

RIETI BBL meeting

生成AIの研究開発と今後の方向性

September 5, 2024

NEC Data Science Laboratories/Generative AI Center

Ken Hanazawa

Table of Contents

1. Introduction

- 自己紹介/組織紹介

2. 技術の系譜

- なぜ生成AIか
- 技術の歴史
- マーケットの期待

3. 世の中の動向

- 国内外各社の動向

4. NECにおける生成AI開発

5. 今後の方向性

Introduction

Self-Introduction

◆ Research Interests

- Speech Recognition and Machine Translation
- Pattern Recognition and Machine Learning
- Data Science and Artificial Intelligence
- Human Intelligence Augmentation



<http://linkedin.com/in/ken-hanazawa-590752166>

Joined
NEC



JEITA Technical Standardization Committee



JSAI Editorial Board Member

Now

Speech Recognition and Translation



Biometric Authentication



NEC Labs
America



Data
Science



NEC組織体制（2024年4月）

クロス
インダストリー
ビジネス
ユニット

DGDF
ビジネス
ユニット

パブリック
ビジネス
ユニット

エンタープライズ
ビジネス
ユニット

テレコムサービス
ビジネス
ユニット

エアロスペース・
ナショナル
セキュリティ
ビジネス
ユニット

デジタルプラットフォームビジネスユニット

グローバルイノベーションビジネスユニット

研究開発

×


新事業開発

×


知的財産戦略

コーポレート

グローバルイノベーションビジネスユニット活動体制



グローバルの強みを活かし研究開発と事業開発の機会を拡大



技術の系譜

なぜ我々は生成AI開発に取り組むのか？

なぜ我々は生成AI開発に取り組むのか？

◆ 知の拡張・知識欲

- 知識源としての生成AI/LLM



◆ 労働/業務の効率化

- 各種ツール/AIとのインタフェースとして生成AI/LLMの対話機能を活用




人の能力の拡張

人の知的能力の段階的な向上についての米国教育界での分類を参考

◆ Bloom's Taxonomy

■ 人の知的能力の段階的な向上についての分類（米国教育界）



Bloom, B. S. (Ed.). (1956). Taxonomy of educational objectives: The classification of educational goals, by a committee of college and university examiners. New York: Longmans.


