

# 時系列情報予測のための オシプレミスエンコーダ・デコーダ モデル

---

神奈川工科大学 工学部 電気電子情報工学科 教授 広井 賀子

20251007 11:00~11:25

## 紹介する新技術

- ▶ 自然言語長文脈推定深層學習機を基盤に、  
學習データ入力構造および長文脈予測能を改良したプログラム

# 何ができるようになったのか

- ▶ 時系列データをはじめとする、文脈構造を持った汎用データの学習  
汎用の意味：言語に限らない
- ▶ 制約条件  
前後のデータ間に相互因果関係があること  
予測したい軌跡の特徴を強く規定する変数が4つ以上あること

## 以前の技術との違い

- ▶ 複数の異なる変数の学習を行える
- ▶ 学習する変数の種類を物理的制約の上限まで無制限に増やせる

## 想定される用途

- ▶ 動物・移動機器の複雑な軌跡予測
- ▶ 人間行動予測
- ▶ 健康状態推移の予測

# 背景技術

## Attention(2015)

系列データの特定の部分に注意を向けるように学習させる仕組み

# Attention(2015)

系列データの特定の部分に注意を向けるように学習させる仕組み

例) 英語の `it` ... その単語だけでは翻訳できない

`it` を含む文章中のどの単語にどれだけ注目すべきかというスコアを表してくれるのが Attention。

# 自然言語処理向け深層学習モデルの歴史

登場した年	モデル名
1986	RNN
2014	Seq2Seq
2015	Attention
2017	Transformer
2018	BERT

登場した年	モデル名
2019	GPT-2
2019	T5
2020	GPT-3
2022	GPT-3.5
2023	GPT-4

# Transformerとは 概要

## [背景]

翻訳などの入力文章を別の文章で出力するというモデル(=Sequence Transduction Model)は  
Attentionを用いたエンコーダー-デコーダ形式のRNNやCNNが主流であった。  
→Transformer: RNNやCNNを用いずAttentionのみを用いたモデル

## Transformerの特徴

再帰も畠み込みも一切使わない。

現在最も広く使用されている機械翻訳の評価方法(BLEUスコア:28.4)で高い値を出した。

並列化しやすく訓練時間が圧倒的に削減できる。

他のタスクにも汎用性が高い。

# Transformer なぜスゴい?

## [背景]

翻訳などの入力文章を別の文章で出力するというモデル(=Sequence Transduction Model)は  
Attentionを用いたエンコーダー-デコーダ形式のRNNやCNNが主流であった。  
これらのモデルは逐次的に単語を処理するがゆえに訓練時に並列処理ができないという欠点あり

## Transformerの特徴

再帰も畠み込みも一切使わない。

現在最も広く使用されている機械翻訳の評価方法(BLEUスコア:28.4)で高い値を出した。

並列化しやすく訓練時間が圧倒的に削減できる。

他のタスクにも汎用性が高い。

# 計算量問題

文章の依存関係を掴むための逐次的な計算を減らす という目的のもとRNNの代わりに使われたのがCNN。 CNNは並列処理可能だが、 文章が長くなるとそれに従って  $O(n)$  または  $O(\log n)$  で計算量が増えてしまい、 より長文の依存関係を掴めない という問題が残された。

Table 1: Maximum path lengths, per-layer complexity and minimum number of sequential operations for different layer types.  $n$  is the sequence length,  $d$  is the representation dimension,  $k$  is the kernel size of convolutions and  $r$  the size of the neighborhood in restricted self-attention.

Layer Type	Complexity per Layer	Sequential Operations	Maximum Path Length
Self-Attention	$O(n^2 \cdot d)$	$O(1)$	$O(1)$
Recurrent	$O(n \cdot d^2)$	$O(n)$	$O(n)$
Convolutional	$O(k \cdot n \cdot d^2)$	$O(1)$	$O(\log_k(n))$
Self-Attention (restricted)	$O(r \cdot n \cdot d)$	$O(1)$	$O(n/r)$

A Vaswani, N Shazeer, N Parmar, J Uszkoreit, L Jones, AN. Gomez, L Kaiser, I Polosukhi, “Attention Is All You Need,” arXiv:1706.03762, 2017.

