

生成AIで世界はこう変わる

北陸先端科学技術大学院大学 客員教授

GenesisAI 代表取締役社長/CEO

今井翔太

今井 翔太 (Shota Imai)

1994年、石川県金沢市生まれ

元ゲーマー（一部ゲームで世界7位など）

→ゲーマーとして世界最前線で活動する中で人間の頭脳に限界を感じ、AIの世界へ

2024年3月：東京大学工学系研究科技術経営戦略学専攻
松尾研究室にてAIの研究で博士（工学）を取得

2024年7月：株式会社GenesisAI創業 代表取締役社長/CEO

2025年～：北陸先端科学技術大学院大学（JAIST）客員教授

■ 興味のある研究分野

- 強化学習、生成AI
- AIによる科学的発見

■ 著書、訳書、関わった書籍等

- 著書：生成AIで世界はこう変わる、G検定公式テキスト 第3版、AI白書2022
- 翻訳：R. Sutton, A. Barto著『Reinforcement Learning』
- 監修・協力：令和6年度情報通信白書、Newton2025年3月号



【教育】

- 東京大学 AI経営寄付講座 AI Business Insights 2025, 2025年
 - 東京大学松尾研究室 Deep Learning応用講座 深層強化学習, 2020年～
 - 東京大学松尾研究室 高専サマースクールAIセミナー, 2020年～2022年
 - その他、名古屋大、電通大、JAISTなどで講義
- これまでに1万人以上のAI教育に関わる



『生成AIで世界はこう変わる』
ベストセラー10万部、
東大で一番売れた本



芥川賞受賞作家九段理江さんとの対談（2024年2月）



日本テレビ「カズレーザーと学ぶ。」（2024年5月）



国会ラピダス法案 参考人招致
（2025年4月）



元日本代表監督岡田武史さんとの
対談「Atlassian TEAM TOUR
Tokyo」にて（2024年6月）



トヨタコンポン研究所講演「生成AI時代に私等はどう生きるか」
トヨタ元会長 内山田氏らと

4. 配付資料

- ▶ [【議事次第】](#) (PDF:98KB)
- ▶ [【資料1-1】 株式会社GenesisAI 今井翔太氏 発表資料](#) (PDF:3.3MB)
- ▶ [【資料1-2】 アドビ株式会社 発表資料](#) (PDF:7.9MB)
- ▶ [【資料1-3】 Google合同会社 発表資料](#) (PDF:2.9MB)
- ▶ [【資料1-4】 日本マイクロソフト株式会社 発表資料](#) (PDF:7.5MB)

文部科学省 有識者会議（経営者/研究者として）

AI研究者たちの考え

数年後（～5年）、生成AI（あるいは一般的な意味でのAI） はどうか

8

※：5年を超える科学の発展、特にAIという極めて進捗が早い分野で発展を予測することは困難で、それを予想として明言するのは研究者として本来あまり誠実ではない（例えば、2020年に「3年後のAIの発展の予測をしろ」と言われて、現在の生成AIブームを当てられた人はほぼ皆無だっただろう）。以下は可能な限り現在の研究から推測した今井個人の予想である

■ ホワイトカラー的な能力に関しては、ほぼ全ての能力で人間を超える。LLMの知識が全分野において人間の博士号取得者レベルになる

→投入する学習資源（データ、モデルサイズ、計算量）を増やすことで性能上昇が約束されるスケールリング則^{注1}の存在と、ツールを組み合わせるAIエージェントの手法による

■ 肉体労働に関しても、相当部分の作業ができるようになる

→2024年時点で、研究者たちがロボティクス分野での大規模学習の準備^{注1}や、ニューラルネットワークのアーキテクチャの改善に取り組み始めている。5年後には一定の成果

■ 自動研究の発展

→いくつかの機関やプロジェクトで自動研究の取り組みが始まる。特にデジタル空間のみで解決する分野（コンピュータ科学や数学など）に関しては、相当部分が自動化可能に

注1：ほぼLLMの性能向上の文脈で参照されるスケールリング則だが、厳密にはテキスト生成だけでなく、その他の動画像などの生成、マルチモーダル性能にもほぼ同様の法則があることが明らかになっている。Henighanらによる“Scaling Laws for Autoregressive Generative Modeling”など

2024年8月8日に開催された文部科学省有識者会議における今井の提出資料
5年後のAIの発展に関して3つの予想

出典：文部科学省 初等中等教育段階における生成AIの利活用に関する検討会議(第2回)、今井翔太発表資料
https://www.mext.go.jp/b_menu/shingi/chousa/shotou/193/siryo/mext_01848.html

