Deep Researcher with Test-Time Diffusion：拡散プロセスによるAI研究エージェントの変革

はじめに：論文「Test-Time Diffusion Deep Researcher (TTD-DR)」の概要と位置付け

近年の大規模言語モデル（LLM）の急速な発展は、複雑なタスクを自律的に実行するAIエージェント、特に「Deep Researchエージェント」の登場を促しました。これらのエージェントは、検索ツールや分析ツールを駆使して、人間が通常行うような情報収集、推論、そしてレポート作成といった一連のワークフローを自動化する能力を持っています [1]。しかし、多くの既存エージェントは、複雑で広範なトピックに関する長文の研究レポートを生成する際、その性能が頭打ちになるという課題に直面していました。この限界は、主に、LLMの能力を最大限に引き出すための「テスト時スケーリング」手法が、本質的に単発的または線形的な思考プロセスに依存していることに起因します [1]。

このような背景の中、Google Cloud AI Researchの研究者らが提案したのが、画期的なフレームワーク「Test-Time Diffusion Deep Researcher (TTD-DR)」です [4]。この論文の核心は、研究レポートの生成を、まるで画像生成モデルの「拡散プロセス」のように、反復的に洗練していくプロセスとして概念化した点にあります [1]。これは、単に情報を集めて要約するのではなく、人間が論文やレポートを執筆する際の「調査、推論、修正」という、下書きを中心とした反復的なサイクルをAIエージェントのアルゴリズムに組み込むという、根本的に異なるアプローチです。

本報告書は、論文「Deep Researcher with Test-Time Diffusion」の技術的な詳細、その独自性、そして先行研究との比較を通じて、本手法がなぜ既存の限界を超え、AIエージェントの新たなパラダイムを提示しているのかを深く分析します。

第1部：背景としてのDeep Researchエージェントと課題

Deep Researchエージェントの定義と機能

Deep Researchエージェントとは、LLMを中核に据え、複数の外部ツール（ウェブ検索、API、データ分析ツールなど）と連携して、単一の質問回答を超えた、より深く複雑な情報探索とコンテンツ生成を行う自律的なシステムです [1]。これらのエージェントは、新しいアイデアの生成、効果的な情報収集、そして研究レポートや論文の下書き作成といった、人間が行う一連の研究プロセスを自動化する能力を示しています [1]。

既存のオープンソースプロジェクトとして、OllamaやLMStudioといったローカルLLMを利用した「Local Deep Researcher」や「Ollama Deep Researcher」が挙げられます [2]。これらのエージェントは、ユーザーのクエリからウェブ検索クエリを生成し、検索結果を要約します。さらに、その要約から「知識のギャップ」を自己分析し、そのギャップを埋めるための新しい検索クエリを生成するという、反復的なサイクルを繰り返します。最終的に、収集された情報をもとに、引用元を明記した最終的な要約を生成します [2]。

従来の主要な手法と限界

LLMの推論能力を向上させるための一般的な手法は「テスト時スケーリング（test-time scaling）」と呼ばれます。これは、モデルのパラメータを再学習させることなく、プロンプトや推論プロセスを工夫することで性能を向上させるアプローチです。従来のDeep Researchエージェントは、以下のようなテスト時スケーリング手法を主要なメカニズムとして採用してきました [1]。

- **Chain-of-Thought (CoT):** 複雑な問題に対する最終的な答えだけでなく、その答えに至るまでの思考過程を段階的に生成させる手法です [1]。
- **Best-of-n Sampling:** 複数の回答候補を生成し、その中から最も質の高いものを選ぶ手法です [1]。
- **Monte Carlo Tree Search (MCTS):** 思考過程をツリー構造で探索し、最適なパスを見つける手法です [1]。
- **Debate Mechanisms:** 複数のエージェントに異なる視点から議論をさせ、矛盾点を解消していく手法です [1]。
- **Self-refinement Loops:** 生成した回答を自己評価し、そのフィードバックに基づいて修正を繰り返す手法です [1]。

