção do humano e percepção de outro humano (Cenário de Controle).	52
9	Comparativo entre intenção humana e percepção da IA (Cenário 2).	53

LISTA DE ABREVIATURAS E SIGLAS

API	Application Programming Interface
BERT	Bidirectional Encoder Representations from Transformers
C3	Centro de Ciências Computacionais
CEP	Comitê de Ética em Pesquisa
CoT	Chain-of-Thought
FURG	Universidade Federal do Rio Grande
GPT	Generative Pre-trained Transformer
HtT	Hypotheses-to-Theories
IA	Inteligência Artificial
IAG	Inteligência Artificial Generativa
IoU	Intersection over Union
JSON	JavaScript Object Notation
KAT	Keypoint Action Tokens
LLM	Large Language Models
NLP	Processamento de Linguagem Natural
LSTM	Long Short-Term Memory
RNNs	Redes Neurais Recorrentes
TCLE	Termo de Consentimento Livre e Esclarecido
TCP	Transmission Control Protocol
ToM	Teoria da Mente
VLA	Vision-Language-Action

SUMÁRIO

1	Introdução	14
1.1	Objetivos	15
1.2	Estrutura do Trabalho	16
2	Revisão Bibliográfica	17
2.1	Fundamentação Teórica	17
2.1.1	Arquitetura e Evolução dos Modelos de Linguagem	17
2.1.2	Aprendizado Social e Transmissão Cultural	18
2.1.3	Habilidades Emergentes e Raciocínio em LLMs	20
2.1.4	Dinâmicas de Informação e Homogeneização Cultural	24
2.2	Trabalhos Relacionados	25
2.2.1	Inteligência Coletiva e Coordenação Implícita	25
2.2.2	Colaboração Humano-IA em Dinâmicas Sociais	26
2.2.3	Desenvolvimento Cognitivo e Limitações Estatísticas	28
3	Desenvolvimento	31
3.1	Desenho do Experimento	31
3.2	Cenários Experimentais	33
3.2.1	Ciclos	33
3.2.2	Cenários	36
3.2.3	Implementação Computacional	36
3.3	Agentes humanos: Participantes de Pesquisa	39
3.3.1	Comitê de Ética em Pesquisa	39
3.3.2	Procedimentos de Coleta de Dados	40
3.4	Agentes Artificiais: LLMs	42
3.4.1	A Entidade Estrategista (The Thinker)	44
3.4.2	A Entidade Executora (The Player)	45
3.4.3	Gestão de Janela de Contexto e Compressão Semântica	45
4	Resultados	47
4.1	Validação do Ambiente de Aprendizado	47
4.2	Dinâmica de Aprendizado com Agentes Artificiais	49
5	Conclusão	54

1 INTRODUÇÃO

Parte do processo de cognição e aprendizado humano fundamenta-se na troca de conhecimento entre indivíduos. Mediada pela linguagem, essa troca atua como ferramenta para o avanço intelectual e cultural [10], possibilitando a formação de saberes coletivos que são preservados e acumulados ao longo de gerações, mesmo com a sucessiva renovação dos indivíduos que compõe a sociedade. Os saberes são transmitidos por linguagem falada e escrita, imitação e através de artefatos tecnológicos que ficam cada vez mais sofisticados, justamente pelo acúmulo de conhecimento, acelerando o processo de troca ao longo das gerações. Consequentemente, os indivíduos das novas gerações se beneficiam dos conhecimentos acumulados pelas gerações anteriores.

Exemplos desse aprendizado social cumulativo variam desde habilidades básicas de engenharia até a locomoção bípede, que depende da vivência social: crianças isoladas do convívio humano não desenvolvem a capacidade de permanecer em pé ou caminhar, como evidenciado no caso analisado por dos Anjos Pereira and Galuch [4].

Historicamente, a capacidade de construir conhecimento compartilhado, imitando e emulando objetivos, intenções, ações e movimentos, foi uma exclusividade humana. Até tempos recentes, apenas seres humanos demonstravam domínio sobre os processos de descobrir, receber, e transmitir saberes emulados e repetidos ao longo das gerações, de forma impulsionada pela Teoria da Mente (ToM) que é a capacidade cognitiva de inferir que o outro possui estados mentais, como crenças, desejos, intenções e conhecimentos, que é distinto do próprio indivíduo [9].

No entanto, com o surgimento dos Modelos de Linguagem de Larga Escala (LLMs, do inglês *Large Language Models*), agentes artificiais começaram a demonstrar habilidades sociais e colaborativas análogas as habilidades humanas em contextos experimentais. A literatura indica que LLMs podem atuar efetivamente como parceiros de equipe, conforme demonstrado por Dell'Acqua et al. [2], e como participantes válidos em simulações de dinâmicas de grupo [15]. Tanto os estudos recém citados quanto o trabalho de Zhu et al. [16] apontam que os LLMs podem adquirir regras e realizar raciocínio dedutivo de maneira compatível com a inferência humana. Essa capacidade estende-se para além da linguagem verbal, permitindo que os modelos identifiquem, transformem e extrapolem sequências abstratas e não linguísticas

apresentadas em contexto [12]. Contudo, resta investigar se tais competências, observadas em tarefas isoladas, sustentam-se em dinâmicas sociais contínuas.

Conforme descrito por Duéñez-Guzmán et al. [6], o aprendizado social colaborativo entre agentes artificiais e humanos representa um avanço na inteligência artificial, deslocando o garrote do progresso da simples assimilação de dados estáticos para a geração de novos conhecimentos. Esta dinâmica promove a inovação composta, um processo no qual sucessos anteriores impulsionam a exploração de novos territórios intelectuais, permitindo que o sistema aprenda de forma contínua através das interações.

Diante desse cenário, esta pesquisa adota uma abordagem experimental controlada para responder à pergunta central: **Um agente artificial é capaz de participar efetivamente de um processo de descoberta e aprendizado coletivo?**

Partindo da premissa de McLeod [11], de que o aprendizado humano ocorre via transmissão cultural, o experimento utiliza um jogo colaborativo que simula um ambiente de descoberta e evolução cultural para investigar a inteligência sociocultural. A escolha de um quebra-cabeça geométrico não verbal como plataforma experimental permite isolar os mecanismos de aprendizado por observação e ação, oferecendo uma oportunidade de comparar diretamente as estratégias de resolução de problemas entre diferentes tipos de agentes, de forma análoga ao estudo de Dreyer et al. [5], que compara humanos e insetos sociais em tarefas idênticas.

No escopo da Engenharia de Automação, este trabalho insere-se na robótica cognitiva e colaborativa. A validação de agentes artificiais capazes de aprender com humanos por meio da observação representa um avanço na concepção de sistemas autônomos adaptativos. Essa integração em dinâmicas sociais humanas tem implicações diretas no desenvolvimento de robôs sociais, sistemas de controle cooperativo e plataformas de automação inteligentes, onde a autonomia operacional depende não apenas de algoritmos de controle rígidos, mas também da sensibilidade contextual.

1.1 Objetivos

O objetivo deste trabalho consiste em investigar e validar a capacidade de Modelos de Linguagem de Larga Escala de atuarem como participantes ativos em processos de aprendizado social e transmissão de conhecimento de forma coletiva.

Para alcançar este propósito, foram definidas as seguintes metas específicas:

- Desenvolver um ambiente experimental controlado (jogo colaborativo) com desafios colaborativos não verbais, que isole variáveis de aprendizado por observação;
- Implementar uma arquitetura de agente artificial capaz de perceber, processar e atuar no ambiente proposto, utilizando LLMs como base de raciocínio;
- Realizar experimentos sistemáticos de interação humano-humano e humano-IA para mapear a evolução das estratégias de resolução de problemas;

- Analisar comparativamente o desempenho e a curva do aprendizado colaborativo dos agentes artificiais, investigando também a percepção humana sobre a intencionalidade da IA e possíveis divergências entre a ação executada e a interpretação social.

1.2 Estrutura do Trabalho

O restante desta monografia está organizado da seguinte forma: o Capítulo 2 apresenta a Revisão Bibliográfica, detalhando os trabalhos relacionados e a fundamentação teórica. O Capítulo 3 descreve o Desenvolvimento, incluindo o desenho experimental e a arquitetura dos agentes. O Capítulo 4 exibe os Resultados Alcançados na interação colaborativa. Por fim, o Capítulo 5 apresenta as Conclusões e as perspectivas para Trabalhos Futuros.

2 REVISÃO BIBLIOGRÁFICA

O desenvolvimento desta pesquisa teve início com uma análise aprofundada da bibliografia existente. O levantamento obteve trabalhos oriundos da área da psicologia e sociologia cultural, e também estudos sobre modelos de linguagem aplicados de forma condizente ao experimento proposto.

2.1 Fundamentação Teórica

Esta seção explora os pilares teóricos multidisciplinares que fundamentam a hipótese deste trabalho. A investigação se ancora em conceitos de inteligência artificial e da psicologia cognitiva, social e da teoria da evolução cultural para analisar a emergência do conhecimento em grupos híbridos.

2.1.1 Arquitetura e Evolução dos Modelos de Linguagem

No campo da inteligência artificial, historicamente, o processamento de linguagem natural (NLP) dependia de arquiteturas sequenciais, como Redes Neurais Recorrentes (RNNs) e *Long Short-Term Memory* (LSTM). Essa natureza criava um gargalo, pois impedia o treinamento em paralelo e dificultava a conexão de informações em textos longos. A solução definitiva para essas limitações foi apresentada por Vaswani et al. [13], que propuseram o *Transformer*, uma arquitetura que descarta a recorrência em favor de mecanismos de atenção.

A inovação do *Transformer* é o mecanismo de auto-atenção (*self-attention*). Diferente dos métodos anteriores que processavam uma palavra de cada vez, essa técnica permite que o modelo analise a sentença inteira simultaneamente, calculando a relevância de cada *token* em relação a todos os outros. Para capturar diferentes nuances do texto, como relações gramaticais e semânticas, a arquitetura utiliza a Atenção em Múltiplas Cabeças (*Multi-Head Attention*), permitindo que o sistema foque em diferentes partes da informação ao mesmo tempo.

A arquitetura *Transformer*, é composta por um codificador e um decodificador, ambos utilizando camadas de atenção e redes *feed-forward*.

Essa arquitetura tornou-se a base para os Modelos de Linguagem de Larga Escala (LLMs). Essa evolução se ramificou em abordagens distintas: modelos focados na compreensão pro-

funda do contexto, como o *BERT*, e modelos voltados para a geração de texto, como a série *GPT*. Arquiteturas contemporâneas consolidaram essas técnicas com otimizações de memória, possibilitando que esses modelos atingissem as habilidades emergentes observadas atualmente.

2.1.2 Aprendizado Social e Transmissão Cultural

Para validar se essas competências computacionais sustentam dinâmicas culturais, em cenários mistos, é necessário compreender os mecanismos de transmissão de conhecimento, tendo como base o ser humano. Essa análise fundamenta-se na Teoria do Aprendizado Social de Albert Bandura, a qual postula que os indivíduos aprendem através da observação, imitação e modelagem do comportamento de outros. Bandura enfatizou a importância dos processos cognitivos, propondo que novos comportamentos e conhecimentos sejam adquiridos ao observar terceiros, um processo denominado “aprendizagem vicária”, conforme analisado por McLeod [11].

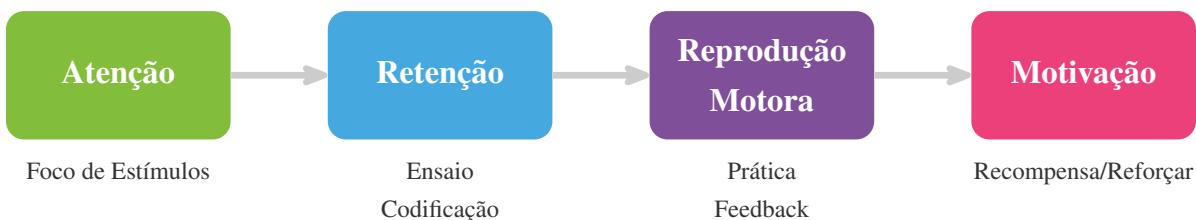


Figura 1: Diagrama da Teoria do Aprendizado Social de Albert Bandura.

Segundo esta teoria, crenças e expectativas influenciam as ações dos indivíduos, que são capazes de avaliar as conexões entre seus comportamentos e as consequências resultantes. Para que o aprendizado social ocorra com sucesso, Bandura identifica quatro estágios cognitivos essenciais:

- **Atenção:** O indivíduo deve, primeiramente, manter o foco no comportamento observado, o que exige concentração ativa nas ações.
- **Retenção:** O comportamento observado precisa ser memorizado, do qual envolve o processamento cognitivo e o armazenamento da informação para uso futuro.
- **Reprodução:** O observador tenta replicar o comportamento, o que pode envolver a prática e o refinamento das ações até que possam ser executadas com precisão.
- **Motivação:** É necessário haver um incentivo para realizar o comportamento, seja por reforço, punição, aprovação social ou outras recompensas.

Além disso, a teoria sugere que terceiros atuam como exemplos; se os observadores presenciam ações sendo recompensadas, a probabilidade de imitação aumenta. Consequentemente, a exposição repetida a esses modelos pode moldar percepções de normas culturais e atitudes conforme McLeod [11].

Expandindo a análise para além do indivíduo, observa-se que as funções psicológicas superiores do ser humano são geradas através da convivência em comunidade. Enquanto a teoria de Bandura foca no mecanismo cognitivo de observação, a perspectiva sócio-histórica argumenta que tal desenvolvimento é intrinsecamente um processo de apropriação cultural, conforme as leis descritas por dos Anjos Pereira and Galuch [4].

Nesse contexto, Leontiev, citado por dos Anjos Pereira and Galuch [4], estabelece o processo de hominização como uma distinção entre homens e animais. Enquanto os animais limitam-se a adaptações biológicas e instintivas, o ser humano organiza-se sob as bases da vida social. O indivíduo nasce com as propriedades biológicas necessárias, mas é somente através da apropriação da cultura e da experiência acumulada pela humanidade que sua cognição efetivamente se desenvolve.

Um exemplo clássico que ilustra a dependência da inteligência em relação ao meio social é o caso de Victor, conhecido como o “Garoto Selvagem de Aveyron”, encontrado na França em 1797. O jovem, com idade estimada entre 11 e 12 anos, vivia isolado em bosques e, ao ser resgatado, não apresentava comportamentos humanos básicos: não falava, não possuía postura ereta e seus interesses restringiam-se à sobrevivência biológica imediata [4].

A análise realizada por dos Anjos Pereira and Galuch [4] deste caso revela que as dificuldades de Victor em desenvolver o pensamento abstrato e a linguagem decorreram da falta de interação social durante seu desenvolvimento. Privado do contato com a cultura, desenvolveu apenas uma inteligência prática, voltada ao uso de objetos para fins biológicos, sem conseguir atribuir-lhes significado social ou simbólico. O caso demonstra que a inteligência não emerge automaticamente do aparato biológico; ela requer o suporte simbólico que apenas a interação social fornece para que se possa generalizar ou planejar conscientemente ações.

Estabelecido que a inteligência humana é produto da interação social e estabelecido o funcionamento de um agente artificial baseado em *LLM*, surge uma questão para este trabalho: os agentes artificiais, possuem os pré-requisitos cognitivos para participar dessa dinâmica? Para responder a isso, é necessário analisar as capacidades dos Modelos de Linguagem, que transcendem a simples estatística textual e começam a exibir traços de cognição e raciocínio lógico.

O trabalho de Duéñez-Guzmán et al. [6] sugere que, assim como ocorreu na evolução humana, a inteligência artificial pode depender da inserção em um ambiente de troca social e cultural para atingir níveis superiores de complexidade. Os autores apontam que a abordagem tradicional das IAs, focada em agentes unitários e *datasets* estáticos, enfrenta uma estagnação, que tem como solução a transição para sistemas multiagentes capazes de gerar seus próprios dados através da interação social. Esse processo fundamenta-se no conceito de “Inovação Composta”, um ciclo virtuoso onde novas estratégias de exploração criam, consequentemente, novas oportunidades de aprendizado.