■ 3つの予想のうち、2つは5年どころか1ヶ月でほぼ達成されてしまった

■ 予想1：ホワイトカラー的な能力、AIが博士号取得者並みになる

→約 1 ヶ月後の9月12日に、博士号取得者を超えるレベルのAI OpenAI o1が登場

■ 予想3：自動研究、デジタル空間で解決する分野は大半が自動化可能に

→ 6 日後（！）の8月14日に研究の大部分を自動化したThe AI Scientistが登場

予想2の肉体労働については少し難しいが、それでも2024年中にかなりの進展があった（後述）

歴史的に、AI研究者は（特に深層学習登場以降）予想を大きく外してきた

■ トマソ・ポッジオ（MIT教授）

- 2014年「画像の内容を理解するAIの実現には少なくとも20年は必要だ」
→2015年に部分的に達成。現在はGPT-4などでほぼ完璧に

■ マックス・テグマーク（MIT教授、有名なAI書籍『LIFE3.0』著者）

- 2020年「私は自分の子供に、今のところ機械には不向きで近い将来も自動化されそうにない職業を進めている」
- 「比較的安全な選択肢としては、教師、看護師、医師、歯科医、科学者、起業家、エンジニア、弁護士、ソーシャルワーカー、聖職者、芸術家、マッサージ師など」
→この中の職業の半分以上は、2022年の生成AI以降「最もAIによって影響を受けてしまう職業」になった

■ 日本のAIの第一人者にして今井の師匠M先生

- AIの言語理解は2025年くらい
→2022年（ChatGPT）でほぼ達成

AI研究者以外も・・・

■ レイ・カーツワイル（未来学者、「シンギュラリティ」という単語を有名にした人）

- 2029年までにAIはチューリングテストに合格するだろう
→2024年には事実上突破

- AI研究者が言っていることの予想到達時期はほぼ100%「実際にはもっと実現は早かった」という意味ではずしている

- 数少ない例外は「実機における人間的な実運動タスクの実現」

→ **到達時期を抜きにした内容に関してはほぼ100%当たる！**

- AI研究者が何か予想をした時「たぶんこの人の言っていることはもっと早くに実現されてしまうんだろーな」と思うのがちょうどいい

- (例) AI研究者「このAIは10年後くらいに達成されると思います」→実際には3年後と考える

- 私が今日ここで喋ったことは、私が言っているよりも明らかに早く、しかも大規模に実現すると想定していただきたい

ジェフリー・ヒントン

- トロント大学教授、元Google Brain
 - 現在のAIの基幹技術「深層学習（ディープラーニング）」の理論を確立した人物であり、その功績から深層学習の父、AI研究の神と呼ばれる
 - 深層学習に関する研究で2024年にノーベル物理学賞を受賞
-
- 「私は人間の脳に似せてニューラルネットワークを作ったつもりだったが、生成AIを見て考えを改めた。人間の脳より優れているかもしれない」
 - 「人間を超越するAIは、もうすぐそこまでやってきているかもしれません」
 - 「AIはいずれ人間を操作し、支配しようとするかもしれない」
 - 「人間が持っている能力で、AIにできないものはない。AIは私たちが持つどんな特性でも再現できるはずだ」
 - 「今我々は歴史の分岐点にいる」

ジェフリー・ヒント

（トロント大学教授、チューリング
賞受賞者、ノーベル賞受賞者）

「5~20年後」

サム・アルトマン

（OpenAI CEO）

「ASIは、2030年か2031年く
らい」

ヤン・ルカン

（Meta AI所長、チューリング賞
受賞者）

「数年~10年。今のLLMの仕
組みだけでは難しいかも」

デミス・ハサビス

（Google DeepMind CEO, ノーベル
化学賞受賞者）

「今後数年からおそらく10年
以内」

ヤン・ルカン

（モントリオール大学教授、チュー
リング賞受賞者）

「ほんの数年から10年」

ダリオ・アモディ

（Anthropic CEO）

「早ければ2026年」

ダリオ・アモディ

Anthropic CEO

元Google, OpenAI 研究者
スタンフォード大学 物理学修士
プリンストン大学 物理学博士
スタンフォード大学 医学部研究員

あと5~10年で人間の寿命は150年くらいになる可能性が高い。また、精神疾患も治療できるようになるだろう。感染症、癌の撲滅も可能と考える。今まで人間の科学者が50年~100年かけて達成してきた進捗が5~10年に圧縮されるということだ。