これらの手法は目覚ましい進歩をもたらしましたが、論文は、多くの人気のあるDeep Researchエージェントが、「人間が執筆を行う際の認知行動に基づいた意図的な設計」を欠いており、「下書き、調査、フィードバック」という原則的なプロセスが欠如していると指摘しています [1]。このことが、特に複雑なテーマに関する長大なレポートの生成において、性能の停滞を引き起こす一因となっています。従来の多くの手法は、単一のセッション内で思考を深めることに重点を置いており、複数の情報源を比

較検討し、矛盾を解消し、下書きを何度も書き直すという、時間軸に沿った反復作業を本質的に組み込めていません。TTD-DRは、この根本的な課題を解決しようと試みるものです。

第2部：TTD-DRの核心概念と技術的基盤

2.1「拡散プロセス」という革新的な比喩

TTD-DRの最も革新的な側面は、研究レポートの生成を、画像生成における「拡散モデル」のサンプリングプロセスになぞらえた点にあります[1]。画像生成の拡散モデルは、ランダムなノイズから、段階的にノイズを除去（デノイズ）することで、最終的に高解像度で高品質な画像を生成します。

TTD-DRでは、この概念をテキスト生成に応用します。ユーザーのクエリに対して、LLMがまず生成する、不完全で不正確な（情報的な「ノイズ」を含む）予備的なレポートを**「ノイズの多いドラフト」と見なします[4]。そして、ウェブ検索などを通じて得られた外部情報（Retrieval-Augmented Generation, RAG）が、このドラフトを段階的に洗練し、より高品質で高解像度な出力へと改善していくプロセスを

「デノイズ」**と捉えるのです[1]。

この比喩は、単なる表現上の工夫を超えた深い意味を持っています。画像生成のノイズがピクセル単位のランダム性であるのに対し、TTD-DRにおける「ノイズ」は、情報の不確実性、不正確さ、および欠落を指します。このフレームワークは、情報の「エントロピー」を低減するという目的を、非常に的確に表現しています。これにより、従来の線形的な思考プロセス（CoTなど）から、より複雑で動的な情報洗練プロセスへと、AIエージェントのパラダイムが転換していることがわかります。

2.2 TTD-DRの「ドラフト中心」設計とワークフロー

TTD-DRは、人間が研究を行うプロセスを模倣するように設計された、3つの主要なステージからなるワークフローを採用しています[1]。この設計の鍵は、最初から「予備的なドラフト」を作成し、それを継続的に進化させていく「ドラフト中心」のアプローチにあります[1]。

TTD-DRの三段階ワークフロー:

1. ステージ1：研究計画の生成 **(Research Plan Generation)**
    - ユーザーからのクエリを受け取ると、まず専用のLLMエージェントが、最終レポートに必要

な主要な領域をリストアップした構造化された研究計画を生成します[1]。
    - この計画は、その後の情報収集プロセス全体を導くための、初期的な足場（scaffold）として機能します[1]。
2. ステージ**2**：反復的な調査と合成 **(Iterative Search and Synthesis)**
    - このステージはループ構造になっており、以下の2つのサブエージェントから構成されます[1]。
        - ステージ**2a:** 検索質問の生成 **(Search Question Generation):** 研究計画、ユーザーのクエリ、そして過去の検索履歴や進行中のドラフトの文脈を参照しながら、次のステップで調査すべき特定の検索クエリを動的に策定します[1]。
        - ステージ**2b:** 回答の検索と改訂 **(Answer Searching):** 策定されたクエリを使って、ウェブ検索などの情報源から関連文書を検索し、RAGベースのジェネレーターを用いて回答を要約します[1]。そして、この新しい情報をドラフトに統合して更新します[1]。
    - このループは、研究計画が十分にカバーされるか、または最大反復回数に達するまで繰り返されます[1]。
3. ステージ**3**：最終レポートの生成 **(Final Report Generation)**
    - 反復プロセスが完了した後、専用のLLMエージェントが、ステージ1の計画と、ステージ2で収集・合成されたすべての情報（質問-回答ペア）を統合し、包括的で一貫性のある最終レポートを生成します[1]。