(参考) 日本におけるBloom's Taxonomyの活用

REVISED Bloom's Taxonomy Action Verbs 改訂版ブルームタキソノミーの動詞

	記憶 (Remembering)		理解 (Understanding)		応用 (Applying)		分析 (Analyzing)		評価 (Evaluating)		Creating	
Bloom'sDefinition ブルームの定義	Exhibit memory of previously learned material by recalling facts,terms, basic concepts, and answers.		Demonstrate understanding of facts and ideas by organizing,comparing, translating, interpreting, giving descriptions, and stating main ideas.		Solve problems to new situations by applying acquired knowledge, facts, techniques and rules in a different way.		Examine and break information into parts by identifying motives or causes. Make inferences and find evidence to support generalizations.		Present and defend opinions by making judgments about information,validity of ideas, or quality of work based on a set of criteria.		Compile information together in a different way by combining elements in a new pattern or proposing alternative solutions.	
	事実、用語、基本概念、および回答を思い出すことによって、以前学習した資料の記憶を提示する		整理、比較、翻訳、解説、説明の提供、主要アイデアの記述により、事実やアイデアの理解を実証する。		獲得した知識、事実、技術、ルールを異なる方法で適用することによって、新しい状況への問題を解決する。		動機や原因を特定して、情報を調べて部品に分解する。 推論を行い、一般化をサポートする証拠を見つける。		情報の基準、アイデアの妥当性、または一連の基準に基づいて仕事の質を判断し、意見を提示し、守る。		新しいパターンで要素を結合するか、代替ソリューションを提案することによって、情報を異なる方法でまとめる。	
Verbs 動詞	• Choose	•選択する	• Classify	•分類する	• Apply	•適用する	• Analyze	•分析する	• Agree	•同意する	• Adapt	•適応する
	• Define	•定義	• Compare	•比較する	• Build	•築く	• Assume	•仮定する	• Appraise	•鑑定する	• Build	•築く
	• Find	•検索	• Contrast	•対比する	• Choose	•選択する	• Categorize	•分類する	• Assess	•評価する	• Change	•変化する
	• How	•どうやって	• Demonstrate	•実証する	• Construct	•構成する	• Classify	•分類する	• Award	•与える	• Choose	•選択する
	• Label	•ラベル	• Explain	•説明する	• Develop	•開発する	• Compare	•比較する	• Choose	•選択する	• Combine	•結合する
	• List	•リストアップする	• Extend	•拡張する	• Experiment with	•実験する	• Conclusion	•結論づける	• Compare	•比較する	• Compile	•編集する
	• Match	•マッチ	• Illustrate	•図解する	• Identify	•識別する	• Contrast	•対比する	• Conclude	•結論づける	• Compose	•作成する
	• Name	•名前	• Infer	•推論する	• Interview	•インタビューする	• Discover	•発見する	• Criteria	•基準を作る	• Construct	•構成する
	• Omit	•省略	• Interpret	•解釈する	• Make use of	•使用する	• Dissect	•解剖する	• Criticize	•批判する	• Create	•作成する
	• Recall	•想起	• Outline	•略述する	• Model	•モデル	• Distinguish	•区別する	• Decide	•決める	• Delete	•削除する
	• Relate	•関連	• Relate	•関連づける	• Organize	•整理する	• Divide	•分割する	• Deduct	•控除する	• Design	•設計する
	• Select	•選択	• Rephrase	•言い換える	• Plan	•計画する	• Examine	•調査する	• Defend	•守る	• Develop	•開発する
	• Show	•見せる	• Show	•見せる	• Select	•選択する	• Function	•作動する	• Determine	•決定する	• Discuss	•話し合う
	• Spell	•スペル	• Summarize	•要約する	• Solve	•解決する	• Inference	•推論する	• Disprove	•論駁する	• Elaborate	•精巧な
	• Tell	•話す	• Translate	•翻訳する	• Utilize	•利用する	• Inspect	•検査する	• Estimate	•見積もり	• Estimate	•見積もる
	• What	•何					• List	•リストアップする	• Evaluate	•評価する	• Formulate	•公式にする
	• When	•いつ					• Motive	•動機づける	• Explain	•説明する	• Happen	•起こる
	• Where	•どこで					• Relationships	•関係づける	• Importance	•重要性	• Imagine	•想像する
	• Which	•どの					• Simplify	•簡素化する	• Influence	•影響を与える	• Improve	•改善する
	• Who	•誰					• Survey	•調査する	• Interpret	•解釈する	• Invent	•発明する
• Why	•なぜ					• Take part in	•参加する	• Judge	•判断する	• Make up	•作成する	
						• Test for	•テストする	• Justify	•正当化する	• Maximize	•最大化する	
						• Theme	•テーマを設定する	• Mark	•印をつける	• Minimize	•最小化する	
								• Measure	•測定する	• Modify	•変更する	
								• Opinion	•意見をいう	• Original	•元の	
								• Perceive	•知覚する	• Originate	•発明する	


自然言語処理における技術とアプリケーションの進化

ChatGPT以前




Transformerによる進化の加速

ChatGPT前夜




大規模言語モデルの変遷とChatGPTの登場



<https://arxiv.org/pdf/2303.18223>

言語の基盤モデル LLM

大量のデータを用いて学習された、大量のパラメータを持つモデル。知識を内包し、プロンプトと呼ばれる入力を与えることで様々なタスクが実行可能となる



大量のデータで大量パラメータの学習

例.

モデル	パラメータ数	データ量
BERT	3.4億程度	13GB※1※2
GPT-3	1,750億	570GB※1

※1 データ量は推定値、
※2 事前学習のデータ量

×

プロンプトを工夫した学習

【参考】In-context learning *GPT-3以降

1	Translate English to French:	← task description
2	sea otter => loutre de mer	← example
3	cheese =>	← prompt

[arXiv:2005.14165] Language Models are Few-Shot Learners




多くのタスクが可能に！

ChatGPT登場後のAIハイプサイクル

従来からの「AIの高度化」技術に加えて、AIとシミュレーションの統合、AIをエージェントとしたマルチエージェントシステムなど「複数AIの連携」技術が増加

Hype Cycle for Artificial Intelligence, 2023



gartner.com

Source: Gartner
© 2023 Gartner, Inc. and/or its affiliates. All rights reserved. 2079794