Duéñez-Guzmán et al. [6] estruturam essa evolução em três níveis:

- **Vida Coletiva:** Onde a competição impulsiona conhecimento e corridas evolutivas;

- **Relacionamentos Sociais:** Que permitem a mitigação de erros via aprendizado social;
- **Cultura Cumulativa:** Onde a linguagem permite o refinamento e o acúmulo de conhecimento através de gerações.

Assim, a integração de agentes em dinâmicas sociais é um requisito para desbloquear níveis de competência análogos aos humanos.

2.1.3 Habilidades Emergentes e Raciocínio em LLMs

Para compreender a arquitetura dos agentes artificiais propostos neste trabalho, é preciso entender o conceito de “emergência” no contexto de *LLMs*. Diferente de sistemas de automação clássicos, onde o comportamento é explicitamente programado ou de alguma forma previsível, as *LLMs* exibem fenômenos onde mudanças quantitativas no sistema resultam em mudanças qualitativas de comportamento.

Neste contexto, define-se uma habilidade como emergente quando ela não está presente em modelos menores, mas se manifesta espontaneamente em modelos de maior escala. A escala, neste domínio, é analisada sob três pilares: a quantidade de computação empregada no treinamento, o número de parâmetros do modelo e o tamanho do conjunto de dados de treinamento [14].

Uma característica distintiva das habilidades emergentes é a imprevisibilidade: elas não podem ser antecipadas pela simples extração do desempenho de modelos menores. Ao analisar curvas de escala, observa-se, em vez de uma evolução linear, um padrão de transição de fase. Essa característica implica que a competência de um agente artificial para realizar tarefas complexas pode depender intrinsecamente do uso de modelos que superem uma “massa crítica” de escala [14].

A pesquisa de Wei et al. [14] identifica diversas habilidades que emergem apenas em grandes escalas e que são necessárias para a construção de agentes capazes de interação social e resolução de problemas. Destacam-se, para os fins deste trabalho, as habilidades de *Prompting* e Raciocínio Lógico, que sustentam as entidades “Pensador” e “Executor” descritas na seção 3.4.

Também, utiliza-se a estratégia denominada *Chain-of-Thought* (Cadeia de Pensamento), que instrui o modelo a gerar uma sequência de passos intermediários antes de fornecer a resposta final. A eficácia dessa técnica é, em si mesma, uma habilidade emergente. Em modelos menores, o uso de *Chain-of-Thought* não resulta em melhoria de desempenho, podendo inclusive prejudicá-lo. Apenas quando o modelo atinge uma escala suficiente é que ele adquire a capacidade de raciocinar sequencialmente de forma superior ao *prompting* padrão. Esta fundamentação justifica a escolha de *LLMs* de grande porte para o agente artificial deste trabalho, visto que a decomposição lógica de estratégias sociais é uma tarefa de múltiplos passos que modelos menores não conseguem processar adequadamente.

Dentre as habilidades que emergem com a escala, uma das mais importantes para a colaboração é a capacidade de inferir estados ocultos de outros agentes, competência análoga à Teoria da Mente humana [9].

A Teoria da Mente (*ToM*) define-se como a capacidade de rastrear, de forma automática e fluida, os estados mentais não observáveis de terceiros, tais como conhecimento, intenções, crenças e desejos. Em seres humanos, essa habilidade é importante para interações sociais, comunicação, empatia, julgamento moral e autoconsciência. Embora animais utilizem pistas observáveis (como postura corporal ou olhar) para prever comportamentos, a *ToM* distingue-se por permitir a compreensão de que outro indivíduo pode possuir crenças que divergem da realidade ou do próprio conhecimento do observador [9].

No contexto da Inteligência Artificial, Kosinski [9] demonstram a aptidão das *LLMs* para resolverem tarefas de *ToM* com desempenho comparável ao de crianças de seis anos de idade. Tecnicamente, esse fenômeno é facilitado pelo mecanismo de “atenção” presente na arquitetura *Transformer* dos modelos. Esse mecanismo permite que o modelo alterne o foco dinamicamente entre diferentes partes da entrada de dados, ponderando a importância relativa de palavras e frases para compreender dependências contextuais. Assim, a “atenção” capacita o modelo a rastrear conexões relevantes entre ações, diálogos e estados internos dos agentes ao longo de uma narrativa, simulando a cognição social [9].

Porém, ainda que *LLMs* possam, em alguma medida, demonstrar a capacidade de “entender” o outro (*ToM*), não é suficiente se o agente não puder seguir regras lógicas de forma consistente para executar tarefas. As limitações do conhecimento implícito das *LLMs* exigem *frameworks* estruturados de raciocínio.

Para operacionalizar a capacidade de raciocínio lógico consistente, aprofunda-se aqui a mecânica do *framework Hypotheses-to-Theories (HtT)*, proposto por Zhu et al. [16]. Esta abordagem estrutura o aprendizado em dois estágios distintos, análogos às fases de treinamento e teste em redes neurais clássicas, mas operando sobre regras textuais interpretáveis: o Estágio de Indução e o Estágio de Dedução.

No Estágio de Indução, o objetivo é descobrir regras a partir de um conjunto de exemplos, sem a necessidade de anotações manuais. O processo ocorre nas seguintes etapas:

- **Geração e Verificação:** O modelo é solicitado a gerar regras para responder a uma questão e, simultaneamente, verificar essas regras comparando sua previsão final com a resposta correta (gabarito).
- **Filtragem de Regras:** Visto que *LLMs* podem gerar regras incorretas, o sistema coleta todas as regras geradas e aplica métricas de mineração de regras (*rule mining*). São avaliados dois critérios principais [16]:
 - **Cobertura:** A frequência com que uma regra aparece no conjunto de dados.

- **Confiança:** A probabilidade de a regra levar a uma resposta correta quando aplicada.
- **Construção da Biblioteca:** Apenas as regras que superam limiares mínimos de cobertura e confiança são armazenadas na “biblioteca de regras”, garantindo a robustez do conhecimento adquirido.

Para otimizar este processo, utiliza-se a técnica denominada “Indução a partir da Dedução” (*Induction from Deduction*). Em vez de criar *prompts* separados para gerar e verificar regras, adapta-se um *prompt* de raciocínio dedutivo (como *Chain-of-Thought*) para realizar ambas as funções segundo estratégia de Zhu et al. [16].

No Estágio de Dedução, o modelo utiliza a biblioteca de regras aprendidas para resolver novos problemas de teste. O *HtT* incorpora a biblioteca de regras diretamente no *prompt*, diferente dos métodos tradicionais, que forçam o modelo a inferir regras no momento da execução,. O modelo é, então, instruído a recuperar e aplicar as regras explicitamente.

A aplicação desta metodologia demonstra que a falha das *LLMs* em tarefas complexas advém, muitas vezes, não da incapacidade de raciocinar, mas da aplicação de regras implícitas incorretas. Ao externalizar o conhecimento em uma biblioteca aprendida, observa-se uma redução na geração de regras erradas, resultando em ganhos de precisão em tarefas de raciocínio relacional e numérico. Além disso, as regras aprendidas demonstram capacidade de transferência, indicando que o modelo é capaz de abstrair a lógica e aplicá-la em diferentes formatos do mesmo problema [16].

Embora as *LLMs* sejam tradicionalmente treinadas para absorver padrões estruturais da linguagem natural, pesquisas demonstram que suas capacidades se estendem a domínios não linguísticos. Contrariando a intuição predominante de que esses modelos dependem exclusivamente de texto, observa-se que *LLMs* pré-treinadas podem atuar como “máquinas de padrões gerais” (*General Pattern Machines*) [12].

Essa competência fundamenta-se na habilidade do modelo de completar, sequências complexas de *tokens* arbitrários. Sem a necessidade de treinamento adicional ou ajuste fino (*fine-tuning*), as *LLMs* conseguem atuar como modeladores gerais de sequências, impulsionados pelo aprendizado em contexto (*in-context learning*). No âmbito da automação e robótica, isso sugere que a habilidade de representar e extrapolar padrões abstratos pode ser transferida do domínio das palavras para o das ações.

Um aspecto para a aplicação de *LLMs* em sistemas de controle e jogos lógicos é a descoberta da “invariância de *tokens*”. O estudo realizado por Mirchandani et al. [12] aponta que a proficiência na conclusão de padrões é parcialmente mantida mesmo quando as sequências são expressas utilizando *tokens* amostrados aleatoriamente do vocabulário, ou seja, símbolos desprovidos de significado semântico prévio.

Os autores indicam que as *LLMs* possuem uma capacidade generalista de representar e extrapolar padrões simbólicos, sendo invariantes aos *tokens* específicos utilizados na tarefa, con-

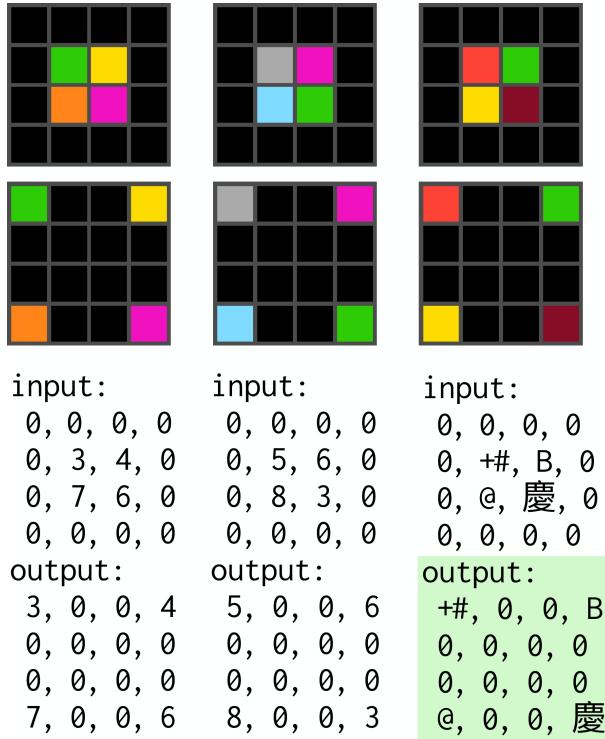


Figura 2: Demonstração de LLMs atuando como “Máquinas de Padrões Gerais”. A imagem ilustra como o modelo consegue identificar a lógica e as sequências abstratas para completar o padrão corretamente apenas observando os exemplos fornecidos no contexto.

Fonte: Mirchandani et al. [12]

forme exemplo da Figura 2. Essa característica sugere que o rearranjo espacial de objetos ou a lógica de um jogo, sejam representados através de *tokens*, validando o uso desses modelos para raciocinar sobre dinâmicas difíceis de descrever com precisão apenas com palavras.

Além do reconhecimento de padrões estáticos, as *LLMs* atuam na conclusão e no aprimoramento de sequências temporais, processo análogo ao planejamento de trajetórias em robótica. A otimização de uma trajetória em relação a uma função de recompensa pode ser estruturada como a extração de uma sequência composta por *tokens* de estado e ação com retornos crescentes.

Contudo, a aplicação de *LLMs* em tarefas de robótica e controle impõe a superação do desafio conhecido como *symbol grounding* (referenciamento simbólico).

Este desafio refere-se ao problema de a IA construir conhecimento apenas relacionando símbolos uns com os outros, sem uma referência na experiência de mundo real. Essa limitação torna-se evidente em contraste com o conhecimento humano, que se fundamenta na relação direta com a percepção (visão, tato, estados internos) e com a ação física; as *LLMs* tradicionais, ao contrário, operam manipulando símbolos que, para o modelo, carecem de referenciamento simbólico real.

Para mitigar essa desconexão, modelos denominados *Vision-Language-Action* (VLAs) começam a quebrar esse paradigma ao buscar relacionar linguagem e experiência (percepção

e ação) em um mesmo espaço latente. Trabalhos como o *framework Keypoint Action Tokens (KAT)*, proposto por Di Palo and Johns [3], exemplificam essa tentativa ao converter observações contínuas de ações em *tokens* discretos que o modelo possa processar semanticamente.

Essa unificação dos espaços de representação visa permitir que a *LLM* infira a relação entre o estado atual do ambiente e a ação necessária. Contudo, o problema do *symbol grounding* persiste; embora tais abordagens ilustrem um caminho para lidar com a integração visual e motora, elas ainda oferecem soluções limitadas.

2.1.4 Dinâmicas de Informação e Homogeneização Cultural

Além dos temas mencionados até aqui, resta também compreender as implicações sistêmicas da inserção dessas IAs em grupos. A literatura recente aponta para um fenômeno de dupla face na aplicação dos agentes artificiais: por um lado, o risco de homogeneização; por outro, o potencial de descoberta acelerada através da interação multiagente e da inovação recombinante [7].

Para compreender a dinâmica de aprendizado social entre humanos e agentes artificiais, é necessário fundamentar como a Inteligência Artificial Generativa processa, padroniza e transmite a informação dentro de um ecossistema de conhecimento. Segundo a teoria proposta por Ghafouri [7], a adoção de *LLMs* gera um efeito dialético sobre a produção de conhecimento: ao mesmo tempo em que promove uma homogeneização da informação, cria condições para uma inovação recombinante entre domínios distintos. O primeiro mecanismo descrito pelos autores é o “Prisma da IA” (*The AI Prism*), definido como um mecanismo sociotécnico cuja arquitetura é projetada para reduzir a variância e convergir para a média estatística. Tecnicamente, isso ocorre porque as *LLMs* são treinadas para prever o próximo *token* mais provável, minimizando o erro de previsão. Consequentemente, o modelo tende a suprimir dados atípicos ou raros, favorecendo saídas que gravitam em torno do centro da distribuição de treinamento. Em um contexto colaborativo, isso pode levar a um efeito de “nívelamento”, onde a diversidade de estratégias é comprimida em favor de soluções padronizadas.

Esse fenômeno é reforçado pela “Epistemologia Derivada da IA” (*AI-Derivative Epistemology*). Trata-se de um padrão onde indivíduos delegam tarefas de síntese e avaliação ao sistema, aceitando as saídas da IA devido a uma preferência racional pela economia de esforço cognitivo. Se os agentes atuarem como consumidores passivos dessas saídas, o sistema corre o risco de entrar em um “ciclo de homogeneidade”, resultando em estagnação criativa.

Apesar da tendência à homogeneização, Ghafouri [7] argumentam que a redução de variância local é, paradoxalmente, a precondição para a inovação em escala global. Este fenômeno, descrito como a “Ponte Paradoxal” (*The Paradoxical Bridge*), sugere que para haver aprendizado social entre “clusters” de conhecimento diferentes, é necessário superar os custos de tradução.

A IA atua aqui através da “Liquefação de Significado” (*Meaning Liquefaction*). Ao mapear

terminologias rígidas em um espaço vetorial compartilhado, as *LLMs* transformam conhecimentos estáticos em módulos interoperáveis. Essa padronização atua como uma língua estatística, permitindo que conceitos sejam desvinculados de seus contextos originais e recombinados em novas configurações.

Por fim, a teoria propõe um modelo de contingência onde o resultado da interação depende de qual dinâmica prevalece:

- **Efeito de Nivelamento:** A IA substitui habilidades centrais, levando à erosão de competências e à estagnação.
- **Efeito de Amplificação:** A IA é utilizada para tarefas complementares, permitindo que os agentes foquem em síntese de alto nível e curadoria, resultando no aumento da variância informacional.

Portanto, a capacidade de um sistema misto demonstrar aprendizado social efetivo depende da presença de estruturas que incentivem a curadoria ativa em detrimento da deferência passiva.