2.3 デノイズと自己進化アルゴリズムの役割

このドラフト中心のワークフローを支えるのが、デノイズと自己進化という2つの重要なメカニズムです[4]。

- デノイズプロセス**:** 前述の通り、外部情報（検索結果）を取り込むことで、不完全なドラフトを段階的に洗練していくプロセスです[1]。このプロセスは、情報の一貫性と正確性を向上させ、レポートの全体的な品質を高める役割を果たします。
- 自己進化アルゴリズム**:** TTD-DRのプロセスをさらに強化するための追加的なメカニズムです[4]。このアルゴリズムは、エージェントの各コンポーネントに適用され、複数の回答候補を生成・評価し、フィードバックに基づいて改訂を繰り返すことで、高品質なコンテキストを生成することを保証します[4]。

これらのメカニズムは、従来のRAGが持つ受動的な役割（検索結果を提示する）を大きく超えています。TTD-DRは、単に外部情報を取得して補完するだけでなく、その情報を使って**「下書き自体を修正・進化させる」**能力を持っています。さらに、自己進化アルゴリズムは、生成された複数の回答候補を自己評価し、最適なものを選択・改善するという、人間的な「推敲」プロセスを模倣しています。これにより、TTD-DRは、より能動的で洗練された情報統合を可能にしているのです。

第3部：先行手法との比較とTTD-DRの優位性

3.1 既存手法との設計思想の比較

TTD-DRの独自性は、従来のテスト時スケーリング手法との設計思想の根本的な違いにあります。以下の表は、主要なDeep Researchエージェント手法の特性を比較したものです。

表1：主要な**Deep Research**エージェント手法の比較

手法名	主要なメカニズム	反復プロセス	文脈管理	強み	弱み
TTD-DR	ドラフトの段階的デノイズ	長期的なサイクル	グローバルな文脈を維持	高い一貫性、情報損失の低減、幻覚の抑制	複雑な実装、計算コスト
Chain-of-Thought (CoT)	思考の連鎖を生成	単一の反復	限定的（プロンプト内）	複雑な推論の透明化	幻覚やエラー伝播のリスク
Debate Mechanisms	複数のエージェントによる議論	単一の反復	限定的（議論のコンテキスト内）	多角的な視点からの検証	協調性の問題、結論の収束が困難な場合あり
Open Deep Research	プランナーとセクション別調査	セクションごとのループ	セクション内のみ	特定のセクションの集中的な調査	グローバルな文脈の欠如、情報の重複や不整合

TTD-DRは、CoTやDebateといった手法が主に思考プロセスの透明化や多角的な視点に焦点を当てるのに対し、**「長期的な執筆と修正のサイクル」**に焦点を当てています[1]。これは、人間が行う研究プロセスそのものを模倣した、より包括的なアプローチです。

3.2「Open Deep Research」との詳細比較

TTD-DRの優位性をより明確にするために、「Open Deep Research」と比較することは非常に重要です [1]。Open Deep Researchは、まず最終レポートの構造をアウトラインとして作成し、その後、各セクションについて独立して反復的な調査を行います [1]。すべてのセクションが完成した後に、それらを組み合わせて最終レポートを生成します。

これに対し、TTD-DRは**「セクションごとの分離した検索を避ける」**という設計思想を持っています [1]。TTD-DRは、常にレポート全体のドラフトを最新のコンテキストとして保持し、それに情報を統合していきます [1]。

この設計上の違いがもたらす影響は、単なるワークフローの差異にとどまりません。論文執筆やレポート作成において、セクションごとの独立した調査は、情報の重複や全体的な論理の一貫性の欠如を引き起こすリスクがあります。TTD-DRの「ドラフト中心」設計は、常にレポート全体の文脈を参照しながら情報を統合するため、この問題を根本的に解決します。この設計思想が、TTD-DRが特に**「長文で包括的な研究レポート」**タスクで優れた性能を発揮する主要因であると考えられます [1]。