Gartner

主流の採用までの時期

2-5年

- Cloud AI Services
- Intelligent Applications
- AI maker & Teaching kits
- Knowledge Graph
- Synthetic data
- Foundation models
- Prompt Engineering
- Decision Intelligence
- AI TRISM*
- **Composite AI**
- Data-Centric AI
- Causal AI
- First-Principles AI

5-10年

- Autonomous vehicles
- ModelOps
- Generative AI
- Smart Robots
- Responsible AI
- Operational AI Systems
- AI Engineering
- **AI Simulation**
- **Multitagent Systems**
- **Automatic Systems**


10年後以降

- AGI
- Neuro-symbolic

下線部：過去2年のハイプサイクルに関連技術がなかったもの
太字：「複数AIの連携」に関する技術

生成AI技術スタック

Gartnerハイプサイクルにある技術をスタック図の形に整理 (弊社解釈)
モデル単体に留まらず幅広い機能・技術が必要



世の中の動向

LLM開発における各社の動向 (1/2)

グローバル大手はプラットフォーム化を狙う、提携も進む

- ◆ OpenAI/MS : GPTシリーズに強み、さらに継続的な強化
- ◆ Google : Geminiシリーズでマルチモーダル対応と大中小のラインナップを用意、Gemmaで小型モデルに注力
- ◆ Anthropic : GoogleやAWSが出資、Claude3は高性能でGPT4対抗一番手
- ◆ Cohere : LLM+RAGに強み、富士通と連携

LLM開発における各社の動向 (2/2)

国内では大規模化で遅れも業種特化に活路

- ◆ NTT：軽量モデルで業種特化しやすさを訴求
- ◆ 富士通：Fugaku-LLMに参画する一方、特化型生成AIを提供、Cohereと提携
- ◆ Softbank：計算基盤拡充により大規模モデルを目指す
- ◆ PFN：日英2言語でのトップ性能を訴求、AI用チップも開発・提供
- ◆ ELYZA：KDDIと連携、業種特化モデルに強み
- ◆ NEC：軽量性と日本語性能で訴求、業種特化して垂直市場を狙う

◆ 独自LLMを開発 (2023.7-)、高い日本語能力と高速性を訴求

1 軽量で、お客様へのカスタマイズが可能な
NEC開発のLLM

高い日本語能力
軽量

医療用 LLM
コールセンター用 LLM

ファインチューニング

NEC開発

2 誰でも便利にLLMを使用できるソフトウェア
NEC Generative AI Framework



3 セキュリティや費用など、お客様の要件にあわせた
柔軟な提供形態

クラウド
オンプレミス

印西データセンター
Microsoft Azure

セキュア/高速低遅延
導入コスト低減

セキュア
お客様拠点

4 「NEC Generative AI Hub」メンバーを中心とした
専門家によるワンストップのサービス提供

AI専門チーム
・データアナリスト
・コンサルタント
etc...

企画・検討
PoC
システム構築
システム運用

NECにおける生成AI開発

NECの生成AI基盤モデル cotomi

速く・性能がよく・手元でうごくLLM

2024/04/24 プレス発表

ChatGPTと比較して、10倍の速度かつ、同等程度の品質を実現可能



cotomi

圧倒的な速度で
充分な性能のLLMを
セキュアに提供

多くのタスクで**充分な性能**
ファインチューニングでの
精度向上が可能

非常に高速
(**chatGPTの10倍**)
インフラの増強による
速度改善が可能

軽量であるため、
オンプレミスでの
セキュアな使用も可能



ChatGPT

高性能なLLMを
SaaSで提供

多くの汎用タスク
において**高性能**

SaaSでの提供であり、
処理速度の
改善ができない

SaaSでの提供であり、
機微な情報での
使用が難しい

高精度

GPT-4

GPT-3.5

互角の性能

10倍の速度

Meta
(Llama2)