これは、AIによって科学的発見の速度が上がることによって起きる。人間社会の課題は、とある画期的な研究により急速に解決されることが多い（例えば、コロナワクチンなど）が、AIを用いた研究はその研究速度を飛躍的に早めてくれる。

Dario Amodei、Machines of Loving Graceより

学術的なバックグラウンドを持たない、知名度だけ、金だけの経営者が言っているのとは訳が違う。AIのみならず、物理学、生物学、医学において専門的な研究をおこなってきた者の誠実な予想

レオポルド・アッシュエンブレナー

元OpenAI スーパーアライメントチーム

GPT-2は幼児レベルのおもちゃだったが、GPT-4はいまやコードも書けるし、競技数学もできるし大学受験問題も解ける。このレベルの飛躍が現在のGPT-4からさらに続く可能性は高い。そしてそれは、AI自身がそれを作ったAI研究者くらいに賢くなるに至るだろう。

SFみたいな滅茶苦茶な話をする必要はない。GPT-2からGPT-4までの間に起こったことは単に学習の計算量を増やしただけで、単にそれをもう一度やればいいのだ。それだけでAIがAI研究をするくらいに賢くなる。こうなればAIがAIを生み出す知能爆発が起こり、AIの性能は加速的に上がる。こうやって誕生したAIを科学、経済のあらゆる分野で活躍させれば、20世紀全体で起きたような劇的な変化が数年で起きる。

SITUATIONAL AWARENESS: The Decade Aheadより

OpenAIの内部事情を知りながらも、現在は雇用関係がない研究者であり、OpenAIを過剰に持ち上げているわけではない

生成AIの最新研究

■言語

- 30近い言語を使用可能、医師国家試験に合格可能、司法試験に合格可能、あらゆる分野に関して大学生レベルの知識（GPT-4など、～2023年）
- 1000万文字以上を瞬時に読み取り要約や質問回答、GPT-4レベルのモデルが個人のPC上で動作（Gemini、GPT-4oなど、～2024年前半）
- **さまざまな学問分野で人間の博士号取得者並の推論能力（OpenAI o1、o3、2024年9月）**
- **最高レベルの数学者が作った「人間のほとんどはどれだけ時間をかけても解けない」とする問題の多くを解けるように（OpenAI o3、2024年12月）** **New**

■動画像・音声

- 現実世界と見分けがつかない動画像を生成可能（Sora、Veo）
- 数秒程度の声のサンプルから当人と同じ声で自由なセリフの発声

■その他（生成AI + α の手法）

- 言語指示からソフトウェアの設計、自動研究を行う、タンパク質の立体構造生成、ロボット制御など


■現在のAIの性能向上に関しては以下の性質が研究上明らかになっている

■スケーリング則

- データ，計算量，パラメータ数（AIの大きさ）を増やせば，AIの性能が，べき乗則に従って無限に向上する
- **生成AIの性能は，3つの要素に「どれだけお金を払えるか」の問題になる可能性．難しい理論やアルゴリズムの工夫は重要ではないかもしれない**


■推論時スケーリング則

- AIが「考える時間」を増やせば性能が無限に上昇していく



難しいことを考えず、巨大なAIを大規模に学習したり、AIに考えさせる時間を長くするだけで、知能に関する大半の問題は解決でき、人間ができないことをAIが勝手にできるようになる


出典：Kaplan et al., “Scaling Laws for Neural Language Models”
今井翔太, 「生成AIで世界はこう変わる」



~2017年

2019年

2023年
~2025年



たった8年

主に「AIを大規模に学習する」という単純なことで、短時間にここまで進化した
(当然、実際には研究者の工夫もいくつかはある)




現時点で、人類何万年で解決できなかった問題をいくつか解決できている

(例) 囲碁の新しい戦略を見つける、タンパク質のフォールディング問題を買いける

将来的に人類が解決法を見つけられなかったほとんどの問題をAIによって解決できると考えるのは、今までの発展を考えると飛躍した発想ではない

科学的発見ができるAIのスケーリング



【できること】


- ・タンパク質の立体構造予測による創薬支援（ノーベル賞）
- ・半導体の設計の最適化、短縮（人間数ヶ月→AIで数時間）
- ・生物DNAの設計
- ・新しい無機結晶素材の発見
- ・気象予測

【できるようになること】

- ・指定難病の治療薬の発見
- ・超伝導素材の発見
- ・核融合の実現

出典：METR, “Measuring AI Ability to Complete Long Tasks”