第4部：実験結果、性能評価、および技術的意義の考察

4.1 評価ベンチマークと性能主張

論文の実験結果は、TTD-DRが、集中的な検索と多段階の推論を必要とする広範なベンチマークで「state-of-the-art」（最先端）の結果を達成していることを示しています [1]。評価に用いられた主要なベンチマークには、複雑な多段階推論タスクを含むGAIA、長文の研究レポート生成を評価するLongForm Research、DeepConsult、そしてHumanity's Last Exam (HLE)などが含まれます [8]。

TTD-DRは、これらのベンチマークにおいて、既存の主要な研究エージェント（OpenAIやPerplexityを含む）を**「有意に上回った」**と報告されています [1]。特に、特定のタスクでは、比較対象エージェントに対する勝率（win rate）が74.5%にも達したことが示されています [8]。

4.2 アブレーションスタディによる要因分析

論文は、TTD-DRの性能向上に貢献している主要な要素を特定するために、アブレーションスタディ（一部の要素を意図的に除去して性能を評価する実験）を実施しました [4]。この分析により、デノイズと自己進化プロセスが、TTD-DRの優れた性能の中核にあることが確認されました [8]。

具体的な定量データとして、わずか9ステップのデノイズと検索のプロセスで、最終レポート情報の51.2%を組み込み、20ステップの自己進化プロセスよりも4.2%高い勝率を達成したという結果が示されています [4]。この結果は、デノイズプロセスが情報の統合において非常に効率的であることを示しています。

表2：**TTD-DR**の実験結果概要（代表例）

ベンチマーク	TTD-DRの成績	比較対象エージェントの成績	TTD-DRの勝率（Win Rate）
LongForm Research	SOTA	既存エージェントを大幅に上回る	-
GAIA	SOTA	既存エージェントを大幅に上回る	-
特定タスク	SOTA	既存エージェントを大幅に上回る	74.5%
デノイズプロセスの効率性	9ステップで最終情報の51.2%を統合	-	20ステップの自己進化より4.2%高い

4.3 技術的意義の考察：なぜ**TTD-DR**は優れているのか

TTD-DRの優れた性能は、その革新的な設計思想に由来します。従来のモデルが情報を逐次的に追加する傾向にあるのに対し、TTD-DRは常に「全体像」であるドラフトを更新しながら情報を統合します。これにより、情報がよりスムーズに文脈に組み込まれ、冗長性の低減と一貫性の向上が実現されます。

さらに、codelionによるオープンソース実装のレビューでは、TTD-DRが**「現在のイベントに関する幻覚（hallucination）を効果的に排除する」**という重要な側面が報告されています [6]。これは、外部の正確な情報源による継続的な「デノイズ」が、LLMが内部知識のみに依存することで発生する不正

確な内容を、効果的に訂正する役割を果たしていることを示しています。この機能は、特に事実に基づいた研究レポート作成において、極めて重要な利点です。

第5部：今後の展望と応用可能性

5.1 コミュニティの反応と実装の現状

TTD-DRの発表は、AIコミュニティで大きな反響を呼びました [1]。Hugging Faceのコミュニティでは、

codelionという開発者が、OptiLLMというライブラリにTTD-DRのアルゴリズムを実装したことを報告しています [6]。

この実装は、以下の実用的な知見を報告しています [6]。

- **幅広いモデルとの互換性:** OpenAI互換のあらゆるモデル（GPT-4、Claude、Llama、Mistralなど）で動作する。
- **小規模モデルの性能向上:** TTD-DRのワークフローと組み合わせることで、**7B**のような比較的小さなモデルでも優れた研究レポートを生成できる。これは、大規模な計算資源を持たない研究者や開発者にとって、非常に大きな意味を持ちます。
- **幻覚の抑制:** イテレーションを重ねることで、幻覚を効果的に排除し、最終的なレポートの品質が顕著に向上する。

これらの報告は、TTD-DRが単なる学術的な成果に留まらず、オープンソースコミュニティで実用的なツールとして迅速に採用されていることを示しています [1]。

5.2 応用範囲の拡大と将来的な示唆

論文では、情報源として主にウェブ検索が想定されていますが、日本の解説記事は、このフレームワークの仕組みが特定の情報源に限定されない点を指摘しています [10]。例えば、検索対象をインターネットから企業の社内ドキュメントやデータベースに切り替えることで、特定の業界や企業に特化した、高度なリサーチアシスタントを構築する可能性が考えられます [10]。これは、金融、バイオメディカル、技術といった多様な産業領域での応用を可能にするものです [1]。