ファインチューニングにより
さらなる精度向上が可能

インフラの増強により、
さらなる高速化が可能

GPU×4

GPU×8

cotomi Light

省コストで大量のリクエストを処理可能。
多くのタスクで充分な性能

cotomi Pro

グローバルベンダのLLMと同等品質を
「プライベートに」提供



※精度はELYZA-tasks-100（日本語の質問応答）での評価
インフラはA100×2を利用し評価（OpenAIはSaaS利用）

高速

(ご参考) cotomi 性能

2024/04/24 プレス発表時

GPT-3.5と並ぶ能力 と GPT-4の12-15倍の高速性




[NEC、世界トップレベル性能の高速な大規模言語モデル \(LLM\) cotomi Pro / cotomi Light を開発 \(2024年4月24日\): プレスリリース | NEC](#)

LLMを活用した業務改善

音声認識や映像理解技術とLLMを組み合わせ、手間のかかる作業工数を削減

音声認識×LLM による業務改善

コンタクトセンタのオペレータ業務工数 4 割削減



映像×LLM による業務改善

ドライブレコーダ映像から事故調査報告書を自動作成




2023/12/5 発表

LLMを活用した業務改善

LLMの対話理解能力、文書読解能力を活かし、使い勝手の良いSLを実現

病院業務

医療用語を学習したLLMを用いて、医師と患者との対話からカルテを自動構成。




※1 現場観察に基づく推論値

電子カルテシステム「MegaOak/iS」として販売を開始

2024/3/18 プレス発表

サイバーセキュリティ診断

セキュリティ特化型LLMがNECリスク診断技術を活用して、依頼文に対し診断やレポートを短時間に回答




※NECサイバー攻撃リスク自動診断技術


2023/12/15 プレス発表

NECではLLMをどう作ったか？

- ◆ 巨大なモデルを大規模・高品質な種々のテキストデータで逐次的に学習





①事前学習：モデルに“知識”と“推論能力”を持たせる



モデルのかなりの能力は事前学習で定まり、後段フェーズでの“劇的な改善”は困難 [Gudibande+23]

①事前学習：モデル規模を決めると、最適なデータ量が定まる

- ◆ どんな大きさのモデルに、どれだけのデータ量を学習させるか、は自由
 - 原理的には、自分の実力 (= 使えるGPU時間) の範囲で、任意に決めて良い
- ◆ ただし、適当に決めると損をする



「学習時間は同じ」 だが 「性能は 70B-1.4T の方が（経験的に）良い」

- ◆ Scaling-Law: 「使えるGPU時間」から最適なデータ量・モデル規模は定まる
 - 様々なデータ量・モデル規模での実験結果から、経験的な最適値の算出モデルを推定 [Kaplan+20]
 - データ量:パラメータ数 = 20:1 にすると良い (Chinchilla 最適) [Hoffmann+22]

[Kaplan+20] [Scaling Laws for Neural Language Models](#)

[Hoffmann+22] [Training Compute-Optimal Large Language Models](#)

①事前学習：モデルサイズは抑え、データを過剰に

近年のトレンド


～ 2022年
(Chinchilla 以前)

Scaling-Law にもとづき
デカイモデルを作ろう
データは二の次！



多くのモデルが
データ不足
学習不足の状態
(モデルサイズのわりに
性能が低い)

データ不足



データ過剰

2022年～
(Chinchilla～LLaMA 以後)

元々の Scaling-Law だと
データ少なすぎでは？
(Chinchilla)



あれ Chinchilla 以上に
データ入れてもまだまだ性能
伸びるじゃん！
(LLaMA)



大量のデータを学習し
モデルの規模を抑えつつ
高い性能を狙うトレンド

①事前学習：データは有限

◆ Chinchilla は (1) データは無限に存在 (2) モデルは任意に大きくできる想定

◆ → これらは、現実には成立しないため、発展的な議論が必要に


◆ (1) データは、実際には有限、高い品質も必要

■ データは4倍ぐらいまでは水増しできるが、それ以降はモデルサイズを増やすべき [Muennighoff+23]

• (データセット中、同じデータを4つ混ぜてもスケール則が成立、それ以降は破綻)