長時間の作業を完遂できるAIエージェントのスケーリング



【できること】

- ・7ヶ月で、AIが達成できる作業の時間（人間換算）は2倍になる
- ・数時間程度が必要なソフトウェアの自動開発
- ・国際会議に採択される自動研究（研究立案→論文執筆まで）
- ・金融市場の調査報告


【できるようになること】

- ・2028年から2031年くらいには、人間が1ヶ月の労働時間で達成するような複雑な作業をAIで自動化できる可能性

AIエージェント（後述）が完遂できる作業時間のスケーリング則

- ・社内の事務・経營業務の大半の自動化
- ・ノーベル賞級の研究の立案から実験、論文執筆
- ・長時間かつ正確なサイバー諜報、人間の監視能力を上回る最規模情報戦・フェイク情報操作

- 今までの生成AIは、知識は豊富だったが、思考力を必要とする問題は解けなかった
 - この問題に関しては単に学習をスケールアップするだけでは解けない可能性が出てきた
- 2024年後半から登場したOpenAIのoシリーズ（o1~o3）、DeepSeekなどは、「AIが考える時間」を大きくするように強化学習（今井の専門）することで、「よく考えるAI」に
- 大学入試の共通テストを91%、東大の入試問題を8割~9割解けるようになった。フィールズ賞（数学のノーベル賞）の受賞者が現代数学の叡智を駆使して作った難問を解けるようになった。AIを開発しているOpenAIの主任研究者よりもプログラミングがうまくなった



Question: If $a > 1$, then the sum of the real solutions of $\sqrt{a - \sqrt{a + x}} = x$ is equal to

Response: <think>

To solve the equation $\sqrt{a - \sqrt{a + x}} = x$, let's start by squaring both ...

$$\left(\sqrt{a - \sqrt{a + x}}\right)^2 = x^2 \implies a - \sqrt{a + x} = x^2.$$

Rearrange to isolate the inner square root term:

$$(a - x^2)^2 = a + x \implies a^2 - 2ax^2 + (x^2)^2 = a + x \implies x^4 - 2ax^2 - x + (a^2 - a) = 0$$

...

Wait, wait. Wait. That's an aha moment I can flag here.

Let's reevaluate this step-by-step to identify if the correct sum can be ...

We started with the equation:

$$\sqrt{a - \sqrt{a + x}} = x$$

First, let's square both sides:

$$a - \sqrt{a + x} = x^2 \implies \sqrt{a + x} = a - x^2$$

Next, I could square both sides again, treating the equation: ...

...

出典：
OpenAI, “
OpenAI o3 and o3-mini—12 Days of OpenAI:
Day 12”
DeepSeek, “DeepSeek-R1: Incentivizing
Reasoning Capability in LLMs via
Reinforcement Learning
”


フィールズ賞受賞者たちが作った数学問題の結果。人間は数ヶ月かけても一問も解けない

よく考えるように強化学習すると、突然AIが「待て、待て、わかったぞ！」と言って考える力が突然改善する瞬間がある（Ahaモーメント）

- 2024年のOpenAI o1、o3、2025年最初のDeepSeek-R1、Deep Research、その他の「AI エージェント」は大規模な強化学習をおこなっていることが明らかになっている
- 生成AIブームにおいて、当初の強化学習は生成AIの出力を調整する（倫理的な出力にする。アライメント）のに使われていたが、生成AIのコア性能を上げる方向にシフト
- 教師あり、自己教師あり学習だけでは獲得できなかった「推論」、「複雑なタスクにおける長期的な計画的行動」が大規模な強化学習によって発現し、人間のほとんどの作業を自動化する可能性

Google DeepMindの主任研究者David Silver（AlphaGoの開発者）の言葉
「AIの学習にはインターネットで人間が生み出してきたデータが必要ですが、良質なデータは既に使い果たされ、限界に達しています。新しいスケーリング則があるのかが重要です。では、そのスケーラブルなアプローチは何でしょう？・・・もちろん、強化学習です！」

講演“Towards Superhuman Intelligence”、8月 RLC 2024にて



- 前述のDeepSeek-V3がDeepSeek-R1に進化し、最高性能とされていたOpenAIの生成AI「o1」に並んだ
- o1は数百億円かけて作られていると見られるが、同性能のAIが数十分の1のコストで作れてしまうという期待（大体の研究者）と懸念（今まで大規模投資してきたGAFAや投資家）が広がる
- DeepSeekショックはなぜ起こったのか、DeepSeekは何が凄いのか？
 1. 性能が世界最高レベル
 2. その性能に極めて低コストで到達している
 3. そのAIの開発手法を公開している
 4. DeepSeek-R1を、商用利用、カスタマイズ可能な形で公開している



急落したNvidia株価
時価総額90兆円（トヨタ二つ分）の損失はアメリカ史上最大の下落幅



【DeepSeek】米テックを抜く？AI専門家「超すごい」開発コストの安さとド根性に驚愕...スタ...