Apresentados os conceitos, esse referencial teórico multidisciplinar estabelece a base da pesquisa, conectando processos cognitivos individuais, dinâmicas de transmissão de conhecimento em grupo e a capacidade de inferência social para investigar se e como uma inteligência artificial pode se integrar a um ecossistema social.

2.2 Trabalhos Relacionados

A construção dos agentes artificiais desta pesquisa, que devem ser capazes de aprendizado social, insere-se na análise de pesquisas que, também, buscam replicar a dinâmica de descoberta coletiva em sistemas sociais. É necessário um olhar multidisciplinar que transcende a tecnologia, incorporando as ciências cognitivas para entender como a inteligência emerge em grupos, bem como a sociologia da interação humano-máquina.

A revisão dos trabalhos relacionados a seguir estrutura-se conectando três eixos: inicia-se com os mecanismos de coordenação observados na natureza, avança para os experimentos de inserção de IAs em dinâmicas de grupo e culmina nas arquiteturas cognitivas propostas para que esses agentes superem suas tendências estatísticas e participem efetivamente da construção de conhecimento.

2.2.1 Inteligência Coletiva e Coordenação Implícita

No âmbito da investigação sobre cognição coletiva e resolução colaborativa de problemas, o estudo de Dreyer et al. [5] estabelece um precedente para a presente pesquisa. Os autores exploram o fenômeno da inteligência coletiva comparando o desempenho de formigas e seres humanos na resolução do “problema do carregador de piano”, um desafio geométrico que exige coordenação espacial para transportar uma carga através de um ambiente obstruído, como mostra a Figura 3.

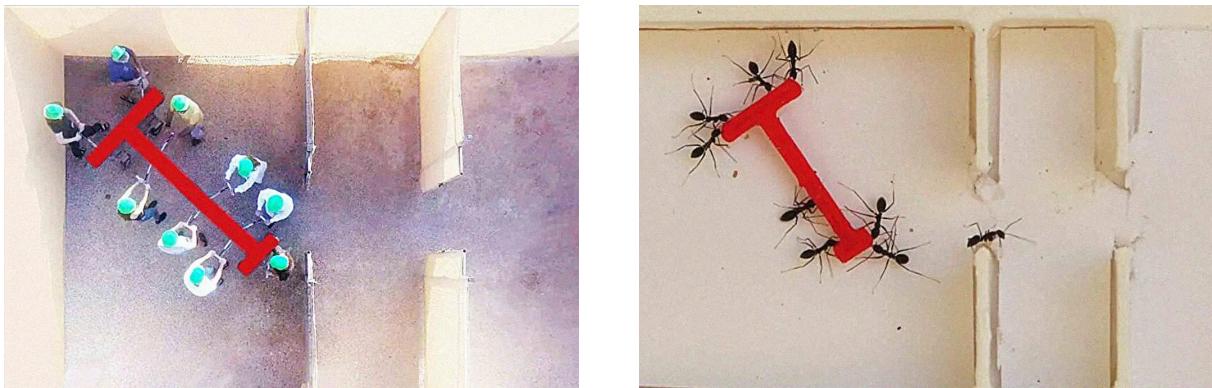


Figura 3: Comparação de desempenho na resolução cooperativa do problema do carregador de piano entre humanos e formigas.

Fonte: Dreyer et al. [5]

A relevância para o escopo deste trabalho reside na metodologia de restrição de comunicação adotada. Dreyer et al. [5] demonstram que, grupos de formigas escalam sua eficiência com o aumento do número de indivíduos, através do desenvolvimento de uma “memória coletiva” emergente baseada em interações, grupos humanos apresentam um declínio de performance quando a comunicação verbal é restringida. Sob condições de comunicação restrita, os humanos tendem a recorrer a heurísticas locais e decisões gananciosas, buscando o caminho mais curto imediato em detrimento da solução global ótima, um fenômeno que os autores associam à busca rápida por consenso. Embora o trabalho de Dreyer et al. [5] foque na comparação biológica interespécies, ele valida a premissa metodológica deste projeto de que a restrição de canais de comunicação força a emergência de comportamentos de coordenação implícita. A presente pesquisa apropria-se dessa estrutura experimental, mas desloca a fronteira da comparação do biológico para o artificial, e investiga se os modelos de linguagem conseguem superar as limitações humanas, atuando como catalisadores de aprendizado social ou se, inversamente, sucumbirão às mesmas heurísticas observadas nos grupos humanos isolados.

2.2.2 Colaboração Humano-IA em Dinâmicas Sociais

Enquanto os estudos de Dreyer et al. [5] elucidam os limites da coordenação humana desprovida de linguagem em comparação a enxames biológicos, surge a necessidade de investigar se a introdução de uma inteligência artificial altera esse resultado. A literatura transita da observação de fenômenos naturais para a engenharia ativa de sistemas artificiais. Não se trata apenas de perguntar “como humanos colaboram”, mas “como a colaboração humana é remodelada pela presença de uma cognição artificial”. Nesse novo paradigma, a IA deixa de ser uma ferramenta inerente para se tornar um agente ativo na dinâmica do grupo, conforme explorado a seguir.

Nesse cenário, destaca-se o trabalho de Dell’Acqua et al. [2], que investigou, por meio de um experimento, como a Inteligência Artificial Generativa transforma os pilares da colaboração: performance, compartilhamento de *expertise* e engajamento social. Os autores introduzem o conceito de “parceiro cibernetico”, demonstrando que indivíduos auxiliados por IA conseguem

igualar, e em certos casos superar, a performance de equipes humanas tradicionais.

A contribuição de Dell'Acqua et al. [2] é particularmente relevante para o presente trabalho ao evidenciar que a IA atua rompendo “silos funcionais”. No experimento, a tecnologia permitiu que os profissionais gerassem resultados viáveis, democratizando a expertise técnica. Os autores argumentam que a tecnologia assume um papel ativo na cognição distribuída, alterando a estrutura do trabalho coletivo e oferecendo uma “sinergia única” capaz de gerar soluções de alta qualidade. Os autores focam na capacidade da IA de substituir certas funções colaborativas sem a perda de qualidade, e com um impacto emocional positivo nos participantes humanos, que relataram menor fricção de coordenação.

Contudo, os achados de Dell'Acqua et al. [2] limitam-se a observar a IA sob a ótica da produtividade e do preenchimento de lacunas de competência. Resta, no entanto, uma questão sobre a natureza da interação: pode um agente artificial não apenas auxiliar, mas liderar ou substituir funcionalmente em tarefas que exigem inferência social? Se Dell'Acqua et al. [2] posicionam a IA focada em eficiência, Weidmann et al. [15] radicalizam essa investigação ao analisar a inclusão de agentes artificiais como participantes ativos em experimentos sociais, investigando se esses agentes podem ser eficazes na substituição de humanos.

Os autores utilizaram uma adaptação do paradigma de “*Hidden Profile*” (Perfil Oculto), onde a informação necessária para resolver um problema é distribuída entre os membros da equipe, exigindo colaboração ativa para a descoberta da resolução. Esta abordagem metodológica faz com que o sucesso dependa da inferência coletiva e da coordenação entre os agentes.

Os resultados obtidos por Weidmann et al. [15] demonstraram uma correlação entre a eficácia de líderes humanos gerenciando equipes de IA e seu impacto causal em equipes humanas reais. Tal achado oferece evidências de que os padrões de interação e colaboração observados em ambientes mistos (Humano-IA) são generalizáveis para dinâmicas puramente humanas. O estudo destaca ainda que comportamentos colaborativos eficazes, como a alternância de turnos na conversação e o questionamento ativo, foram replicados de forma consistente pelos agentes artificiais.

Entretanto, é necessário pontuar as diferenças de escopo e as limitações identificadas que informam a presente análise. Enquanto Weidmann et al. [15] focam na estrutura hierárquica e na liderança explícita mediada pela linguagem verbal, este trabalho investiga o aprendizado social horizontal e a transmissão cultural de regras através da observação. Adicionalmente, os autores observaram que, embora a competência técnica dos agentes seja alta, há uma diminuição da emoção nas interações com as IAs em comparação com humanos. Esta distinção é relevante para a análise qualitativa proposta, sugerindo que embora a transmissão de conhecimento possa ser eficaz, a percepção de vínculo social pode ser um fator limitante na colaboração híbrida.

2.2.3 Desenvolvimento Cognitivo e Limitações Estatísticas

Embora os trabalhos apresentados demonstrem que agentes artificiais baseados em modelos de linguagem possuem competência para atuar em grupos sociais, esses estudos analisam modelos estáticos em seu treinamento. Para que um agente participe de um processo de evolução cultural e descoberta, ele não pode ser apenas um executor competente; ele precisa ser um aprendiz adaptável.

É nessa lacuna de desenvolvimento que se insere a proposta de Kovač et al. [10]. Os autores voltam-se para a gênese das habilidades sociais, argumentando que o “*SocialAI School*” é um ambiente procedural projetado para treinar e avaliar agentes artificiais em habilidades cognitivas. Os autores argumentam que, para uma IA participar efetivamente da evolução cultural humana, ela não deve apenas otimizar recompensas em tarefas isoladas, mas sim desenvolver competências sociais básicas. O trabalho destaca conceitos como a atenção conjunta, a comunicação referencial e o aprendizado cultural, defendendo que a inteligência artificial deve seguir uma trajetória de desenvolvimento análoga à humana, onde a interação social precede e molda a cognição individual. A relevância deste estudo para a presente pesquisa reside na validação da premissa de que a inteligência não é um fenômeno solitário, mas sim emergente de interações sociais ricas. Enquanto os autores utilizam ambientes simplificados focados majoritariamente no treinamento de agentes de Aprendizado por Reforço para adquirir habilidades de baixo nível, a presente pesquisa investiga a aplicação dessas capacidades em um nível de abstração superior, utilizando *LLMs* em um jogo de descoberta coletiva.

Além disso, os autores exploram o conceito de *scaffolding* (andaime), onde o ambiente ou um tutor estrutura o aprendizado do agente, reduzindo graus de liberdade até que a competência seja adquirida. Essa abordagem dialoga com a metodologia aqui empregada, onde a estrutura do jogo e a interação com humanos funcionam como um *scaffolding* social para a *LLM*. Uma observação crítica feita por Kovač et al. [10] em seus experimentos com *LLMs* é que, embora estes modelos demonstrem alta eficiência de amostra, eles muitas vezes falham em generalizar inferências sociais para novos contextos sem um *prompt* ou ajuste fino adequado. Esse achado corrobora a necessidade da arquitetura cognitiva proposta neste trabalho, desenhada para superar essas limitações e permitir que o agente mantenha uma coerência estratégica e social ao longo de ciclos de transmissão cultural. Portanto, enquanto o “*SocialAI School*” foca na emergência das habilidades sociais básicas, este trabalho avança para investigar se agentes já dotados de capacidades linguísticas podem obter, sustentar e transmitir conhecimento cultural em grupos híbridos.

A proposta esbarra, todavia, em uma barreira intrínseca Modelos de Linguagem atuais. Mesmo submetidos a um ambiente rico de interações, os *LLMs* operam sob mecanismos probabilísticos que podem ser antagônicos à criatividade estratégica necessária para a resolução de problemas inéditos. Essa tensão entre a capacidade de processar linguagem e a tendência à estagnação estatística é formalizada por Keon et al. [8] através da “Lei da Mediocridade”.

Antes de esperar que um agente aprenda socialmente, é necessário mitigar sua tendência de

convergir para a média. Em seu estudo, Keon et al. [8] realizam testes de estresse, demonstrando que, sem guias explícitos, os modelos falham em manter a criatividade. Ao simplificar e posteriormente expandir ideias, observou-se que elementos com profundidade emocional desaparecem rapidamente, sendo substituídos por clichês de alta frequência. Uma conclusão dos autores, que dialoga diretamente com a presente pesquisa, é a distinção entre a diversidade lexical e a originalidade real. O fato de um modelo gerar um texto fluente e variado não implica que ele esteja produzindo uma solução inovadora e eficaz.

O escopo de Keon et al. [8] foca no domínio criativo da publicidade, porém suas descobertas sobre a tendência dos modelos de priorizar a média oferecem um contraponto técnico para a aplicação de *LLMs* em tarefas de colaboração. A homogeneização alertada sugere que um agente artificial pode convergir para comportamentos médios e previsíveis, falhando em situações que exigem criatividade fora da distribuição padrão dos dados de treinamento. Esta tendência à homogeneização é uma variável importante para o presente estudo, pois sugere a hipótese de que grupos mistos (Humano-IA) podem sofrer de “estagnação criativa” caso os agentes artificiais não consigam superar a regressão à média inerente à sua natureza.

No contexto da capacidade de raciocínio e aprendizado de agentes artificiais, Zhu et al. [16] investigam as limitações dos *LLMs* em tarefas que exigem raciocínio dedutivo complexo apenas com base em conhecimento implícito. Para mitigar erros gerados por alucinações ou inconsistências, os autores propõem o *framework Hypotheses-to-Theories* (*HtT*), uma abordagem que ensina o modelo a induzir uma biblioteca de regras a partir de exemplos de treinamento e, subsequentemente, utilizar essas regras explicitamente para deduzir respostas. O estudo demonstra que, ao separar o processo em duas etapas, indução (geração e verificação de regras) e dedução (aplicação das regras), é possível obter ganhos de acurácia entre 11% e 37% em tarefas de raciocínio relacional e numérico.

A relevância do trabalho de Zhu et al. [16] para esta pesquisa reside na validação da capacidade de extrair regras generalizáveis a partir de observações contextuais. Zhu et al. [16] focam na indução de regras lógicas explícitas (textuais e simbólicas) para resolver problemas individuais, enquanto o presente trabalho estende essa lógica para um ambiente de aprendizado social, onde as “regras” a serem induzidas são as mecânicas do jogo e as estratégias colaborativas, inferidas não através de texto, mas pela observação das ações dos outros participantes.

Metodologicamente, o *framework HtT* oferece suporte à hipótese deste trabalho de que *LLMs* não são apenas repositórios estáticos de dados, mas sistemas capazes de aprendizado *in-context*. A distinção, no entanto, é que Zhu et al. [16] utilizam verificação com base em respostas verdadeiras (*ground truth*) para filtrar regras, e neste trabalho a verificação ocorre de forma dinâmica e social, através do sistema de *feedback* e da convergência comportamental com o grupo. Assim, este trabalho avança na investigação ao testar se essa capacidade de indução de regras comprovada por Zhu et al. [16] se sustenta quando o “professor” não é um conjunto de dados estático, mas um grupo de pares humanos e artificiais em interação contínua.

Dessa forma, a análise dos trabalhos correlatos estabelece parte do contexto metodológico

desta pesquisa: parte-se da coordenação implícita e da viabilidade da IA social, avançando para o aprendizado *in-context*. A Tabela 1 consolida essa visão, contrastando as abordagens citadas com a proposta específica deste trabalho.

Tabela 1: Comparativo entre trabalhos relacionados e a presente pesquisa.

Referência	Contribuição Relacionada	Diferenciação (Este Trabalho)
Dreyer et al. [5]	Utiliza um quebra-cabeça geométrico e restrição de comunicação para forçar a coordenação implícita.	A comparação original é biológica (formigas vs. humanos), enquanto aqui o foco é a comparação entre humanos e IA.
Dell’Acqua et al. [2]	Explora a IA como um parceiro que participa ativamente da cognição distribuída em equipes.	Foca em produtividade profissional, enquanto aqui foca no aprendizado social horizontal via observação.
Weidmann et al. [15]	Usa o paradigma de “Perfil Oculto” (<i>Hidden Profile</i>), onde o sucesso depende da colaboração.	Foca em liderança e comunicação verbal; este trabalho foca na coordenação não-verbal.
Kovač et al. [10]	Defende que a inteligência emerge de interações sociais (<i>scaffolding</i>).	Aplica em agentes de Aprendizado por Reforço (baixo nível), enquanto aqui se usa LLMs em abstração superior.
Keon et al. [8]	Formaliza a tendência de LLMs convergirem para a média estatística (limitação de criatividade).	Utiliza esses achados não como fim, mas como base para propor a arquitetura cognitiva do agente.
Zhu et al. [16]	Apresenta o framework HtT, validando que LLMs podem induzir regras de observações contextuais.	A verificação no HtT original é via dados estáticos; aqui ela ocorre de forma dinâmica e social no jogo.