TTD-DRの成功は、今後のAIエージェント開発における重要な方向性を示唆しています。それは、AI

の性能向上が、単に巨大なモデルを構築することに依存するのではなく、人間的な認知プロセスを模倣するような、洗練されたワークフローの設計にますます依存していくということです。このアプローチは、より効率的で、一貫性があり、信頼性の高いAIシステムを構築するための新たな標準を確立する可能性があります。

結論：TTD-DRの要点と最終的な評価

「Test-Time Diffusion Deep Researcher (TTD-DR)」は、AIによる研究レポート生成という課題に対し、これまでの線形的な思考プロセスとは一線を画す、画期的な解決策を提示しました。その最も重要な貢献は、研究レポートの生成を「拡散プロセス」として再定義し、人間が行う「下書き、調査、修正」のサイクルを技術的に再現した点にあります [1]。

この「ドラフト中心」かつ「グローバルな文脈を維持する」設計は、従来のDeep Researchエージェントが抱えていた、情報の一貫性や正確性の欠如といった問題を根本的に解決します [1]。論文の実験結果は、この設計思想の優位性を明確に裏付けており、様々なベンチマークで既存の最先端エージェントを上回る性能を実証しました [1]。

さらに、オープンソースコミュニティでの実装は、本手法が学術研究だけでなく、実用的な開発においても非常に有効であることを証明しています。特に、小規模なモデルでも優れた性能を発揮する可能性は、AI研究と開発の民主化を加速させるかもしれません [6]。

結論として、TTD-DRは単なる技術的な改良ではなく、今後のAIエージェント開発における新たな標準を確立する可能性を秘めた、画期的な研究成果であると評価できます。これは、AIがより人間的な思考プロセスを模倣し、複雑なタスクをより信頼性高く、効率的に実行する未来への重要な一歩を示しているのです。

引用文献

1. Deep Researcher with Test-Time Diffusion - arXiv, 8月 29, 2025にアクセス、https://arxiv.org/html/2507.16075v1
2. langchain-ai/local-deep-researcher: Fully local web research and report writing assistant - GitHub, 8月 29, 2025にアクセス、https://github.com/langchain-ai/local-deep-researcher
3. bhza/ollama-deep-researcher: Fully local web research and report writing assistant - GitHub, 8月 29, 2025にアクセス、https://github.com/bhza/ollama-deep-researcher
4. (PDF) Deep Researcher with Test-Time Diffusion - ResearchGate, 8月 29, 2025にアクセス、https://www.researchgate.net/publication/393924018_Deep_Researcher_with_Test-Time_Diffusion
5. [2507.16075] Deep Researcher with Test-Time Diffusion - arXiv, 8月 29, 2025にアク

セス、https://arxiv.org/abs/2507.16075
6. Paper page - Deep Researcher with Test-Time Diffusion - Hugging Face, 8月 29, 2025にアクセス、https://huggingface.co/papers/2507.16075
7. Deep Researcher with Test-Time Diffusion - Online Marketing Consulting, 8月 29, 2025にアクセス、https://www.kopp-online-marketing.com/patents-papers/deep-researcher-with-test-time-diffusion
8. Test-Time Diffusion Deep Researcher: Ushering in a Human-Like AI Research Paradigm, 8月 29, 2025にアクセス、https://joshuaberkowitz.us/blog/papers-7/test-time-diffusion-deep-researcher-ushering-in-a-human-like-ai-research-paradigm-652
9. Daily Papers - Hugging Face, 8月 29, 2025にアクセス、https://huggingface.co/papers?q=iterative%20reasoning%20cycles
10. Googleが解き明かした「最強の調べものAI」の裏側〜最新論文『Test-Time Diffusion』を徹底解説, 8月 29, 2025にアクセス、https://note.com/life_to_ai/n/nbb9d6f7fee55