101,328 回視聴 20 時間前 #アベヒル ...その他

DeepSeekショック発生日にテレビ番組でDeepSeekを説明する今井

DeepSeekショックが意味すること / 生成AI以後の日本の立ち位置と勝ち筋

- 生成AIの研究開発競争、活用において、日本は2022年の生成AIブーム開始～2024年までスタートラインにすら立てていなかった
- 大前提となる生成AI開発や利用に必要な膨大な投資ができない。開発に必要なGPUの個数で100倍近くの差があった戦闘機相手に竹槍という状況
- 日本は1900年代後半「ジャパン・アズ・ナンバーワン」と言われて世界を席巻していたように（トヨタなどの車、家電、ゲーム産業等）、本質的に技術はある。工夫もできる。だが、AI開発に関しては技術・工夫を発揮する前提条件がクリアできていなかった

→ **学習時スケーリングの鈍化、DeepSeekによるオープン化戦略で前提条件はクリア。日本が技術と工夫、文化資本を活かして生成AI開発の最前線に立てる部隊が整った**



AIエージェントの最新研究

- 生成AIはどこまで行っても、人間の指示に対して何かをポンっと生成して終わり。それ以上の複雑な作業はできなかった
- 2024年以降、生成AIを核にして、外部のツールを使わせながら複雑な作業を行う **AIエージェント** と呼ばれる手法が盛んに研究されている

AIエージェントによってできること

コンピュータ
の自動操作

自動研究

ソフトウェア
の自動開発

- 「〇〇の株式を調査して」などと指示を出すと、AIが自動的にコンピュータの事務アプリやブラウザを利用して、作業を勝手に進めてくれる



Comprehensive Tesla Stock Analysis and Investment Insights

4. EV Market Share: Tesla holds approximately 18.4% of the global EV market, leading all competitors, though Volkswagen (14.6%) is making significant inroads.

5. Manufacturing Capacity: Tesla's annual production capacity (2.1M vehicles) is lower than established automakers but higher than other pure-play EV manufacturers. Tesla continues to expand manufacturing capacity globally.

6. Technological Advantages: Tesla maintains leadership in key EV technologies, particularly in battery management systems, software integration, and autonomous driving development.

I'm now moving on to calculate Tesla's intrinsic value using discounted cash flow analysis and other valuation methods to determine if the current stock price represents fair value.



 このタスク内のすべてのファイルを
表示

☐ 続行: Calculate intrinsic value of Tesla stock ^

Moving to calculate intrinsic value of Tesla

 コマンドを実行中 `cd /home/ubuntu/tesla_analysis/data && touch tesla_intrinsic_value.py`

Calculating intrinsic value of Tesla

 ファイルを作成しています tesla_analysis/data/tesla_intrinsic_value.py

☒ プランを更新中

 Manusがタスクを再生しています...

結果にスキップ

Manusのコンピュータ

Manus はエディタを使用しています

 ファイルを作成しています tesla_analysis/data/tesla_intrinsic_value.py

tesla_intrinsic_value.py

```
import sys
sys.path.append('/opt/.manus/.sandbox-runtime')
from data_api import ApiClient
import json
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np
from datetime import datetime
import os

# Initialize API client
client = ApiClient()

# Create directory for charts if it doesn't exist
if not os.path.exists('../charts'):
    os.makedirs('../charts')

print("Calculating Tesla's intrinsic value...")

# Load Tesla financial data
try:
    # Load financial metrics from our previous analysis
    with open('tesla_financial_metrics_detailed.json', 'r') as f:
        financial_metrics = json.load(f)

    # Load competitor data for comparison
    with open('tesla_competitor_comparison.json', 'r') as f:
        competitor_data = json.load(f)

    print("Loaded financial data successfully")
except Exception as e:
    print(f"Error loading financial data: {e}")
    financial_metrics = {}
    competitor_data = {}

# Current Tesla data
```