■ データには、極めて高い品質が求められる

• LLM の性能は「ほぼデータで定まる」というのが近年のコンセンサス



◆ (2) モデルは、実際には一定のサイズに抑えたい


■ Chinchilla 最適にもとづく「最適モデルサイズ」が現実には許容できないこともある

• → 1.4T のデータにもとづく 70B が最適だが、実際には 70B のモデルを作ってもデカすぎて取り回しづらい

■ → LLaMA のように、モデルサイズは推論環境・推論速度の要件に伴って定め、持てる限りのデータを Chinchilla 最適以上に突っ込むトレンドに (前ページの議論)

• ただし、限界は明らかにある。小さいモデルは、特に記憶できる知識量 (QA能力)、多言語能力に限り

①事前学習：データを準備し、事前学習



そうそう、これが欲しかったんじゃ

事前学習モデルの段階であっても
低レイヤ NLP API として使う人はいる

```
from openai import OpenAI
client = OpenAI()
response = client.completions.create(
    model="text-davinci-001",
    prompt="吾輩は猫である。名前は"
)
```




なんかちょっと、期待と違う...

「100文字以内で」みたいな指示したいんだけど
ChatGPT みたいに対話したいんだけど

ChatGPT がやりたければ、後半戦へ

事後学習 (Post-Training)

②事後学習：モデルに“機能”を持たせる



要約, RAG (機械読解)
function calling, math, coding, ...³³

②事後学習：機能を定義し、データを作り、学習する


◆ こういうプロンプト x を入れたら、こういう出力 y をしてほしい、を作り、学習

$\{ (x_i, y_i) \}$

(“吾輩は猫であるの作者は?”, “夏目漱石です”)



```
<|im_start|>user  
吾輩は猫であるの作者は?  
<|im_end|>  
<|im_start|>assistant  
夏目漱石です
```



事前学習と同じ「次単語予測タスク」で学習
(機能次第で、構造 aware な工夫をしても良い)

◆ 考えなければならないことは様々

■ そもそも、どうやって高品質な入出力のペアを（大量に）用意するのか？

- 人力、気合いだけでは限界。LLMを使った半自動生成の仕組みも無数。“GPT-4蒸留”と呼ばれる禁止行為は避ける。

■ 複数のタスクを混在させて良い？ その割合は？

- 混ぜることで、タスク間で転移が起き互惠 [Wei+21]。ただし、割合次第で“破壊的忘却”が発生するため注意。

◆ 良いデータは、タダでは手に入らない

■ 一見それらしい入出力は HuggingFace で公開されていたり、擬似生成できたり、する

- が、安易に使うと、「それっぽくは動くが使ってみると微妙」なモデルが出来上がる

■ 担保された品質のデータを多量に確保するための資金力 / 賢さ / 気合がカギ

②事後学習：2つのステップ、指示学習とアラインメント



データ	あるプロンプトに対する「望ましい出力」 "こういうときは、こんな出力をしてほしい" (x_i, y_i)	あるプロンプトへのLLMの出力2つに関する優劣 "この出力よりは、こういう出力が好ましい" $(x_i, (y_{i1} < y_{i2}))$
学習方法	Causal LM タスクで SFT (Supervised fine-tuning)	強化学習 (PPO) 特殊な損失のSFT (DPO, IPO, KTO, SteerLM)
目的	LLM にタスク処理能力を具備させる 「できる」を増やす	出力結果をよりフレンドリーにする 知らない情報を知らないと言うようにする 非倫理的内容を出力しないようにする 「できるけど、あえてしない」を増やす

DPO: [Direct Preference Optimization: Your Language Model is Secretly a Reward Model](#)


IPO: [A General Theoretical Paradigm to Understand Learning from Human Preferences](#)

KTO: [KTO: Model Alignment as Prospect Theoretic Optimization](#)

SteerLM: [SteerLM: Attribute Conditioned SFT as an \(User-Steerable\) Alternative to RLHF](#)


③モデルの評価・選定

- ◆ LLMは汎用性が求められるため、複数の尺度（メトリック）で評価して総合的に良いモデルを選定する
- ◆ ゴールとのギャップを認識し、施策の効果を見極め、正しい方向に進む
 - 「実際のユーザが満足する可能性」を可能な限り高めておきたい
- ◆ 陥りがちなパターン
 - 手段と目的が逆転 (Leaderboard で1位！)
 - そもそも、ゴールが定義されていない
 - 評価している観点（指標）がゴールと乖離