3 DESENVOLVIMENTO

Tendo a base no alicerce teórico, esta seção detalha a concepção e a implementação do experimento, que emprega um jogo colaborativo como cenário para investigar a evolução cultural e a transmissão de conhecimento. Serão apresentados os cenários de teste e os procedimentos de coleta e análise de dados, visando elucidar os mecanismos de aprendizado social entre agentes humanos e agentes artificiais.

3.1 Desenho do Experimento

Para o experimento, foi implementado um jogo multijogador colaborativo para quatro participantes simultâneos, que podem ser humanos ou *LLMs*. Cada jogador possui uma interface individual, na qual não há comunicação verbal; os jogadores apenas observam as ações uns dos outros nas telas, que são sobrepostas, permitindo o acompanhamento visual das atividades alheias. Esta condição de comunicação restrita é o que força o surgimento de mecanismos de coordenação e consenso baseados apenas em heurísticas visuais, um cenário que em humanos demonstrou levar à adoção de estratégias mais simples e uniformes, como no trabalho de Dreyer et al. [5].

No início de cada partida, peças (semelhantes às peças de *Tetris*) com cores únicas para cada jogador são geradas aleatoriamente em diferentes poses (x, y, θ) . A Figura 4 apresenta a visão da tela de um participante, neste caso, o jogador associado à cor azul. A interface permite que o jogador visualize suas peças de forma destacada, ao mesmo tempo em que oferece uma percepção do ambiente de jogo dos demais participantes, cujas peças são exibidas em segundo plano com uma coloração mais translúcida. Tal *design* enfatiza a colaboração visual e a observação indireta das ações alheias.

A mecânica central do jogo envolve transladar e rotacionar as peças com o intuito de alcançar o objetivo (oculto aos jogadores) que se trata do posicionamento das peças semelhantes na mesma pose (x, y, θ) , de forma que elas se sobreponham visualmente, como mostra a comparação entre o inicio do jogo (pontuação: 0.0%) e o final do jogo (pontuação: 100%), na Figura 4.

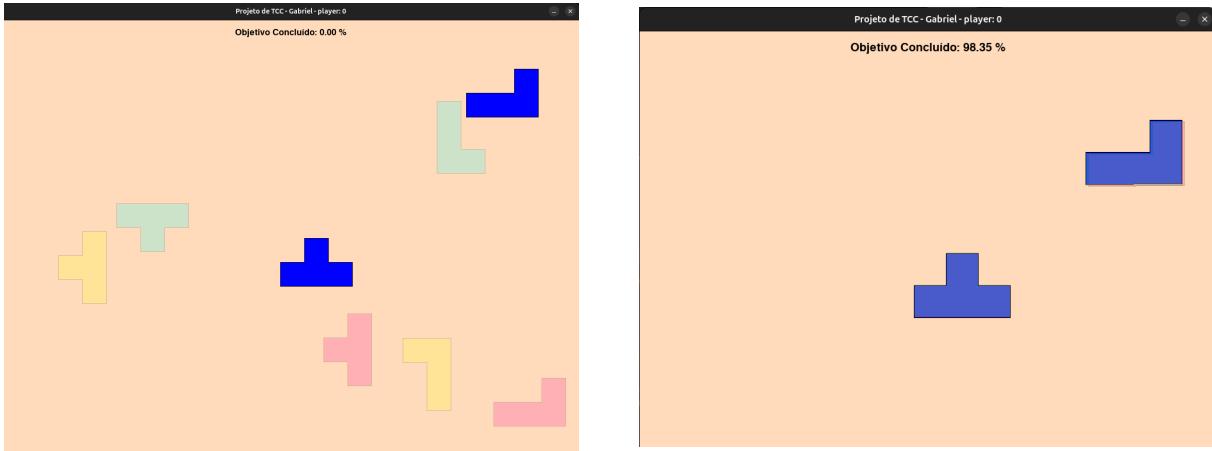


Figura 4: Captura de tela do jogador azul em dois estados distintos: (a) momento inicial com peças dispersas (0,0% de progresso) e (b) momento final com peças alinhadas (100% de progresso).

Fonte: Dreyer et al. [5]

Um mecanismo de *feedback* percentual da pontuação é fornecido, o qual aumenta quando o grupo se aproxima do objetivo do jogo e diminui ao se afastar, servindo como indicador de progresso em direção a meta comum. O mecanismo é análogo ao uso de observação de resultados para inferência de comportamento em modelos de linguagem [3]. Para concluir o jogo, é necessário atingir 95% no *feedback* de pontuação, em razão de uma margem de erro de 5% no alinhamento das peças. Para aumentar essa pontuação, medida por um cálculo de Interseção sobre União (*Intersection over Union – IoU*) adaptado às circunstâncias próprias do jogo, os jogadores devem unir suas peças, sobrepondo-as, o que permite atingir o valor percentual requerido.

A ausência de instruções explícitas sobre como jogar força o aprendizado via observação das ações dos demais, assim como a colaboração entre os agentes. Esse desenho assemelha-se ao cenário de “*Hidden Profile*” (perfil oculto), realizado no trabalho de Weidmann et al. [15], que é um paradigma de ciência social utilizado para examinar a tomada de decisões em grupo. Ele é projetado para garantir que o sucesso dependa da capacidade da equipe de reunir suas informações e sintetizar o conhecimento coletivo para atingir seus objetivos.

Outra informação não indicada aos jogadores é se os demais participantes são humanos ou *LLMs*, o que visa avaliar se o agente artificial consegue demonstrar comportamentos sociais sutis. Essa omissão também é importante para evitar comportamentos previsíveis ou vieses associados à identificação de IAs, mantendo assim os dados coletados livres de interferências externas ao ambiente cultural sob investigação, da mesma forma como explorado nos experimentos de Weidmann et al. [15], Wei et al. [14], Zhu et al. [16]. Em razão desta necessidade, a pesquisa terá como título público aos participantes “APRENDIZADO SOCIAL NA ERA DIGITAL”.

Os formatos das peças estão exibidos na Tabela 2 junto ao seu nome e seu *token* único,

interpretado pela *LLM*. Os dados posicionais e descritores são enviados para o agente no formato JSON seguindo a estrutura apresentada no código 1. Mais detalhes sobre as técnicas de interpretação do agente artificial encontram-se na seção 3.4.

```

1  {
2      "actual_score": "Pontuação atual",
3      "actual_position": {
4          "player_{color}": {
5              "object_{n}": {
6                  "type": "Token representando o formato do objeto",
7                  "pos": [ "x", "y" ],
8                  "rot": "theta"
9              }
10         }
11     }
12 }
```

Código 1: Estrutura de entrada de dados, do agente artificial, contendo o estado global e as coordenadas posicionais das peças dos jogadores.

Além da mecânica de jogo apresentada, a estrutura experimental organiza-se em etapas distintas. O jogo conta com diferentes ciclos, todos com o mesmo objetivo e nível de dificuldade; a diferença reside na renovação gradual dos integrantes do grupo. A característica do experimento é a observação da transmissão de conhecimento entre esses grupos de jogadores.

3.2 Cenários Experimentais

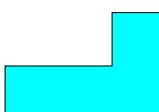
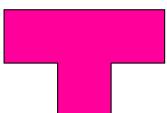
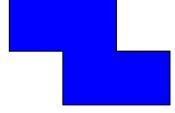
Para avaliar a transmissão e a evolução do conhecimento, o experimento é estruturado em dois cenários (explicados em 3.2.2), cada um composto por 27 ciclos (explicados em 3.2.1). Cada agente participante atua em, no máximo, doze ciclos consecutivos, até sua substituição.

3.2.1 Ciclos

Entende-se por ciclo a estrutura de jogabilidade que vai desde o início do jogo até o momento em que o objetivo é atingido. O encerramento do ciclo é o que valida o progresso, permitindo que o jogo reinicie com uma nova configuração de pose para as peças, e assim um novo ciclo.

O desenho longitudinal prevê a substituição a cada dois ciclos de um membro do grupo que esta jogando, por outro membro do próximo grupo que não possui conhecimento prévio sobre o jogo. Isso garante a renovação gradual dos participantes, mantendo sempre “veteranos” capazes de transmitir o conhecimento adquirido aos novos integrantes, até que a composição original seja totalmente alterada. Esse processo de substituição se repete até que três grupos sucessivos

Tabela 2: Imagens das peças presentes no jogo.

Peça	Nome	Token
	<i>Generic</i>	Interpretado pela <i>LLM</i> como o <i>token</i> “D”
	<i>Hero</i>	Interpretado pela <i>LLM</i> como o <i>token</i> “I”
	<i>Ricky</i>	Interpretado pela <i>LLM</i> como o <i>token</i> “L”
	<i>Teewee</i>	Interpretado pela <i>LLM</i> como o <i>token</i> “T”
	<i>z</i>	Interpretado pela <i>LLM</i> como o <i>token</i> “Z”

sejam formados em cada cenário.

O propósito de observar três grupos é verificar a capacidade de: (1) o primeiro descobrir e transmitir o conhecimento sobre a mecânica do jogo; (2) o segundo recebê-lo e, subsequentemente, repassá-lo; e (3) o terceiro assimilar o conhecimento transmitido pelos grupos anteriores. Após sua substituição, o participante humano preencherá um formulário sobre seu processo de aprendizado e, então, será dispensado.

Cada grupo é composto por quatro agentes, podendo ser exclusivamente humanos ou exclusivamente *LLMs*. Durante as transições entre grupos, ocorrerão formações mistas (humanos e *LLMs*, devido à troca individual a cada dois ciclos), permitindo avaliar a capacidade das *LLMs* de aprender e transmitir conhecimento sobre a mecânica do jogo de forma eficaz em um contexto social heterogêneo.

A Tabela 3 e a Figura 5 exemplificam a composição dos grupos ao longo dos ciclos de um cenário, ilustrando a transição gradual entre eles.

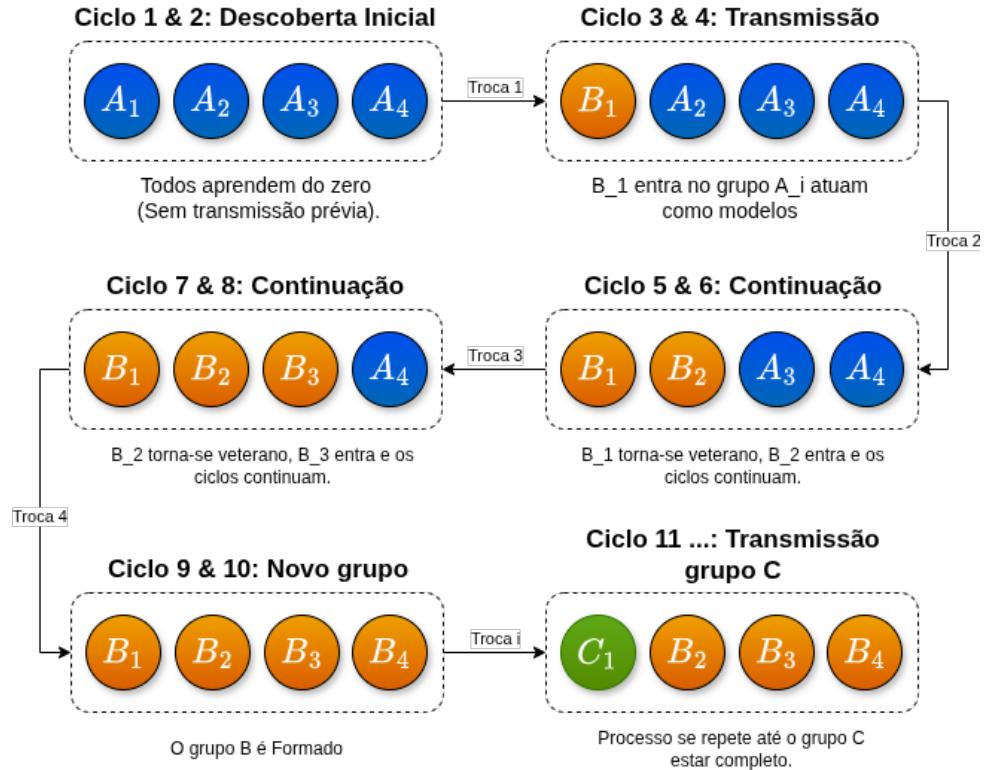


Figura 5: Fluxograma da dinâmica de Transição de Grupos. Cada bloco representa a composição do grupo em um intervalo de ciclos. A cor azul indica os membros detentores do conhecimento original e a laranja indica os novos integrantes que dependem do aprendizado social. Em verde o grupo final que receberá o conhecimento do grupo intermediário.

Tabela 3: Exemplo de transição de grupos em um cenário. A_i representa os agentes que iniciam no Grupo A; B_i representa os agentes que iniciam no Grupo B. A natureza de cada agente (seja A_i ou B_i) pode ser humano ou *LLM*, e é definida conforme o cenário experimental específico, descrito na Tabela 4.

Bloco de Ciclos	Ciclo	Agente 1	Agente 2	Agente 3	Agente 4
Responsável pela Descoberta	1	A_1 (Novo)	A_2 (Novo)	A_3 (Novo)	A_4 (Novo)
	2	A_1	A_2	A_3	A_4
Transmissão Inicial	3	B_1 (Novo)	A_2	A_3	A_4
	4	B_1	A_2	A_3	A_4
Continuação da Transmissão	5	B_1	B_2 (Novo)	A_3	A_4
	6	B_1	B_2	A_3	A_4
Transmissão quase Completa	7	B_1	B_2	B_3 (Novo)	A_4
	8	B_1	B_2	B_3	A_4
Novo Grupo Formado	9	B_1	B_2	B_3	B_4 (Novo)
	10	B_1	B_2	B_3	B_4
<i>(O processo se repete para formar o Grupo C)</i>					

3.2.2 Cenários

Foram projetados dois cenários para investigar a transmissão de conhecimento em configurações com e sem a presença de agentes artificiais. As configurações são exibidas na Tabela 4

Tabela 4: Descrição dos cenários experimentais e da natureza dos grupos.

Cenário	Grupo A	Grupo B	Grupo C
1	Humanos	Humanos	Humanos
2	Humanos	<i>LLMs</i>	Humanos

O Cenário 1 serve como controle, estabelecendo uma linha de base para comparação ao avaliar a eficiência da transmissão de conhecimento em grupos exclusivamente humanos. O Cenário 2 foca na interação mista, investigando se as *LLMs* conseguem aprender com humanos e transmitir esse conhecimento. Em prol da viabilidade técnica, cenários onde a “descoberta fundamental” dependia exclusivamente da iniciativa da IA foram descartados do escopo; testes empíricos preliminares indicaram que o modelo selecionado apresenta limitações de inferência para a gênese da estratégia sem um jogador prévio, conforme detalhado na seção 3.4.

Esses cenários permitem uma análise das dinâmicas de aprendizado social e transmissão cultural em ambientes colaborativos mistos. A comparação entre as configurações mistas segue desenhos experimentais utilizados para isolar o impacto da IA na dinâmica de grupo, conforme também experimentado por Dell’Acqua et al. [2] ao comparar indivíduos e equipes com e sem o auxílio de IA, permitindo que agentes isolados alcancem a qualidade e a integração de *expertise* típicas de equipes humanas.