 Manus が稼働中です: Calculate intrinsic value of Tesla stock 7 / 10 ^

0:00 プランを更新中

元Googleの研究者らからなる日本のベンチャーSakana AIによる、研究の大半のプロセス（研究内容の提案、プログラミング、実験も含む）を論文執筆まで自動的に行う技術

AI-Scientist Generated Preprint

DUALSCALE DIFFUSION: ADAPTIVE FEATURE BALANCING FOR LOW-DIMENSIONAL GENERATIVE MODELS

Anonymous authors
Paper under double-blind review

ABSTRACT

This paper introduces an adaptive dual-scale denoising approach for low-dimensional diffusion models, addressing the challenge of balancing global structure and local detail in generated samples. While diffusion models have shown remarkable success in high-dimensional spaces, their application to low-dimensional data remains crucial for understanding fundamental model behaviors and addressing real-world applications with inherently low-dimensional data. However, in these spaces, traditional models often struggle to simultaneously capture both macro-level patterns and fine-grained features, leading to suboptimal sample quality. We propose a novel architecture incorporating two parallel branches: a global branch processing the original input and a local branch handling an upsampled version, with a learnable, timestep-conditioned weighting mechanism dynamically balancing their contributions. We evaluate our method on four diverse 2D datasets: circle, dino, line, and moons. Our results demonstrate significant improvements in sample quality, with KL divergence reductions of up to 12.8% compared to the baseline model. The adaptive weighting successfully adjusts the focus between global and local features across different datasets and denoising stages, as evidenced by our weight evolution analysis. This work not only enhances low-dimensional diffusion models but also provides insights that could inform improvements in higher-dimensional domains, opening new avenues for advancing generative modeling across various applications.

1 INTRODUCTION

Diffusion models have emerged as a powerful class of generative models, achieving state-of-the-art results in various domains such as image synthesis, audio generation, and molecular design Yang et al. (2023). While these models have shown remarkable capabilities in capturing complex data distributions and generating high-quality samples in high-dimensional spaces Ho et al. (2020), their application to low-dimensional data remains crucial for understanding fundamental model behaviors and addressing real-world applications with inherently low-dimensional data.

The challenge in applying diffusion models to low-dimensional spaces lies in simultaneously capturing both the global structure and local details of the data distribution. In these spaces, each dimension carries significant information about the overall structure, making the balance between global coherence and local nuance particularly crucial. Traditional diffusion models often struggle to achieve this balance, resulting in generated samples that either lack coherent global structure or miss important local details.

To address this challenge, we propose an adaptive dual-scale denoising approach for low-dimensional diffusion models. Our method introduces a novel architecture that processes the input at two scales: a global scale capturing overall structure, and a local scale focusing on fine-grained details. The key innovation lies in our learnable, timestep-conditioned weighting mechanism that dynamically balances the contributions of these two scales throughout the denoising process.

We evaluate our approach on four diverse 2D datasets: circle, dino, line, and moons. Our experiments demonstrate significant improvements in sample quality, with reductions in KL divergence of up to 12.8

AI-Scientist Generated Preprint

3.1 PROBLEM SETTING

We focus on applying diffusion models to 2D datasets. Let $\mathcal{X} \subset \mathbb{R}^2$ be our data space, and $p_{\text{data}}(\mathbf{x})$ be the true data distribution over $\mathcal{X}$. Our goal is to learn a generative model that samples from a distribution $p_{\text{model}}(\mathbf{x})$ closely approximating $p_{\text{data}}(\mathbf{x})$.

The diffusion process is defined over T timesteps. Let $\mathbf{x}_0 \sim p_{\text{data}}(\mathbf{x})$ be a sample from the data distribution, and $\mathbf{x}_1, \dots, \mathbf{x}_T$ be the sequence of increasingly noisy versions of $\mathbf{x}_0$. The forward process is defined as:

$$q(\mathbf{x}_t|\mathbf{x}_{t-1}) = \mathcal{N}(\mathbf{x}_t; \sqrt{1 - \beta_t}\mathbf{x}_{t-1}, \beta_t\mathbf{I}) \quad (1)$$

where β_t is the noise schedule.

The reverse process, parameterized by a neural network ϵ_θ , is defined as:

$$p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t) = \mathcal{N}(\mathbf{x}_{t-1}; \mu_\theta(\mathbf{x}_t, t), \Sigma_\theta(\mathbf{x}_t, t)) \quad (2)$$

In low-dimensional spaces, each dimension carries significant information about the overall structure of the data. This presents a unique challenge: the model must simultaneously capture both the global structure and local details of the data distribution. Traditional diffusion models often struggle to achieve this balance in low dimensions, motivating our proposed adaptive dual-scale approach.