Transformerは  $O(1)$ ! ← 最強。

[背景]

# Transformer どう新しい?

翻訳などの入力文章を別の文章で出力するというモデル(=Sequence Transduction Model)は  
Attentionを用いたエンコーダー-デコーダ形式のRNNやCNNが主流であった。  
これらのモデルは逐次的に単語を処理するがゆえに訓練時に並列処理ができないという欠点あり  
長文に対してはAttentionが使われていたが、そのAttentionは上記RNNと一緒に使われていた  
Transformerの特徴

再帰(RNN)も畠み込みも一切使わない→入出力の文章同士の広範囲な依存関係を捉えられる  
現在最も広く使用されている機械翻訳の評価方法(BLEUスコア:28.4)で高い値を出した。  
並列化しやすく訓練時間が圧倒的に削減できる。  
他のタスクにも汎用性が高い。

CNNや逐次的RNNを一切使わずAttentionのみを用いた  
一番最初のトランスタクションモデル

# Transformer 構造の特徴

翻訳のような、ある文章を他の文章に変換するモデルをトランスダクションモデルという  
主流なのはエンコーダ-デコーダモデル

エンコーダ: 入力の文  $(x_1, x_2, \dots, x_n)$  を  $z = (z_1, z_2, \dots, z_n)$  へ変換

デコーダ:  $z$  から単語  $(y_1, y_2, \dots, y_n)$  を出力。

ただし、1時刻に1単語のみで、前時刻のデコーダの出力を現時刻のデコーダの入力として使う。

Transformerは基本的な大枠はエンコーダ-デコーダモデルで、  
self-attention層とPosition-wise全結合層を使用している

## 以前の技術との違い

- ▶ 複数の異なる変数の学習を行える
- ▶ 学習する変数の種類を物理的制約の上限まで無制限に増やせる

...ように改変を行うことで、様々な「将来予測」に適用

# 使用事例

小型船舶の航路予測

## 1. Introduction

### (背景)

- ✓ 船舶の航路予測は、海運分野において、安全性や輸送効率化のための重要な役割を担っている
- ✓ AISデータの取得ハードルは下がったが、活用方法は各分野で研究中