3.2.3 Implementação Computacional

A simulação do jogo foi desenvolvida em *Python*, com abordagem de orientação a objetos, utilizando a biblioteca *Pygame* para a participação dos agentes e o gerenciamento do estado visual do jogo (posição, rotação e cor das peças). A arquitetura do sistema possui um modelo cliente-servidor. Destaca-se que o código-fonte do jogo é aberto (*open source*) e pode ser inspecionado por qualquer perito, garantindo a transparência e o compromisso com a segurança cibernética, assegurando que não há qualquer tipo de violação ao computador do participante. Ao final da participação, o jogo poderá ser excluído do dispositivo.

SERVIDOR

A arquitetura do servidor utiliza *sockets TCP* para a comunicação e *threading* para gerenciar a concorrência. O servidor atua de forma central, sendo responsável pela geração procedural dos ciclos, posicionando os objetos e validação das posições no início da partida. Para além, ele gerencia o estado global do jogo, monitorando o progresso e calculando a pontuação de forma semelhante à métrica de Interseção sobre União (*IoU*) em uma *thread* separada, dedicada

a cálculos geométricos, o que permite que ele processe a lógica do objetivo sem bloquear a comunicação com os jogadores.

Para o cálculo do progresso, cada jogador (sendo n o número total de jogadores) possui uma área total da união das suas peças chamada de A_{goal} , que é constante para todos, pois o tamanho e tipo das peças se repetem. O servidor calcula a união global de todas as peças chamada de A_{union} .

Ressalta-se que a métrica tradicional de *Intersection over Union (IoU)* não foi adequada para esta aplicação, pois o *IoU* é tipicamente utilizado para medir a sobreposição entre duas instâncias (geralmente uma predição e uma referência). Neste cenário colaborativo com n agentes, o objetivo não é apenas maximizar uma interseção, mas sim promover a convergência de todas as peças para uma mesma posição espacial. O uso de um *IoU* generalizado para n conjuntos (Interseção Global / União Global) seria ineficiente como barra de progresso médio, pois tenderia a valores nulos a menos que os jogadores estivessem próximos ao objetivo final (peças sobrepostas).

A tendência a valores nulos seria prejudicial para o mecanismo de *In-Context Learning* da LLM, que necessita de um gradiente de *feedback* para validar suas hipóteses passo-a-passo, diferentemente da intuição humana que pode lidar com recompensas esparsas.

Portanto, optou-se por uma adaptação na métrica proposta. Quando as peças de diferentes jogadores não se sobrepõem (progresso de 0%), a área total é $A_{union} = n \cdot A_{goal}$; já quando estão perfeitamente alinhadas (progresso de 100%), tem-se $A_{union} = A_{goal}$. Desta forma, pode-se definir a porcentagem do progresso considerando a razão:

$$\text{Progresso} = \frac{\text{Diferença entre o objetivo e a União atual}}{\text{Área total a ser reduzida}} \quad (1)$$

Onde:

- **Diferença entre o objetivo e a União atual** = $n \cdot A_{goal} - A_{union}$
- **Área total a ser reduzida** = $n \cdot A_{goal} - A_{goal} = (n - 1) \cdot A_{goal}$

Portanto a fórmula final do progresso resulta:

$$\text{Progresso (\%)} = 100\% \cdot \frac{n \cdot A_{goal} - A_{union}}{(n - 1) \cdot A_{goal}} \quad (2)$$

A Figura 6 ilustra a necessidade da adaptação da métrica. No Início do jogo, onde as peças estão distantes, a Interseção de quatro conjuntos simultâneos é nula, fazendo com que o IoU Tradicional (linha vermelha tracejada) permaneça em 0%, criando uma “zona morta” de aprendizado onde o agente não recebe recompensa por se aproximar.

Já a fórmula proposta (linha azul contínua) utiliza a redução da União Global (A_{union}) como métrica de progresso. Como observado no gráfico, à medida que o sistema transita do estado disperso para o Caso B (Alinhado), a métrica cresce linearmente, fornecendo um gradiente de

feedback constante necessário para a motivação dos agentes, evitando a estagnação observada na métrica tradicional.

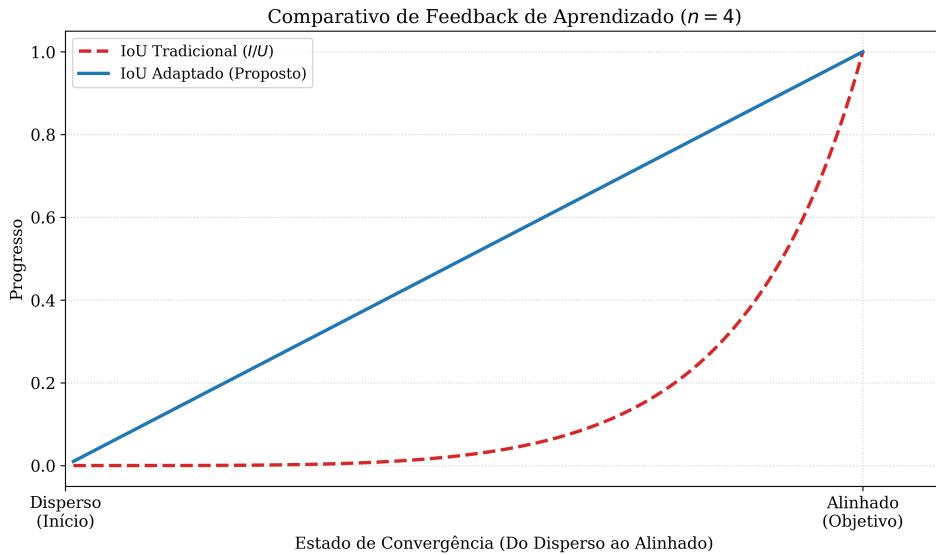


Figura 6: Comparativo entre o IoU tradicional e a métrica adaptada (Equação 2) para $n = 4$ agentes. O gráfico evidencia a “zona morta” de aprendizado na métrica tradicional (vermelho) quando as peças estão dispersas, em contraste com o feedback linear e contínuo fornecido pela abordagem proposta (azul).

O diagrama da Figura 7 esquematiza a arquitetura *multithread* do sistema, mostrando a segregação de responsabilidades entre a renderização nos clientes e o processamento centralizado do estado global no servidor.

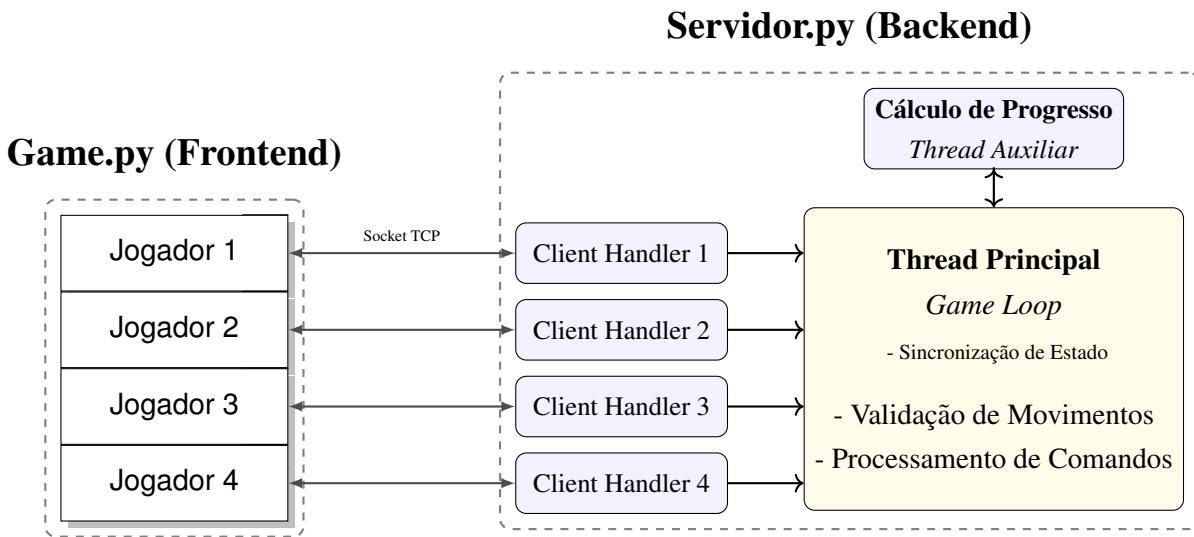


Figura 7: Diagrama ilustrando a arquitetura multithread do sistema. À esquerda, as instâncias dos clientes; à direita, a arquitetura do servidor com threads dedicadas para gestão de conexão e a thread principal para gerenciamento do estado global.

No lado do cliente, a aplicação foi projetada para separar a renderização gráfica da lógica de rede, garantindo fluidez visual. O *loop* principal do jogo roda na *thread* principal e desenha a interface, enquanto uma *thread* secundária escuta continuamente as atualizações enviadas pelo servidor. Para garantir a integridade dos dados compartilhados entre essas duas linhas de execução, o código implementa um mecanismo de bloqueio, que impede que a tela tente renderizar o estado do jogo enquanto ele está sendo modificado pelos dados recém-chegados da rede.

A interação com o jogo possui duas camadas distintas de implementação dependendo do tipo de jogador. Para humanos, o sistema captura eventos diretos de *mouse*, permitindo arrastar objetos ou clicar com o botão direito para rotacioná-los. Já para os agentes artificiais, a implementação é mais complexa, explicada na seção 3.4.

Independentemente de quem controla o objeto, toda movimentação é submetida a um sistema de validação física antes de ser efetivada. O módulo de movimento utiliza uma técnica de interpolação que divide o deslocamento desejado em pequenos passos discretos, verificando em cada milímetro se há colisões com as bordas da tela. Se qualquer colisão for detectada durante esse trajeto, o movimento é interrompido imediatamente, impedindo que objetos saiam da área de jogo.

A fim de mitigar a discrepância temporal entre os agentes, o sistema impõe um *delay* fixo de 3 segundos nas interações dos agentes humanos. Esse valor espelha o tempo médio que a *LLM* leva para processar e retornar um movimento. Essa estratégia de sincronização visa impedir que o humano distinga a IA pelo tempo de resposta. Dessa forma, qualquer atraso percebido é atribuído à latência da rede ou do servidor. Se a IA for percebida como uma máquina lenta e intermitente, a colaboração seria perdida. Essa escolha metodológica serve para evitar que a velocidade de processamento seja um fator discriminador entre humano e máquina.

3.3 Agentes humanos: Participantes de Pesquisa

Como destacado na Tabela 4 em 3.2.2, serão utilizados cinco grupos distintos de participantes humanos, cada um composto por quatro indivíduos, conforme a explicação fornecida em 3.2. Assim sendo, será necessária uma população de 20 participantes de pesquisa ($5 \times 4 = 20$).

3.3.1 Comitê de Ética em Pesquisa

O projeto foi aprovado pelo Comitê de Ética em Pesquisa da Universidade Federal do Rio Grande (CEP/FURG)¹. Dessa forma, o estudo compromete-se a seguir todos os princípios éticos e responsabilidades estabelecidos na Resolução nº 510, de 2016 [1], voltada para pesquisas nas ciências sociais. Esse compromisso visa garantir o respeito e a proteção aos participantes envolvidos.

Os participantes devem ter idade superior a 18 e inferior a 60 anos, em razão de sua capa-

¹ A submissão ocorreu em maio de 2025, e a aprovação foi concedida no dia 18 de julho do mesmo ano.

cidade de decisão; podem ser de ambos os sexos e devem ser alfabetizados para que possam responder às perguntas. O participante necessita ter disponibilidade de acesso a um computador com conexão à internet e ter uma experiência mínima com jogos virtuais de qualquer natureza. Esta experiência é necessária, pois há aspectos intuitivos e comuns de jogabilidade que são importantes para um bom desempenho no jogo.

A participação na pesquisa oferece, como benefício, a contribuição para um projeto acadêmico relevante em uma área de grande crescimento. A análise do comportamento dos jogadores, sejam eles humanos ou IAs, em um contexto de aprendizado cultural, visa um futuro em que a inteligência artificial possa descobrir novas leis da física, matemática e outras áreas, compartilhando suas descobertas de forma eficiente com os seres humanos.

Como riscos ao participante, é possível que a atenção exigida pelo jogo cause algum desconforto ou cansaço. Podem ocorrer também erros técnicos no *software*, por ser um jogo simples desenvolvido exclusivamente para este trabalho, o que poderia resultar em tempos de espera. Adicionalmente, o questionário inclui perguntas sobre aspectos pessoais que podem gerar desconforto.

3.3.2 Procedimentos de Coleta de Dados

A coleta de dados aconteceu somente após a aprovação deste projeto pelo Comitê de Ética em Pesquisa (CEP) da FURG, quando foram convidados os estudantes para que sejam participantes de pesquisa.

Após o participante se voluntariar, foi enviado um *e-mail* individual contendo a descrição do projeto e o teor da pesquisa à qual estará submetido (não mencionando a participação de agentes artificiais), assim como o contato dos pesquisadores responsáveis para eventuais dúvidas a respeito do projeto. Junto, foi enviado o Termo de Consentimento Livre e Esclarecido (TCLE) e uma breve explicação sobre o que ele representa, para que o participante assine e o envie aos pesquisadores.

Uma vez obtido o consentimento dos participantes de pesquisa, foi agendado um horário comum para a realização do experimento. Os participantes de pesquisa são organizados em grupos de quatro indivíduos, sorteados aleatoriamente. As sessões experimentais agendadas envolvem de dois a três desses grupos simultaneamente (totalizando 8 ou 12 participantes por sessão), conforme a aplicação dos diferentes cenários.

No momento combinado para a realização do experimento, foi realizado a coleta de dados, de forma totalmente *online*. Durante cada ciclo do experimento, os seguintes dados foram sistematicamente registrados pelo servidor:

- **Tempo de descoberta do objetivo:** Duração necessária para que o grupo atinja a pontuação predefinida, indicando a compreensão do objetivo do jogo.
- **Evolução da pontuação:** Registro contínuo da pontuação ao longo do tempo, refletindo a progressão e adaptação do grupo em relação ao objetivo do jogo, o que permite inferir

a velocidade do processo de aprendizado.

- **Gravação de tela:** Vídeo completo de cada cenário, para uma análise posterior do comportamento coletivo e das estratégias emergentes.

Ao final de sua participação, os participantes responderam a um questionário, que tem o objetivo coletar informações qualitativas sobre como inferiram o objetivo do jogo e como interpretaram as ações dos demais participantes. O questionário é dividido em duas partes, uma pré e outra pós o esclarecimento de que há possibilidade de outros agentes serem artificiais ou não, conforme o cenário explorado. A seção pré-esclarecimento possui três perguntas e a seção pós-esclarecimento possui sete perguntas; elas foram respondidas logo após a substituição do participante no jogo. Este componente qualitativo complementa as métricas quantitativas, oferecendo *insights* sobre os modelos mentais dos jogadores e seus processos de Teoria da Mente.

As perguntas que constituem este instrumento qualitativo são justificadas nas Tabelas 5 e 6.

Tabela 5: Descrição das perguntas “Pré-Esclarecimento” enviadas ao participante

Pergunta	Justificativa
Descreva o seu processo para entender qual era o objetivo do jogo. Houve alguma pista específica que contribuiu para essa sua compreensão?	Busca verificar se o participante utilizou a atenção às ações dos outros como mecanismo de descoberta, validando a premissa de transmissão de conhecimento dentro do grupo.
Ao longo da sua participação, como você tentou interpretar as intenções ou estratégias dos outros jogadores?	Investiga se o participante atribuiu estados mentais aos outros, aplicando da Teoria da Mente (<i>ToM</i>)
Explique como a sua estratégia evoluiu ao longo de sua experiência no jogo?	Mapear a curva de aprendizado e a evolução cultural do grupo. A resposta ajuda a distinguir se houve uma convergência de estratégias.