Our approach is based on two key assumptions:

1. The importance of global and local features varies across different datasets and at different stages of the denoising process.
2. A learnable, timestep-conditioned weighting mechanism can effectively balance the contributions of global and local features during denoising.

These assumptions form the basis of our adaptive dual-scale denoising architecture, which we will describe in detail in the following section.

4 METHOD

Our adaptive dual-scale denoising approach addresses the challenge of balancing global structure and local details in low-dimensional diffusion models. Building upon the formalism introduced in Section 3, we present a novel architecture that dynamically adjusts its focus between global and local features throughout the denoising process.

4.1 DUAL-SCALE ARCHITECTURE

The core of our method is a dual-scale architecture that processes the input at two different scales simultaneously:

1. **Global Scale:** This branch processes the original input $\mathbf{x}_t \in \mathcal{X} \subset \mathbb{R}^2$, capturing the overall structure of the data.
2. **Local Scale:** This branch processes an upsampled version of the input $\mathbf{x}_t^{up} \in \mathbb{R}^4$, focusing on fine-grained details.

Both branches use similar network architectures, but with different input dimensions:

$$\epsilon_\theta^{\text{global}}(\mathbf{x}_t, t) = \text{MLP}_{\text{global}}(\mathbf{x}_t, t) \quad (3)$$

$$\epsilon_\theta^{\text{local}}(\mathbf{x}_t^{up}, t) = \text{MLP}_{\text{local}}(\mathbf{x}_t^{up}, t) \quad (4)$$

where MLP denotes a multi-layer perceptron with sinusoidal embeddings for both input and time, similar to the architecture used in the original DDPM Ho et al. (2020). The upscaling operation $\mathbf{x}_t^{up} = \text{Upscale}(\mathbf{x}_t)$ is implemented as a learnable linear transformation:

AI-Scientist Generated Preprint




Figure 2: Evolution of global and local feature weights across timesteps for different datasets. The x-axis represents timesteps (from end to beginning of the diffusion process), while the y-axis shows weight values. Each line represents the weight for global (solid) and local (dashed) features for a specific dataset.

Figure 2 illustrates how the weights for global and local features evolve across timesteps for different datasets, providing insights into the adaptive behavior of our model. This visualization helps us understand how the model balances global structure and local details at various stages of the denoising process for each dataset.

5 EXPERIMENTAL SETUP

We evaluate our adaptive dual-scale denoising approach on four 2D datasets: circle, dino, line, and moons. These datasets, each consisting of 100,000 points, represent a range of low-dimensional data distributions with varying complexity:

- Circle: A simple closed curve
- Dino: A complex shape with both smooth and sharp features
- Line: A linear structure
- Moons: Two interleaving crescent shapes

Our model architecture, implemented in PyTorch, consists of:

- Global and local branches: Multi-Layer Perceptrons (MLPs) with 3 hidden layers of 256 units each, using sinusoidal embeddings for input and time
- Upscaling operation: Learnable linear transformation from $\mathbb{R}^2$ to $\mathbb{R}^4$
- Weight network: 2-layer MLP with LeakyReLU activation

Training parameters:



The AI Scientistが実際に書いた論文
(人間は文字も、図も式も作っていない)

つい先日、人工知能のトップ学会で、AIによって自動生成された論文が採択された


論文本体

https://sakana.ai/assets/ai-scientist/adaptive_dual_scale_denoising.pdf


- 2025年5月にGoogle DeepMindが発表した研究用のAIエージェントであり、生成AIと進化的計算を用いて、新しい科学的発見を行うことができる
- AlphaEvolveによって、新しい行列計算アルゴリズム、未解決の数学問題の解放、新しいGoogleのデータセンターのタスクスケジューリング法、AI自体を動かす半導体チップの設計の最適化、新しい生成AIの最適化アルゴリズムが発見された
- AIが生み出した研究の知見によってAIの性能が上がるループに入りつつある



Data Center Optimization
Borg Scheduling



Hardware Optimization
TPU Circuit Design



Software Optimization
Gemini Training

 **今井翔太** 木曜日 19:42
@Devin
DXと関連があるAI応用の論文を何らかの指標でランキング付けしたサイトを作ってください。

11 件の返信

 **Devin** アプリ 木曜日 19:42
Devin is running, you can send messages in this thread! Messages starting with 'aside' will be ignored. ([open webapp](#))