### (課題)

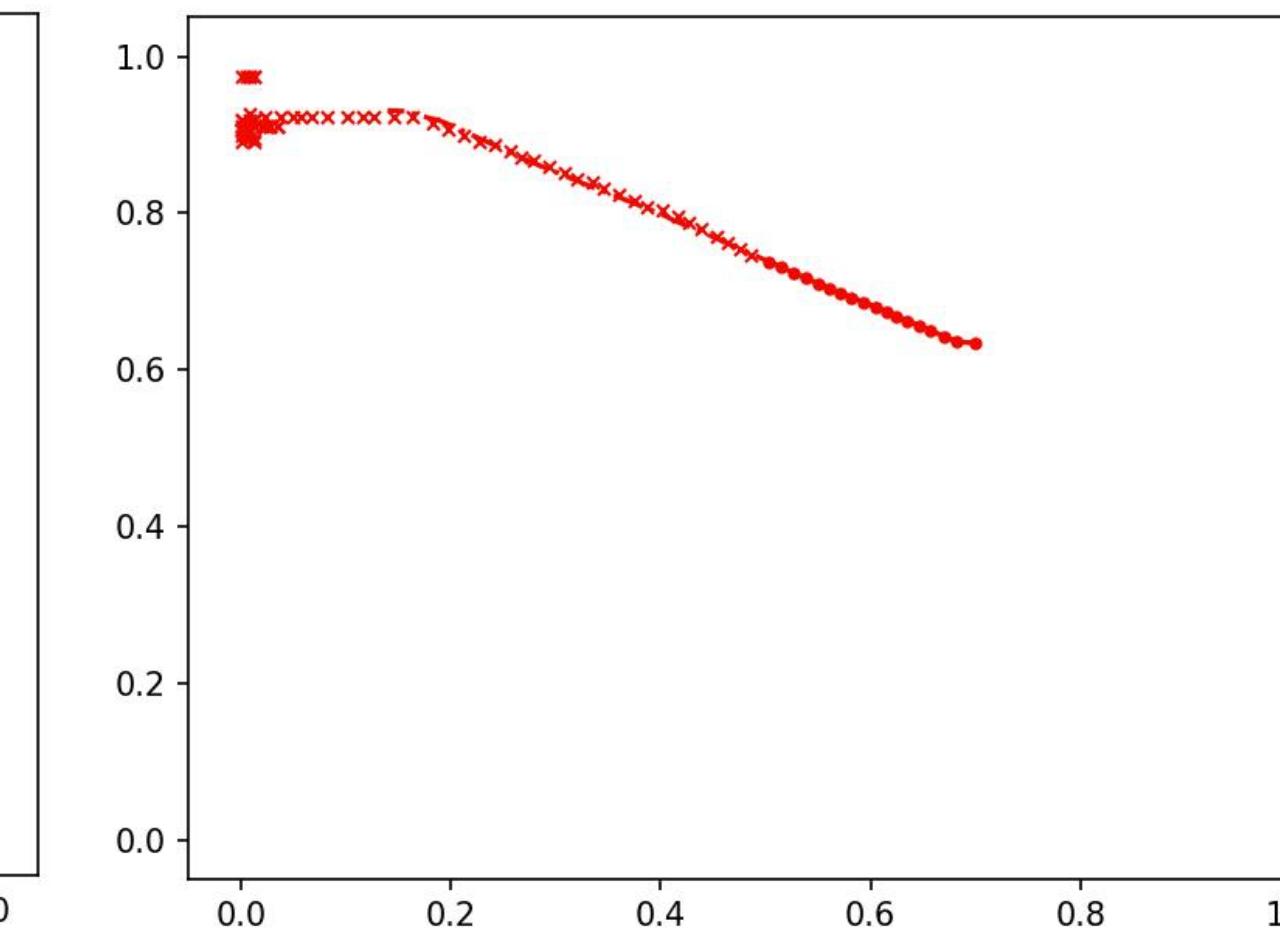
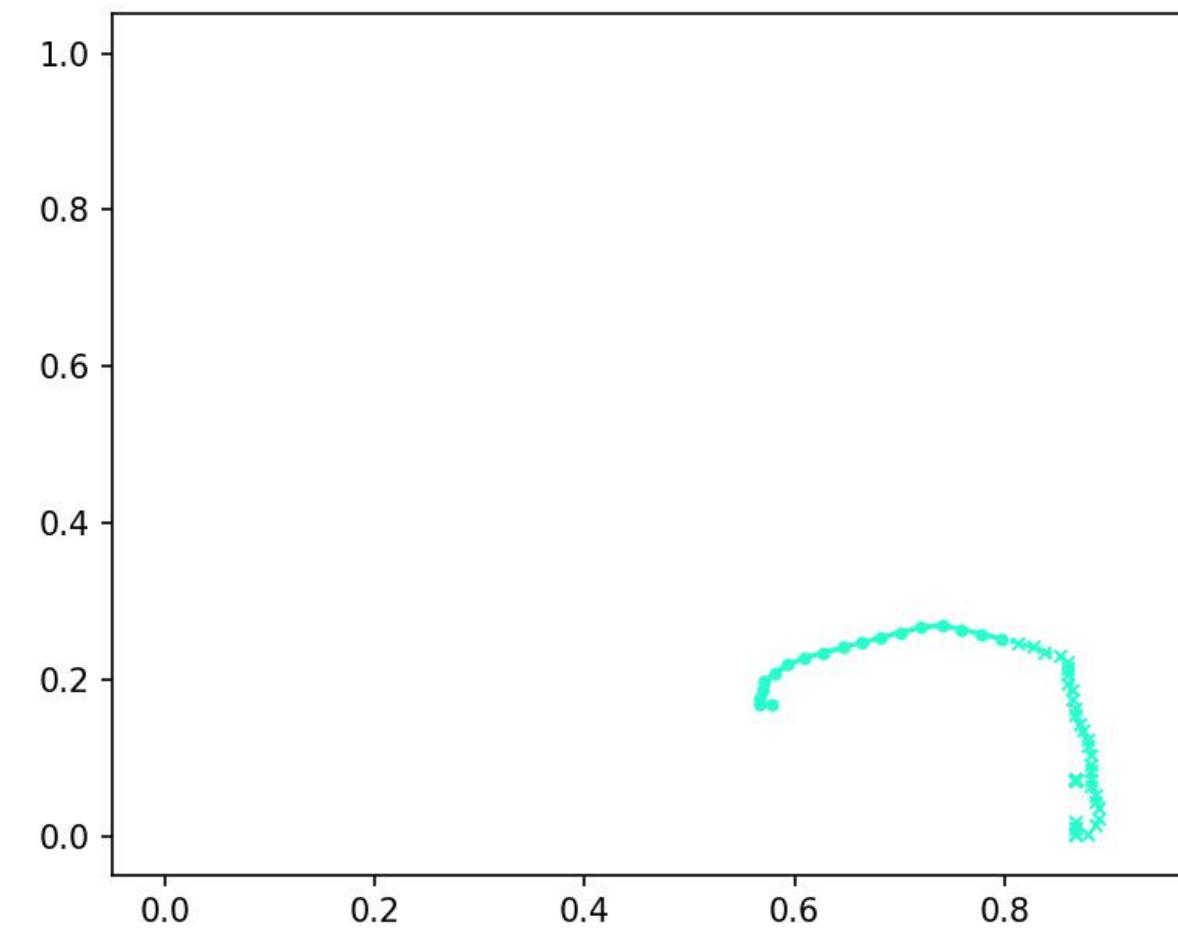