As duas sessões de questionários foram desenvolvidas separadamente para analisar como a percepção dos participantes sobre a natureza do agente influencia o seu engajamento e a forma como eles confiam nas informações. Segundo Ghafouri [7], essa distinção atua de forma a medir o impacto do viés da IA; enquanto o desconhecimento pode levar o usuário a tratar a IA como um “oráculo moderno” infalível, o esclarecimento posterior oferece a oportunidade de observar se o comportamento migra de uma recepção passiva para uma curadoria ativa, onde a confiança passa a depender da avaliação crítica e não apenas da fluência da interação.

Todas as perguntas foram formuladas para incitar respostas que permitam uma análise dos modelos mentais dos jogadores, suas estratégias de inferência e a aplicação da Teoria da Mente no contexto da interação não verbal e colaborativa proposta pelo experimento.

A coleta de dados (quantitativos e qualitativos) foi realizada de forma anônima; os dados, os quais estão armazenados em um servidor *offline* com proteção adequada e acesso restrito aos pesquisadores, serão destruídos por meio de formatação segura no prazo de cinco anos, conforme exigência da Resolução [1].

Tabela 6: Descrição das perguntas enviadas “Pós-Esclarecimento” ao participante

Pergunta	Justificativa
Você chegou a suspeitar que algum dos outros participantes não era humano? Explique.	Avalia se os agentes artificiais conseguiram mimetizar comportamentos humanos.
Agora que você sabe que possivelmente alguns jogadores eram IAs, qual é a sua reação inicial a essa informação?	A resposta permite ponderar se a percepção de competência do parceiro é alterada apenas pelo rótulo IA.
Na seção anterior, você descreveu como tentou interpretar as intenções dos outros. Sabendo que possivelmente alguns deles eram IAs, como você reinterpreta as suas observações?	Busca entender se o participante altera o modelo mental que havia construído sobre os parceiros
Você a percebeu como um bom ou mau colaborador?	Uma avaliação subjetiva que será cruzada com os dados de desempenho
Você acha que o agente de IA demonstrou capacidade de aprender com as ações dos outros jogadores ao longo dos ciclos?	Avalia a percepção sobre a capacidade de <i>In-Context Learning</i> e adaptação da <i>LLM</i> .
Da mesma forma, você sentiu que você conseguiu ensinar a IA a jogar melhor através das suas ações?	Verifica se o humano percebeu o canal de comunicação visual como eficaz para instrução.
Esta experiência muda sua percepção sobre a capacidade das IAs de colaborar com humanos em tarefas complexas no futuro?	Conecta o experimento com o contexto da Interação Humano-Robô. Mede o impacto da experiência na confiança do usuário em sistemas colaborativos híbridos.

3.4 Agentes Artificiais: LLMs

Os agentes artificiais do sistema foram desenvolvidos sob o paradigma de entidades autônomas baseadas em *LLMs*. Esta abordagem utiliza o conhecimento linguístico pré-treinado e a capacidade de raciocínio de modelos generativos para tomada de decisão no ambiente colaborativo do jogo, diferente de abordagens tradicionais que treinam sistemas do zero.

A arquitetura foi desenhada para superar as limitações de raciocínio espacial e janelas de contexto de modelos de linguagem tradicionais, utilizando uma abordagem hierárquica e modular. Adota-se o padrão *Chain of Responsibility* (Cadeia de Responsabilidade) e *Decomposition* (Decomposição de Tarefas), segmentando o processo cognitivo em três entidades especializadas, cada uma instanciada com *System Prompts (Personas)* distintos, para separação de interesses entre estratégia, operação e gestão de memória conforme Tabela 7:

A Figura 8 esquematiza a arquitetura interna dos agentes artificiais, evidenciando o fluxo de informações entre os módulos de raciocínio, memória e execução que culmina na síntese de uma ação validada.

Tabela 7: Descrição das entidades de um agente artificial.

Entidade	Responsabilidade
Entidade Pensador (<i>Thinker</i>)	Planejamento estratégico de alto nível, percepção visual e raciocínio social.
Entidade Jogador (<i>Player</i>)	Operacionalização dos movimentos e <i>symbol grounding</i> .
Entidade Resumidor (<i>Summarizer</i>)	Responsável pela gestão da memória de longo prazo e compressão de contexto.

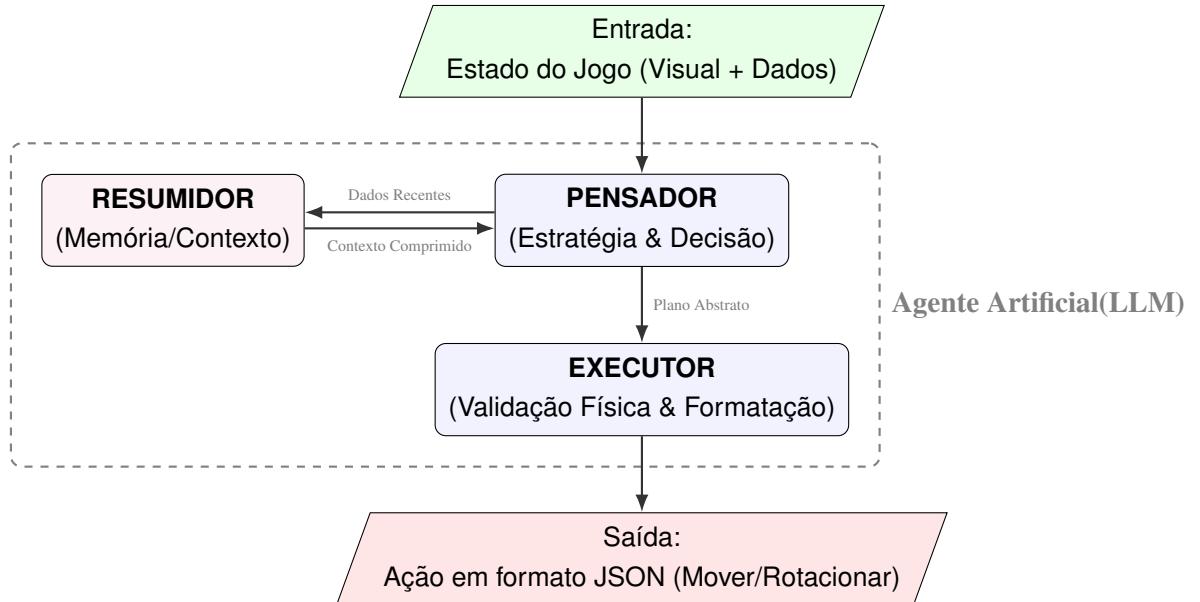


Figura 8: Diagrama do fluxo de dados do agente artificial (LLM).

Como os modelos de linguagem utilizados são pré-treinados e congelados (*frozen weights*), emprega-se a técnica de *In-Context Learning*. A cada ciclo de interação, o histórico de ações passadas e seus resultados (recompensas/*scores*) são injetados no *prompt* do modelo. Isso permite que a *LLM* aprenda a dinâmica do jogo em tempo real, ajustando seu comportamento com base nas correlações observadas na sessão atual.

O sistema mimetiza uma função de recompensa, típica de *Reinforcement Learning* clássico, através de instruções de *Role-Playing*. O *prompt* define explicitamente que a motivação do agente deve ser a maximização do *score* global, instruindo-o a calcular o gradiente de pontuação para validar suas hipóteses.

As requisições dos agentes artificiais foram realizadas através da API OpenRouter, que provê uma interface unificada para acesso a diversos Modelos. A escolha por uma infraestrutura baseada em nuvem, em detrimento da execução local, deve-se às limitações de inferência identificadas nos testes preliminares. Modelos menores passíveis de execução em hardware local (como versões menores da família Llama, Qwen e DeepSeek) demonstraram incapacidade de realizar a inferência necessária para descobrir o objetivo oculto do jogo (falha na indução de regras), resultando em comportamentos sem convergência estratégica.

Para a seleção do modelo dos agentes, foram realizados testes de qualificação com as arquiteturas propostas, incluindo modelos de baixo custo como Claude 3.5 Sonnet, Llama 3 e a família GPT-4. Nos ensaios controlados de observação pura:

- **Claude 3.5 e Llama 3:** Falharam consistentemente na tarefa de extrair a regra de pontuação apenas pela observação visual dos pares, não conseguindo generalizar a estratégia de união de peças.
- **GPT-4.1-nano:** Foi o modelo mais baixo custo a demonstrar a capacidade de In-Context Learning necessária para inferir a mecânica do jogo e adaptar seu comportamento para maximizar o score.

Dessa forma, os experimentos reportados neste trabalho utilizam o modelo **OpenAI/GPT-4.1-Nano**. Optou-se por este modelo para investigar a emergência de comportamento social em modelos mais acessíveis, aceitando-se os riscos de menor capacidade de raciocínio abstrato em comparação a modelos maiores porem de mais elevado custo.

3.4.1 A Entidade Estrategista (The Thinker)

A entidade estrategista é responsável pelo planejamento de alto nível. Este módulo, a entidade, implementa uma arquitetura Multimodal, processando simultaneamente a representação visual do estado do jogo e o contexto textual, para inferir estratégias fundamentadas em cognição social e raciocínio explícito.

Essa arquitetura, processa o contexto textual, *snapshots* e os dados do estado atual do jogo (em formato *JSON* na estrutura exibida no Código 1). Sua implementação permite que o agente identifique padrões nos dados posicionais mesmo sem treinamento prévio específico. Essa redundância visa garantir o *symbol grounding* adequado, permitindo que o modelo correlacione os dados visuais (posições relativas) com a descrição lógica do sistema. Tal abordagem segue o trabalho de Mirchandani et al. [12], que investiga uma habilidade de abstração generalista em *LLMs*, promissora para aplicações em robótica e tomada de decisão sequencial. O trabalho de Di Palo and Johns [3] utiliza uma abordagem semelhante para traduzir percepção em ação.

A utilização da técnica *Chain-of-Thought (CoT)* garante que o planejamento estratégico seja robusto. No código desenvolvido, o *prompt* força o modelo a gerar passos de raciocínio intermediários antes de uma conclusão. Conforme descrito por Wei et al. [14], Zhu et al. [16], essa estratégia capacita os modelos a decompor problemas complexos e solucionar tarefas de raciocínio simbólico.

Para operacionalizar o aprendizado social, o *prompt* da entidade *Thinker* foi estruturado para mapear diretamente os pilares da Teoria do Aprendizado Social de Bandura, estudada por McLeod [11], conforme ilustrado na Figura 1 na seção 2.1:

A implementação computacional destes pilares no *system prompt*, ocorre da seguinte forma:

- **Atenção:** O agente recebe a instrução explícita obrigando o modelo a filtrar o ruído visual e identificar quais ações dos pares resultaram em alterações no estado do jogo.

- **Retenção:** Ocorre através do raciocínio dedutivo (*CoT*): o *prompt* instrui a IA a induzir uma biblioteca de regras a partir da observação antes de agir, validando se a estratégia retida correlaciona-se com o aumento do *score*.
- **Reprodução Motora e Motivação:** A motivação é vinculada ao *score* global: o agente deve calcular o gradiente de pontuação e realizar a atribuição causal, determinando se o sucesso foi próprio ou fruto da observação de terceiros, adaptando suas ações futuras (Reprodução) conforme esse *feedback*.

O *prompt* incorpora conceitos de Teoria da Mente (*ToM*) instruindo a entidade a inferir a intenção dos outros jogadores. O Estrategista aproveita a emergência de habilidades análogas à *ToM* em *LLMs*, conforme análise de Kosinski [9], que demonstraram que *LLMs* podem resolver tarefas de falsa crença com desempenho comparável ao de crianças de seis anos, sugerindo que a *ToM* emerge como subproduto da capacidade linguística, viabilizando a IA socialmente hábil.

3.4.2 A Entidade Executora (The Player)

O sistema implementa uma divisão de trabalho na qual o Estrategista se concentra na cognição de alto nível e o Executor se dedica à execução prática de baixo nível. A implementação desta entidade atua como uma camada de *symbol grounding* para mitigar os riscos da imprevisibilidade dos modelos em tarefas de controle físico.

Conforme discutido em Keon et al. [8], *LLMs* tendem a convergir para médias estatísticas e frases previsíveis, o que resulta em dificuldades para gerar saídas numericamente precisas fora do domínio linguístico.

Nesse cenário, a entidade Executora atua impedindo que imprecisões verbais se manifestem como falhas no jogo. O *prompt* desta entidade define restrições físicas invioláveis. O Estrategista gera o planejamento abstrato, e o Executor deve mapear essas instruções em comandos certos e determinísticos, de forma similar à implementada por Mirchandani et al. [12].

Dessa forma, a separação de funções garante que o planejamento criativo do Estrategista não resulte em violações das regras físicas. Tal arquitetura alinha-se ao proposto por Ghafouri [7], demonstrando como a IA permite que a lógica de uma ideia seja desvinculada do seu contexto original e reaplicada em novos domínios (neste trabalho, do texto para o jogo).

3.4.3 Gestão de Janela de Contexto e Compressão Semântica

Para mitigar a limitação da janela de contexto e a latência de processamento, obstáculos técnicos comuns em *LLMs* citados por Di Palo and Johns [3], implementa-se uma arquitetura de memória gerenciada pela Entidade Resumidora.

A necessidade de compressão semântica é metodológica; o uso desta abordagem viabiliza uma realocação da cognição, fenômeno corroborado por Ghafouri [7], cujo os autores demonstram que o ganho de desempenho em sistemas híbridos advém da capacidade de reduzir a entropia ao fornecer resumos concisos de entradas ruidosas.

No sistema proposto, o *prompt* instrui o Entidade Resumidor a transformar os dados brutos dos turnos passados em uma narrativa de decisão e racionalidade. Isso permite que o sistema descarte coordenadas numéricas obsoletas e preserve apenas o “conhecimento cristalizado”, a regra que levou ao sucesso ou fracasso daquela rodada.

Contudo, são mantidos os últimos cinco turnos de forma bruta, preservando a capacidade da *LLM* de identificar tendências locais. Essa arquitetura assemelha-se à cognição humana observada por Dreyer et al. [5], onde o aprendizado envolve a poda imediata de métodos inválidos, garantindo que o esforço cognitivo seja gasto apenas na trajetória viável.

4 RESULTADOS

Neste capítulo, são apresentados os resultados obtidos a partir dos experimentos realizados. A coleta de dados ocorreu de forma remota, seguindo o desenho experimental longitudinal no qual os participantes foram intercalados entre os ciclos dos grupos, conforme metodologia descrita na Seção 3.2.

A análise foca em duas métricas: o tempo de convergência para a descoberta do objetivo e a estabilidade da pontuação (*score*) ao longo dos ciclos. Adicionalmente, apresenta-se uma análise qualitativa baseada nos relatos dos participantes de pesquisa, visando compreender os mecanismos cognitivos subjacentes às curvas de desempenho observadas.

4.1 Validação do Ambiente de Aprendizado

Como resultado inicial do Cenário 1 (composto exclusivamente por humanos), obtém-se a validação do jogo como um ambiente propício para a emergência de cultura de aprendizado coletivo. A Figura 9 apresenta a evolução do progresso do grupo A durante seus dois primeiros ciclos.

A análise das curvas sob a ótica da teoria da cognição coletiva, cruzada com os dados dos questionários, permite as seguintes observações:

- **Ciclo 1 (Exploração):** Nota-se uma latência inicial; como nenhum integrante possuía conhecimento prévio, o grupo dependeu de heurísticas individuais e exploração estocástica. Nos questionários, os participantes descreveram esta fase como “mexer de maneira desordenada” ou “tentativa e erro” até que a variação na barra de progresso (*feedback visual*) indicasse o caminho correto.
- **Ciclo 2 (Consolidação):** Uma vez adquirido o conhecimento, o grupo demonstra uma convergência. A mudança drástica na inclinação da curva valida a hipótese de que a mecânica do jogo é passível de retenção, superando a necessidade de adaptação da estratégia a cada rodada. Um participante relatou que, após a compreensão inicial, sua estratégia focou em “ser o mais rápido possível” para reproduzir o conhecimento já estabelecido.