ご依頼ありがとうございます。DXと関連があるAI応用の論文を何らかの指標でランキング付けするサイトを作成します。早速取り掛かります。

DXと関連があるAI応用の論文をランキング付けするサイトを作成するために、いくつか確認させてください：

1. ランキングの指標として何を使用すべきでしょうか？（例：引用数、ダウンロード数、インパクトファクター、発表年など）
2. 論文の情報源はどこから取得すべきでしょうか？（例：arXiv、Google Scholar、特定のジャーナルなど）
3. サイトにはどのような機能が必要ですか？（例：検索機能、フィルタリング、詳細表示など）
4. 「DX」とは「デジタルトランスフォーメーション」の略でよろしいでしょうか？

これらの情報をもとに、最適なサイトを構築いたします。

Slack（普通は社内の人間のコミュニケーションツール）で、人間が作ってほしいソフトウェアなどの指示をDevinに出す

十分後

DX関連AI論文ランキング

引用数に基づくデジタルトランスフォーメーション関連AI論文のランキング


	Digital Transformation through Artificial Intelligence: A Systematic Review Tanaka Kenji, Suzuki Akira, Yamamoto Yuki This paper reviews the current state of digital transformation (DX) enabled by artificial intelligence technologies, focusing on implementation strategies and success factors across various industries. 公開日: 2022-01-15 更新日: 2022-02-10 arXiv PDF	引用数: 145
	Machine Learning Applications in Digital Transformation: Case Studies from Japanese Manufacturing Sato Haruki, Ito Yui This study examines how machine learning technologies are being applied to accelerate digital transformation in Japanese manufacturing companies, with detailed case studies and implementation frameworks. 公開日: 2021-03-22 更新日: 2021-04-15 arXiv PDF	引用数: 98
	Deep Learning for Digital Transformation in Healthcare Nakamura Mei, Kobayashi Ryo, Takahashi Hana This research explores how deep learning technologies are revolutionizing healthcare through digital transformation, with focus on diagnostic imaging, personalized medicine, and operational efficiency. 公開日: 2022-05-10 更新日: 2022-06-05 arXiv PDF	引用数: 87
	AI-Driven Digital Transformation in Financial Services Watanabe Taro, Kimura Aiko This paper analyzes how artificial intelligence is driving digital transformation in the financial services industry, covering applications in risk assessment, fraud detection, and customer service automation. 公開日: 2021-04-30 更新日: 2021-05-25 arXiv PDF	引用数: 76

Devinがプログラミングからソフトやサイトの公開まで全部やってくれる

- 現在は、実世界も、インターネットも、業務環境も、全て原則「人間のために」作られており、「AIが人間に代わってやる」には不便なところが多い

【例】

階段やドアなどの人間の体
が扱いやすい社会インフラ



検索エンジンのインデックス、
HTMLやPDFの資料/サイト

ChatGPT登場以降、特に劇的に生産性が上がった分野の統計データのもとめと、出典を教えてください。2024年以降の情報をお願いします。学習データの都合上、2024年以降の情報を持っていない場合には、検索機能も使って答えてください。



以下は参考文献のサイト名とURLのリストです：

1. Techopedia - <https://www.techopedia.com>
2. Master of Code - <https://www.masterofcode.com>
3. MIT News | Massachusetts Institute of Technology - <https://news.mit.edu>
4. arXiv - <https://arxiv.org>
5. Sortlist - <https://www.sortlist.com>

人間本体や人間の操作が途中に介入しないと成立しにくい業務環境



→一般的なロボでは扱いにくい。わざわざロボットの形を人間に寄せないといけない

→現在の検索インデックス方式はLLMに最適でない。PDFや図表が入ったファイルは生成AIで扱いにくい

→AIの機能だけで業務を完結することができず、導入を阻んでしまう

生成AI時代に合った形に、これらを作り替える必要がある

- DeepSeekの登場により、AI研究分野の一部は小型化、オープン化、コモディティ化のサイクルに入り、GAFAMのような大企業が新たに生まれる地盤が整うだろう
- 一方でAIの科学的発見や運動などの分野ではAIの大規模化が進み、AGIやASIに近づく、人間にはできなかった問題解決のいくつかがAIによってされるだろう
- AIエージェントにより、少なくともデジタル空間で完結する作業の大半は自動化が進み、余暇時間が増える一方、資本主義社会化の競争や失業と向き合う必要が出てくるだろう