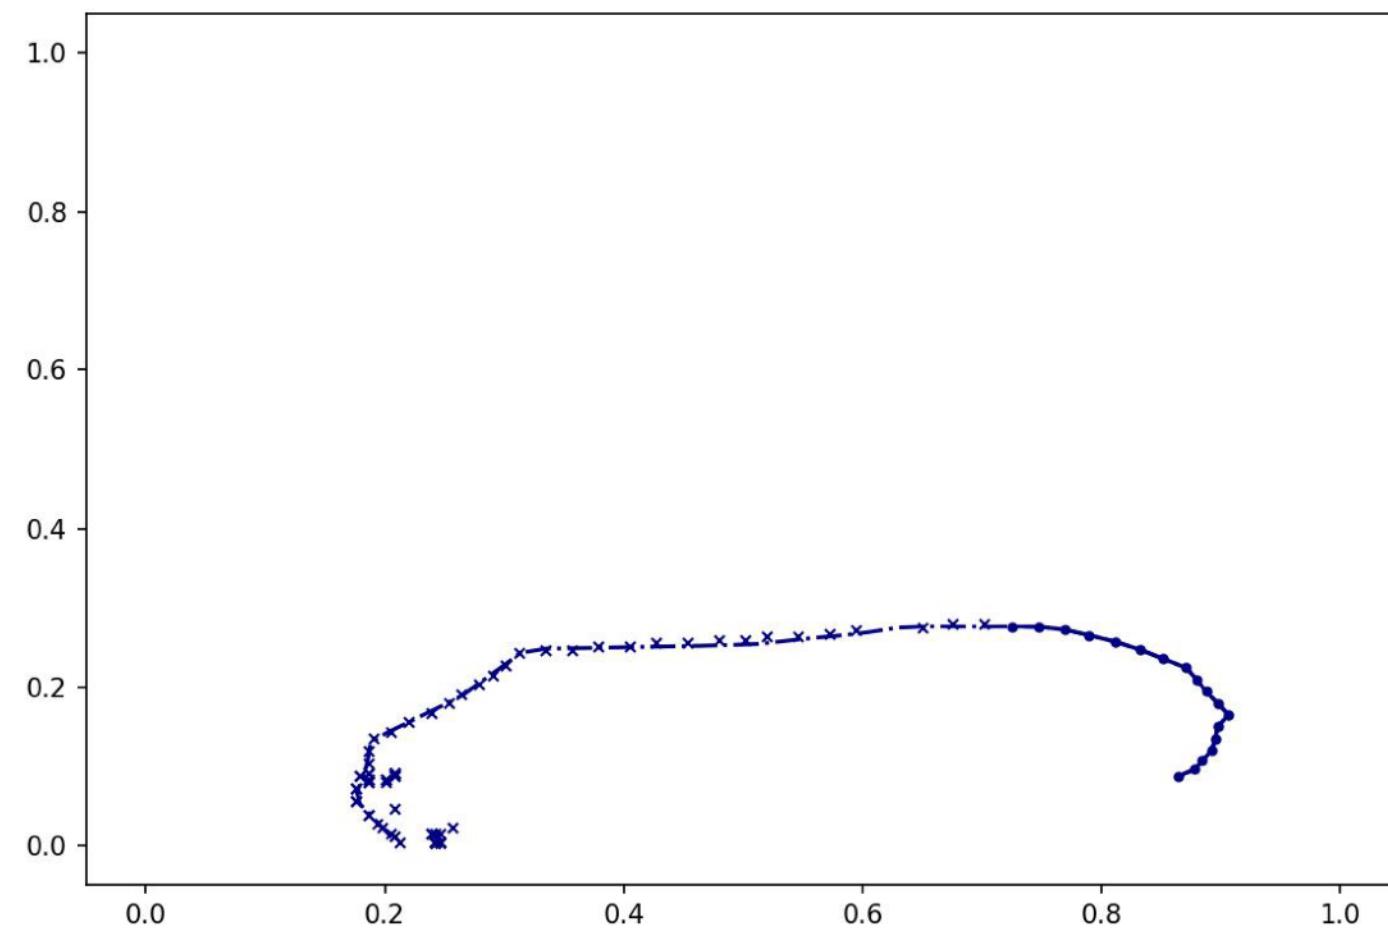
- ✓ AISデータの複雑さや多様性により、航路予測は困難な課題