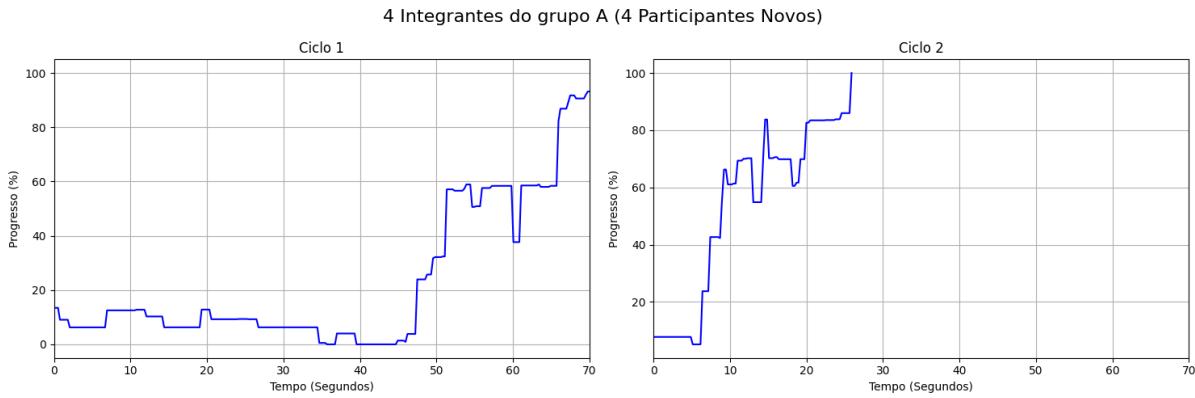


Figura 9: Evolução da pontuação do grupo A, comparativo entre a fase de descoberta (Ciclo 1) e a fase de consolidação (Ciclo 2).

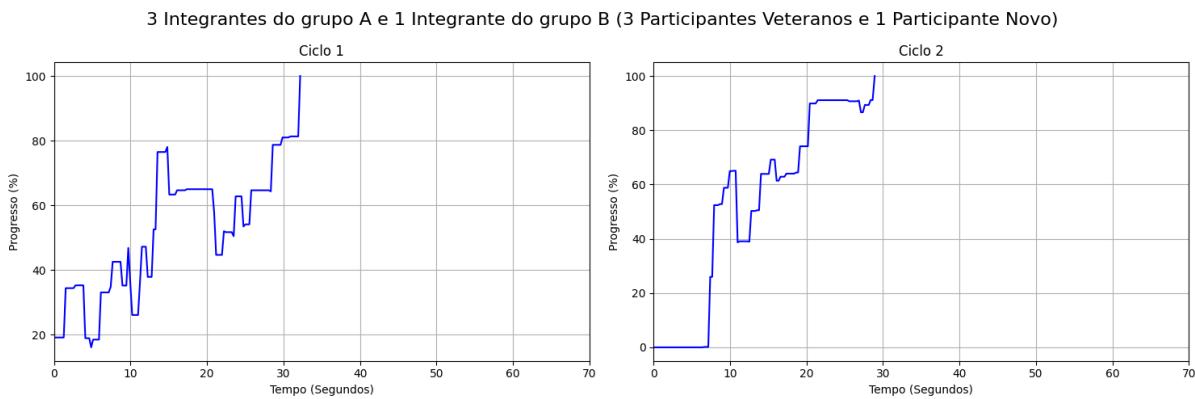


Figura 10: Evolução da pontuação na transição de grupos: performance de 3 Veteranos (Grupo A) interagindo com 1 novo integrante (Grupo B). O aprendizado cultural acelera a estabilização da pontuação.

Na etapa seguinte, analisa-se o momento de transição (Figura 10), caracterizado pela substituição de um participante por um novo integrante (considerado do Grupo B) junto ao grupo de veteranos. Diferente da rodada inicial, pautada pelo aprendizado exploratório, as transições seguintes evidenciaram a transmissão cultural. Nota-se que o subgrupo de veteranos converge rapidamente para a posição-alvo, atuando como modelo comportamental. O gráfico ilustra esse fenômeno por meio de uma estabilização na pontuação, indicando que os veteranos sustentaram a configuração correta enquanto o novo integrante processava as informações e ajustava suas peças para completar a pontuação alvo. A Figura 11 retrata o momento dessa estabilização, extraído da gravação de tela (conforme detalhado em 3.3.2).

O comportamento do novo integrante neste cenário corrobora a Teoria do Aprendizado Social de Bandura [11]. Ao visualizar as peças estáticas dos veteranos (estágio de *Atenção e retenção*), o novo integrante consegue inferir o objetivo sem a necessidade de exploração aleatória, indo diretamente para a fase de *Reprodução Motoria*.

Esta dinâmica foi confirmada pelos relatos subjetivos, onde participantes descreveram suas estratégias como, observar onde as peças se acumulavam para “copiar o comportamento”. A

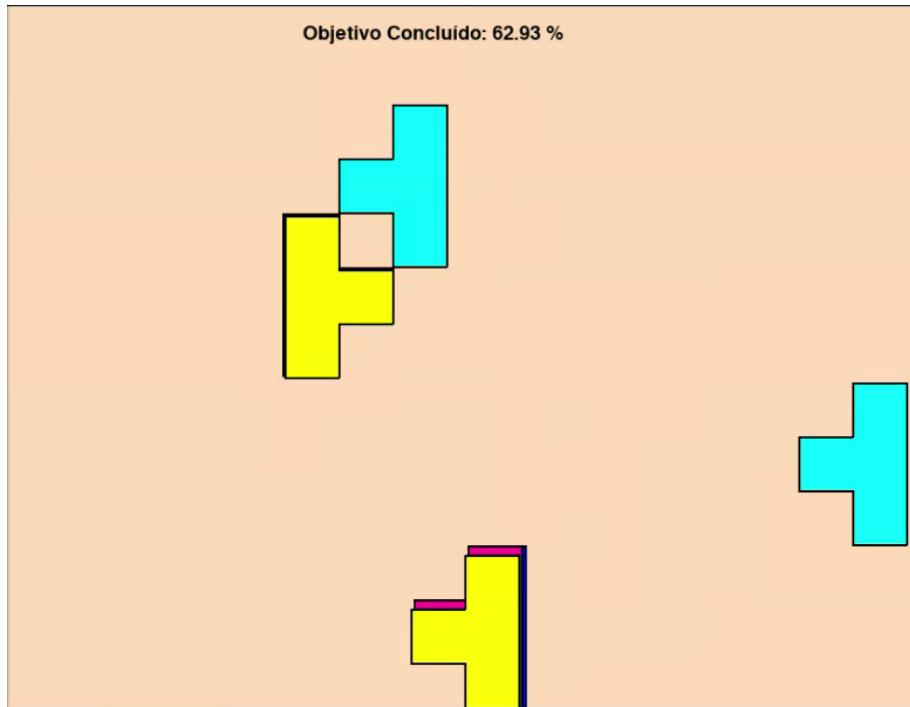


Figura 11: Momento em que os jogadores veteranos (amarelo, azul-escuro e rosa) já haviam posicionado suas peças, enquanto o novo integrante (azul claro) processava a informação para, em seguida, posicionar a sua.

eficácia da transmissão é evidenciada pela intenção pedagógica explícita de alguns participantes veteranos, que após entender o jogo, afirmou que, posicionava-se intencionalmente para “guiar os outros jogadores”.

No Ciclo 2 (etapa de consolidação), a hesitação desaparece, o que indica uma inovação composta, conforme também ocorrido na pesquisa de Duéñez-Guzmán et al. [6]: o conhecimento não foi perdido com a troca de membros, mas sim acumulado, permitindo que o grupo mantivesse a performance eficiente típica de sistemas com cultura. A presença dos veteranos atuou, portanto, como um *scaffolding* (andaime) social, validado pela métrica de performance e pela percepção dos usuários.

Assim sendo, dados os resultados apresentados e os relatos subjetivos nos questionários, o objetivo de desenvolver um ambiente experimental controlado, que isole variáveis de aprendizado por observação, foi concluído ao validar o jogo como um cenário experimental eficaz. Ainda que limitado a um escopo, o ambiente atende aos requisitos para as investigações dos fenômenos de aprendizado propostos neste trabalho.

4.2 Dinâmica de Aprendizado com Agentes Artificiais

A introdução dos agentes artificiais no ambiente de jogo (Cenário 2) alterou a dinâmica observada no cenário de controle (exclusivamente humano). A análise cruzada entre os dados de performance, os registros internos de processamento (*logs*) e os relatos dos participantes sugere

que a presença de LLMs impacta negativamente a capacidade do grupo de atingir o “ótimo global” da pontuação, resultando em um fenômeno de estabilização em sub-ótimos locais.

Ao comparar as curvas de desempenho, observa-se uma correlação negativa direta entre o número de agentes artificiais no grupo e o sucesso da tarefa. Grupos compostos majoritariamente por humanos atingiram consistentemente a marca de 100% de progresso (convergência completa), enquanto os grupos com maior densidade de agentes artificiais (como a configuração de 3 LLMs para 1 Humano) demonstraram dificuldade em superar a faixa de 40% a 50% da pontuação.

A Figura 12 ilustra a natureza desse comportamento. Diferente da curva ascendente observada nos grupos humanos (Figura 13), a curva dos grupos dominados por IA apresenta platôs de estagnação.

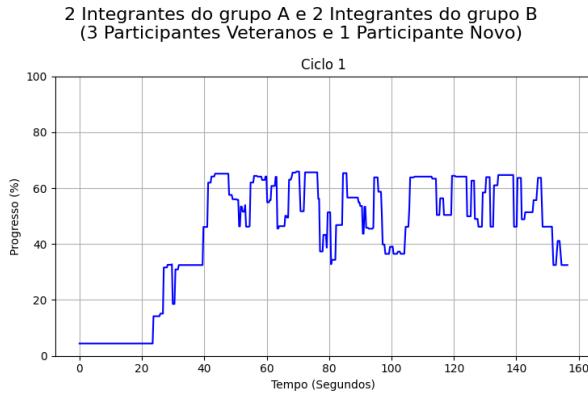


Figura 12: Ciclo com 2 humanos (grupo A) e dois agentes artificiais (grupo B). O progresso permaneceu estagnado em um sub-ótimo local.

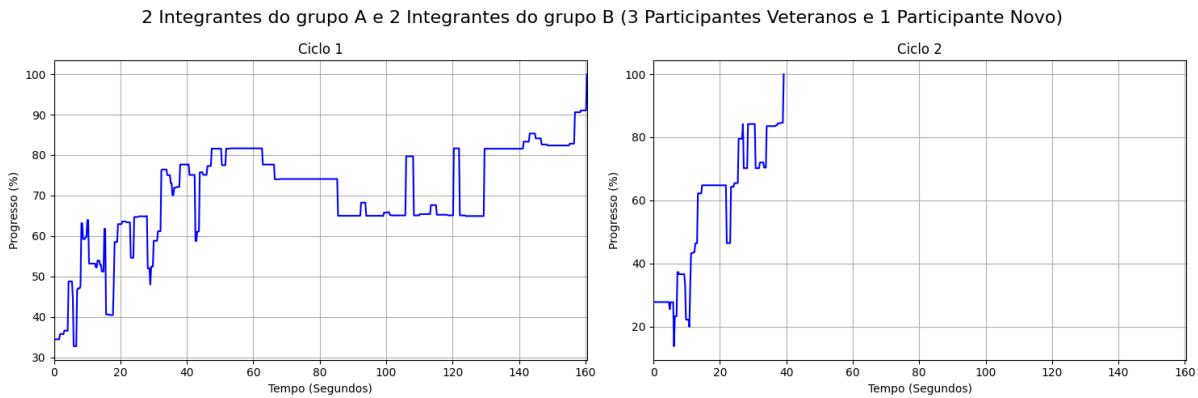


Figura 13: Ciclo com 2 participantes humanos do grupo A e dois participantes humanos do grupo B. A estagnação não aconteceu e o objetivo foi realizado.

A análise sugere que, embora o agente (operando via *In-Context Learning*) seja capaz de induzir a regra geral de aproximação, o sistema converge para uma média estatística de comportamento que carece da criatividade necessária para o refinamento final. Essa degradação do

refinamento torna-se evidente na análise comparativa das diferentes composições de grupo do um mesmo cenário, apresentada na Figura 14:

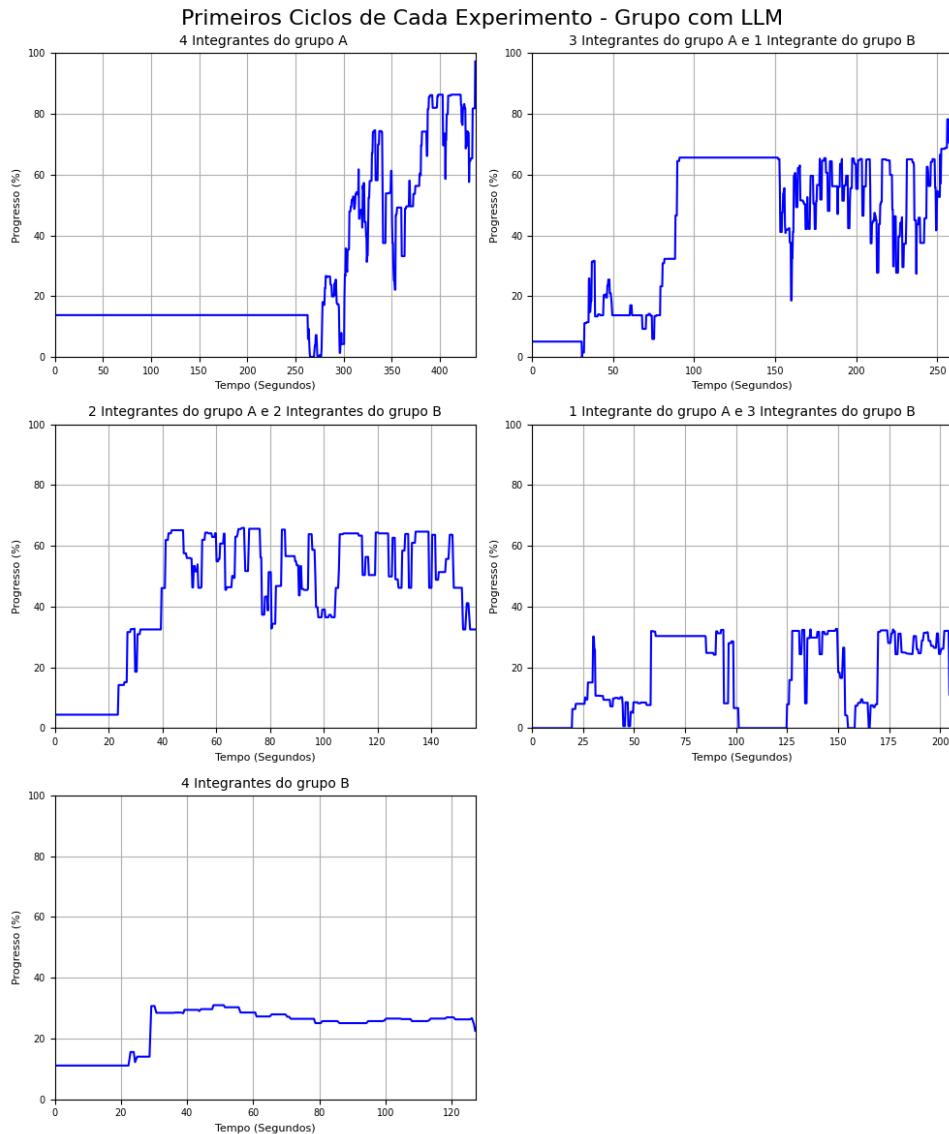


Figura 14: Gráficos resultantes da transição do grupo A (humanos) para o grupo B (artificial) do Cenário 2

- **4 Humanos:** Apresentam curvas ascendentes rápidas, atingindo o objetivo em aproximadamente 200 segundos após o início da variação.
- **3 Humanos e 1 IA:** O grupo atinge 100%, mas com momentos de “estagnação”. Observa-se que a estratégia humana atua como um *scaffolding* (andaime) ainda robusto o suficiente para compensar a passividade da IA e carregá-la ao objetivo.
- **2 Humanos e 2 IAs:** O progresso oscila em um *loop* entre 40% e 60%; os humanos não conseguem, sozinhos, forçar a coordenação contra dois agentes estocásticos que buscam maximizar o score localmente sem visão estratégica global.