NECではLLMをどう作ったか？ - まとめ -

- ◆ 巨大なモデルを大規模・高品質な種々のテキストデータで逐次的に学習
- ◆ 教科書的な手法をベースに、試行錯誤を繰り返しながら最善策を取り続けた



これまでの活動を振り返り

動きの速い業界で、全力疾走

日本で企業が生成AIを研究開発することに意義はある

◆ 国産であることの意義

- 基盤モデルは知識源でもあることから、日本の言語・文化・常識に根差したモデルの開発・維持が、経済安全保障面からも必須
- 一方で国内の活動に閉じずに先端技術（例：北米）や先進規制（例：欧州）との情報流通も必要

◆ 自前であることの意義

- ツールを使いこなすには、そのツールをフルスクラッチで作れるぐらいの知識が重要、AI/LLMも同様
- 動きが速い業界なので、使い続けることも重要

◆ 強みをもつことの意義

- ユニークに訴求できる強みを磨いていかないと、激しい競争の中で埋もれてしまう
例：高速性と日本語性能に強み

（ご参考） 社内活用事例

NECでは社内での生成AI活用を積極的に推進

- ◆ 社内利用におけるルール・ガイドラインをいち早く制定
 - 社員が安心して利用できる仕組みづくり
- ◆ NEC Generative AI Serviceとして、数万人規模の社員が日常的に業務利用
 - cotomiなど内製に拘らない、他社ツールとも柔軟に連携
 - 既に1年ほど運用、データやノウハウを蓄積
 - 一部効果は出てきているが、テキスト以外の入出力はまだまだ

課題

内外で利用者・関係者と会話する中で、性能やコスト面での課題は多い

◆ 精度・性能の課題

動作が遅い（特にクラウド型）

思った結果が得られない（受容性・正当性含）

テキスト以外も扱いたい

◆ 安全性の課題

著作権・プライバシーが気になる

機密情報を扱いたい

◆ コスト面の課題

利用料が高い・消費電力が気になる

開発費が高い（海外大手と投資規模が桁違い）

課題

内外で利用者・関係者と会話する中で、性能やコスト面での課題は多い
対策を打ち続ける

◆ 精度・性能の課題

動作が遅い（特にクラウド型）
思った結果が得られない（受容性・正当性含）
テキスト以外も扱いたい

◆ 安全性の課題

著作権・プライバシーが気になる
機密情報を扱いたい

◆ コスト面の課題

利用料が高い・消費電力が気になる
開発費が高い（海外大手と投資規模が桁違い）

◆ 対策の例


ファクトチェック機能の導入
マルチモーダル対応
高速版・小型軽量版の導入
オンプレミス対応（HW提供含む）
業種・タスク特化
日本向け対応
学習データの透明性
投資規模に頼らない強みの確立・維持

今後の方向性

今後の展望

必要とされる技術は幅広く、多くはまだハイプカーブの途中にある


Hype Cycle for Artificial Intelligence, 2023



gartner.com

Source: Gartner
© 2023 Gartner, Inc. and/or its affiliates. All rights reserved. 2079794

Gartner.



短期的な展望

引き続き競争状況は激しくなると予想
ニーズのある機能・技術が順次開発され、取り入れられていく

◆ 生成AIの入力の幅を広げるマルチモーダル技術の進化

- 画像・映像や音声などの入力モダリティ拡大
- センサデータなど時系列情報の取り込み

◆ 結果の正当性を評価、受容性を向上する技術の進化

- 正当性を担保するファクトチェック機能
- 課題となっているハルシネーションの抑止

◆ 高速性や業界特化は引き続き強化

中長期の展望

労働力が減少していく社会でも生活水準を維持・向上させていく技術の開発

◆ 業務の効率化

- 生成AIをインターフェースとして用いることで、複雑な業務・熟練が必要な業務を簡単に



◆ AIの民主化


- 誰でも簡単に使えるAI、人間の知的能力の拡張

今後に向けた論点

計算資源やデータの整備は引き続き課題
協調領域と競争領域を区別した議論が必要

学習・評価のためのデータ
(日本固有を含む)

正しい進化を促す評価の仕組み



学習・推論のための計算資源
(用力費等も含む)

ポスト生成AIの技術に向けた議論

\Orchestrating a brighter world

NEC