- **1 Humano e 3 IAs:** O progresso luta para superar 30%; o humano tenta sinalizar estratégias, mas a diluição causada por três agentes operando na média anula a tentativa de coordenação, levando o humano, por vezes, a zerar a pontuação na tentativa frustrada de reiniciar a estratégia.
- **4 IAs:** O gráfico apresenta-se praticamente plano, preso em um mínimo local (30%), evidenciando que a inovação composta não emerge sem o catalisador humano.

A percepção dos participantes, observada nos questionários, sobre a dinâmica revelou uma dicotomia influenciada pela densidade de agentes artificiais. No cenário de controle (Humano-Humano), conforme evidenciado na Tabela 8, houve sucesso no entendimento: estratégias, como “manter a peça parada” ou “seguir o aglomerado”, foram corretamente interpretadas pelos parceiros resultando em uma convergência de ações que contribuíram para sucesso do objetivo.

Tabela 8: Comparativo entre intenção do humano e percepção de outro humano (Cenário de Controle).

Intenção Humana (Questionário)	Interpretação Humana (Questionário)
“...me preparar para ‘guiar’ os próximos jogadores novos.”	“O movimento dos outros jogadores serviu para copiar o comportamento e chegar ao objetivo.” (<i>Aprendizado Social por Imitação</i>)
“Notei que algumas vezes era melhor manter a peça parada, para que os outros jogadores viessem na minha.”	“Depois de alguém começar a sobrepor a outro jogador, consegui interpretar o aumento do objetivo e assim, decifrar.” (<i>Reconhecimento de Sinalização</i>)
“...conforme todos os jogadores moviam as peças [...] a porcentagem aumentava, logo concluí que esse era o objetivo.”	“A partir da segunda rodada, basicamente todo o grupo entendeu o objetivo e onde tinham mais peças colocavam as suas.” (<i>Convergência de Modelo Mental</i>)

Em contrapartida, essa fluidez desaparece nos grupos mistos. As divergências entre a intenção humana e a interpretação da LLM podem ser visualizadas na Tabela 9, que confronta diretamente os relatos subjetivos com os registros de raciocínio da IA para os mesmos eventos. Embora a janela de contexto tenha sido suficiente para armazenar o histórico de ações, a natureza estatística da LLM tende a tratar comportamentos fora da distribuição padrão (como os movimentos bruscos de sinalização que foram eficazes entre humanos) como ruído, e não como informação relevante. A Tabela 9 evidencia, portanto, que o agente “viu” o movimento, mas sua atenção estatística o filtrou como irrelevante.

Além disso, a análise dos *logs* revela um comportamento típico de sistemas de otimização presos em máximos locais. Para a resolução do quebra-cabeça proposto, frequentemente é necessário desfazer uma união parcial (reduzindo momentaneamente o score) para permitir um rearranjo global. Contudo, a natureza probabilística da LLM, que busca maximizar a predição de recompensa a cada *token*, evitava ao máximo perda de pontuação. Agentes frequentemente

Tabela 9: Comparativo entre intenção humana e percepção da IA (Cenário 2).

Intenção Humana (Questionário)	Processamento da IA (Logs do Sistema)
“Eu balancei a peça para mostrar que queria que ele viesse para o canto.” (Sinalização Pedagógica)	“O jogador [...] está se movendo de forma aleatória. A pontuação não mudou. Manter minha posição.” (Classificação como Ruído Estatístico)
“Parei de jogar para esperar ele encaixar a peça dele.” (Coordenação de Turnos)	“Ninguém está se movendo. Vou fazer uma pequena rotação para ver se o score muda.” (Incapacidade de reconhecer)
“O outro jogador estava pensando muito antes de jogar, parecia cauteloso.” (Modelagem cognitiva (ToM) errada)	“Risco de diminuir score ao mover é alto. Ação: Manter posição (x,y).” (Estagnação em Máximo Local)

registravam justificativas como “Vou fazer um pequeno movimento para ver se a pontuação muda”, resultando em um padrão de micro-ajustes de coordenadas em vez de exploração espacial efetiva.

5 CONCLUSÃO

Esta pesquisa investigou a capacidade de agentes artificiais, baseados em LLMs, de participarem efetivamente de processos de aprendizado social e transmissão cultural em ambientes colaborativos. Por meio de um experimento controlado, validou-se o jogo desenvolvido como um cenário eficaz para a emergência de coordenação estratégica e aprendizado coletivo. Nos grupos exclusivamente humanos, observou-se a “inovação composta” descrita por Duéñez-Guzmán et al. [6]: o conhecimento não foi apenas preservado, mas refinado através dos grupos, validando a premissa de que a interação social atua como um *scaffolding* para o aprendizado cognitivo.

No entanto, a introdução de agentes artificiais revelou limitações das LLMs para dinâmicas sociais criativas. Os resultados demonstraram uma correlação negativa entre o número de agentes artificiais no grupo e o sucesso da tarefa. Grupos humanos convergiram para o ótimo global, enquanto grupos mistos, com predominância de IAs, ou completamente formados por elas, estagnaram em sub-ótimos locais.

Esse fenômeno corrobora a “Lei da Mediocridade” proposta por Keon et al. [8], indicando que o gargalo reside na natureza probabilística do modelo. A análise sugere que, embora o agente (operando via *In-Context Learning*) seja capaz de induzir a regra de aproximação, o sistema converge para uma média estatística de comportamento que carece da criatividade necessária para o refinamento. A LLM, treinada para minimizar erros de predição de *tokens*, demonstrou priorizar estados de segurança em detrimento de movimentos arriscados, como desconstruir uma formação parcial para buscar o sucesso total (100%), ancorando o grupo em um desempenho mediano.

Dessa forma, retomando a pergunta central que norteou esta investigação, se um agente artificial é capaz de participar efetivamente de um processo de descoberta e aprendizado coletivo, os resultados obtidos impedem uma resposta definitiva no atual estágio tecnológico. O experimento evidenciou uma viabilidade condicionada: o agente artificial demonstrou, através do In-Context Learning, a competência técnica para induzir regras e participar da dinâmica (o “saber jogar”), mas falhou em sustentar o comportamento de risco necessário para a inovação social (o “descobrir jogando”). Portanto, não se pode afirmar que a incapacidade é inerente à condição de agente artificial, mas sim que ela é uma limitação da arquitetura estatística do modelo atual

(GPT-4.1-nano), que prioriza a convergência para a média em detrimento da exploração criativa.

Além das métricas de desempenho, a percepção subjetiva dos participantes revelou nuances importantes na interação: nos grupos onde o humano era minoria, a falha de coordenação foi interpretada como incompetência (“não se mexiam e não entendiam os sinais”). Essa frustração advém de uma quebra de expectativa da qual o humano projetou uma intencionalidade colaborativa que não foi reciproca aos agentes. Por outro lado, em grupos mistos mais equilibrados, observou-se o fenômeno de “Falsos Positivos”. Participantes relataram que a IA “ajudava no raciocínio”, antropomorfizando falhas e atrasos como se fossem estratégias deliberadas de um parceiro humano cauteloso.

Ao investigar a origem dessa falha sob a ótica da Teoria do Aprendizado Social de Bandura, identifica-se que a ruptura não ocorreu no estágio de Retenção (memória/contexto), mas sim no estágio da Atenção. A janela de contexto foi suficiente para armazenar o histórico de ações; contudo, a natureza estatística da LLM tendeu a tratar comportamentos fora da distribuição padrão (como movimentos bruscos de sinalização humana) como ruído, e não como informação relevante. A Tabela 9 evidencia que o agente “viu” o movimento, mas sua atenção estatística o filtrou como irrelevante.

Em suma, a estagnação dos grupos mistos reflete uma barreira imposta pela natureza estatística dos modelos de baixo custo, impedindo que o ciclo de aprendizado social avançasse para a consolidação de uma estratégia cultural complexa.

Diante das limitações identificadas e do escopo deste trabalho, sugerem-se as seguintes direções para pesquisas futuras:

- 1. Avaliação de Escala e Capacidades Emergentes:** A presente pesquisa priorizou a viabilidade de execução, utilizando modelos de baixo custo e menor latência. No entanto, observa-se uma tensão entre a escala do modelo utilizado e a complexidade da tarefa de coordenação social. Embora o modelo tenha demonstrado capacidade de *In-Context Learning*, a literatura revisada sugere que a *ToM* e o planejamento estratégico dependem de uma massa crítica de parâmetros. Recomenda-se, assim, a replicação deste experimento com modelos maiores, para verificar se o aumento de escala é suficiente para superar as barreiras encontradas.
- 2. Avaliação de Novos Modelos:** A evolução das Inteligências Artificiais Generativas sugere a substituição futura dos modelos atuais por modelos multimodais, capazes de processar os dados de forma mais avançada. Além disso, a validação com novas gerações de modelos focados em raciocínio lógico visa superar as limitações encontradas neste estudo.
- 3. Integração com Sistemas Robóticos Físicos:** A arquitetura desenvolvida neste trabalho favorece a migração do ambiente virtual para o mundo físico. Propõe-se a integração dos agentes com manipuladores robóticos. O objetivo seria substituir a validação de movimento virtual por planejadores de trajetória reais (como via ROS), investigando os

desafios e verificando se a inferência de intenções baseada em LLMs mantém sua eficácia diante das incertezas sensoriais e falhas inerentes à robótica física.

4. **Expansão dos Cenários de Dinâmica de Grupo:** A ampliação do escopo dos experimentos para incluir cenários compostos exclusivamente por agentes artificiais (LLM-LLM-LLM). A investigação focaria em verificar se grupos puramente sintéticos convergem para protocolos de comunicação não-verbal emergentes ou se sucumbem à estagnação criativa e homogeneização estatística. Adicionalmente, cenários mistos de “minoria humana” (LLM-humano-LLM) poderiam elucidar o impacto da influência social exercido pelos agentes artificiais sobre a tomada de decisão humana.
5. **Aumento da Complexidade da Tarefa Colaborativa:** O jogo atual baseia-se primariamente em coordenação espacial. Trabalhos futuros podem explorar tarefas que exijam coordenação temporal e interdependência de recursos (ex: tarefas de montagem sequencial onde um agente depende da ação prévia de outro). Isso exigiria o desenvolvimento de uma teoria da mente mais robusta, capaz de prever não apenas “onde” o parceiro vai jogar, mas “quando” e “porquê”.

Conclui-se, portanto, que para que agentes artificiais participem do processo de evolução cultural, é necessário ir além do aumento de escala ou da engenharia de *prompt*. É preciso superar a barreira da mediocridade estatística. Enquanto os modelos forem penalizados por desvios da média, eles serão excelentes executores de tarefas conhecidas, mas incapazes de participar do processo de descoberta coletiva que exige, fundamentalmente, a coragem cognitiva de errar para inovar.

REFERÊNCIAS

- [1] Brasil. Ministério da Saúde. Conselho Nacional de Saúde (2016). Resolução nº 510, de 07 de abril de 2016. *Diário Oficial da União*, 1(98):44–46.
- [2] Dell'Acqua, F., Ayoubi, C., Lifshitz, H., Sadun, R., Mollick, E., Mollick, L., Han, Y., Goldman, J., Nair, H., Taub, S., et al. (2025). The cybernetic teammate: a field experiment on generative ai reshaping teamwork and expertise. Technical report, National Bureau of Economic Research.
- [3] Di Palo, N. and Johns, E. (2024). Keypoint action tokens enable in-context imitation learning in robotics. *arXiv preprint arXiv:2403.19578*.
- [4] dos Anjos Pereira, T. M. and Galuch, M. T. B. (2012). O garoto selvagem: a importância das relações sociais e da educação no processo de desenvolvimento humano. *PERSPECTIVA*, 30(2):553–571.
- [5] Dreyer, T., Haluts, A., Korman, A., Gov, N., Fonio, E., and Feinerman, O. (2025). Comparing cooperative geometric puzzle solving in ants versus humans. *Proceedings of the National Academy of Sciences*, 122(1):e2414274121.
- [6] Duéñez-Guzmán, E. A., Sadedin, S., Wang, J. X., McKee, K. R., and Leibo, J. Z. (2023). A social path to human-like artificial intelligence. *Nature machine intelligence*, 5(11):1181–1188.
- [7] Ghafouri, B. (2025). A theory of information, variation, and artificial intelligence.
- [8] Keon, M., Karim, A., Lohana, B., Karim, A., Nguyen, T., Hamilton, T., and Abbas, A. (2025). Galton's law of mediocrity: Why large language models regress to the mean and fail at creativity in advertising.
- [9] Kosinski, M. (2024). Evaluating large language models in theory of mind tasks. *Proceedings of the National Academy of Sciences*, 121(45):e2405460121.
- [10] Kovač, G., Portelas, R., Dominey, P. F., and Oudeyer, P.-Y. (2023). The socialai school: Insights from developmental psychology towards artificial socio-cultural agents.

- [11] McLeod, S. (2025). Albert bandura's social learning theory in psychology.
- [12] Mirchandani, S., Xia, F., Florence, P., Ichter, B., Driess, D., Arenas, M. G., Rao, K., Sadigh, D., and Zeng, A. (2023). Large language models as general pattern machines.
- [13] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2023). Attention is all you need.
- [14] Wei, J., Tay, Y., Bommasani, R., Raffel, C., Zoph, B., Borgeaud, S., Yogatama, D., Bosma, M., Zhou, D., Metzler, D., Chi, E. H., Hashimoto, T., Vinyals, O., Liang, P., Dean, J., and Fedus, W. (2022). Emergent abilities of large language models.
- [15] Weidmann, B., Xu, Y., and Deming, D. J. (2025). Measuring human leadership skills with ai agents. Technical report, National Bureau of Economic Research.
- [16] Zhu, Z., Xue, Y., Chen, X., Zhou, D., Tang, J., Schuurmans, D., and Dai, H. (2023). Large language models can learn rules. *arXiv preprint arXiv:2310.07064*.

A REPOSITÓRIO COM CÓDIGO FONTE

Visando a reproduzibilidade científica, a transparência e a continuidade da pesquisa, o software desenvolvido foi publicado em um repositório hospedado na plataforma *GitHub*. O repositório contém o jogo colaborativo multijogador, desenvolvido em *Python* utilizando a interface gráfica *Pygame*. Abaixo encontra-se o endereço de acesso e a descrição da estrutura de seu conteúdo.

- **Endereço:** <https://github.com/Gabriel-br2/TCC-Gabriel2025>
- **Conteúdo:**
 - `mainGame.py`: *Script* principal do cliente (*Frontend*) que executa o jogo
 - `mainServer.py`: *Script* do servidor central (*Backend*) gerencia os ciclos.
 - `screen.py`: Módulo de renderização gráfica responsável por desenhar a interface.
 - `config/`: Diretório de parâmetros gerais do sistema.
 - `objects/`: Diretório com a implementação das peças dos jogadores.
 - `results/`: Diretório com os dados obtidos nas experimentações.
 - `human.py`: Gerencia os eventos de entrada (mouse) para o controle do jogo.
 - `LLM.py`: Implementa a lógica dos agentes artificiais via API de LLM.
 - `colision.py`: Responsável pelos movimentos e detecção de colisões.
 - `network.py`: Abstração da camada de rede para comunicação via *Sockets TCP*.
 - `objective.py`: Responsável pelo cálculo de progresso (IoU Adaptado)