### (目的)

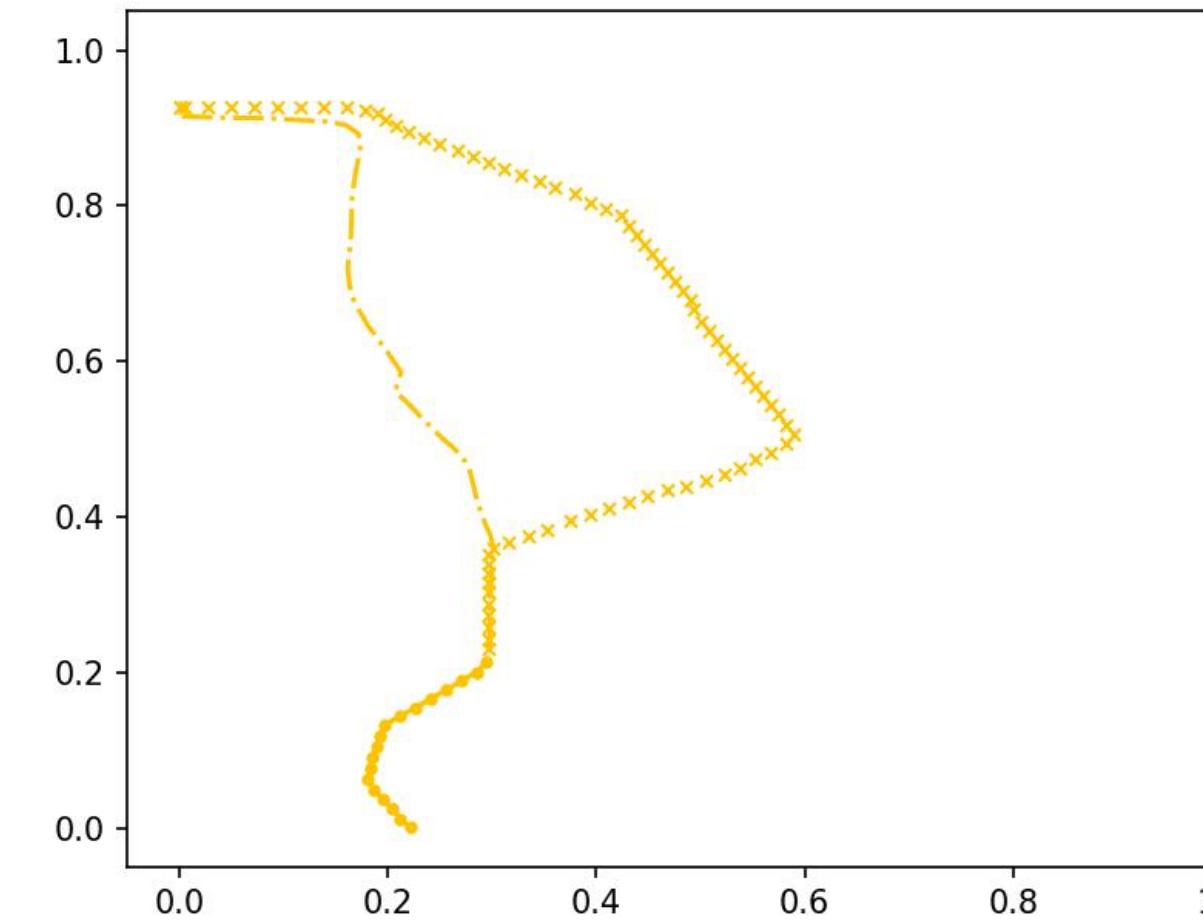
- ✓ 今日の高性能なAIの利用と適切なデータクレンジングで、AISデータから**航路予測を行う手法**を提案する

## 船舶航行データに基づく軌跡予測の例・破線が実航路、xが予測

### ▶ 完全予測の例



### ▶ 方向予測の例



	1h	2h	3h
他の手法(LSTM)での誤差の広がり [km]	6.204	11.871	17.872
本手法での誤差の広がり [km]	0.899	1.668	2.897

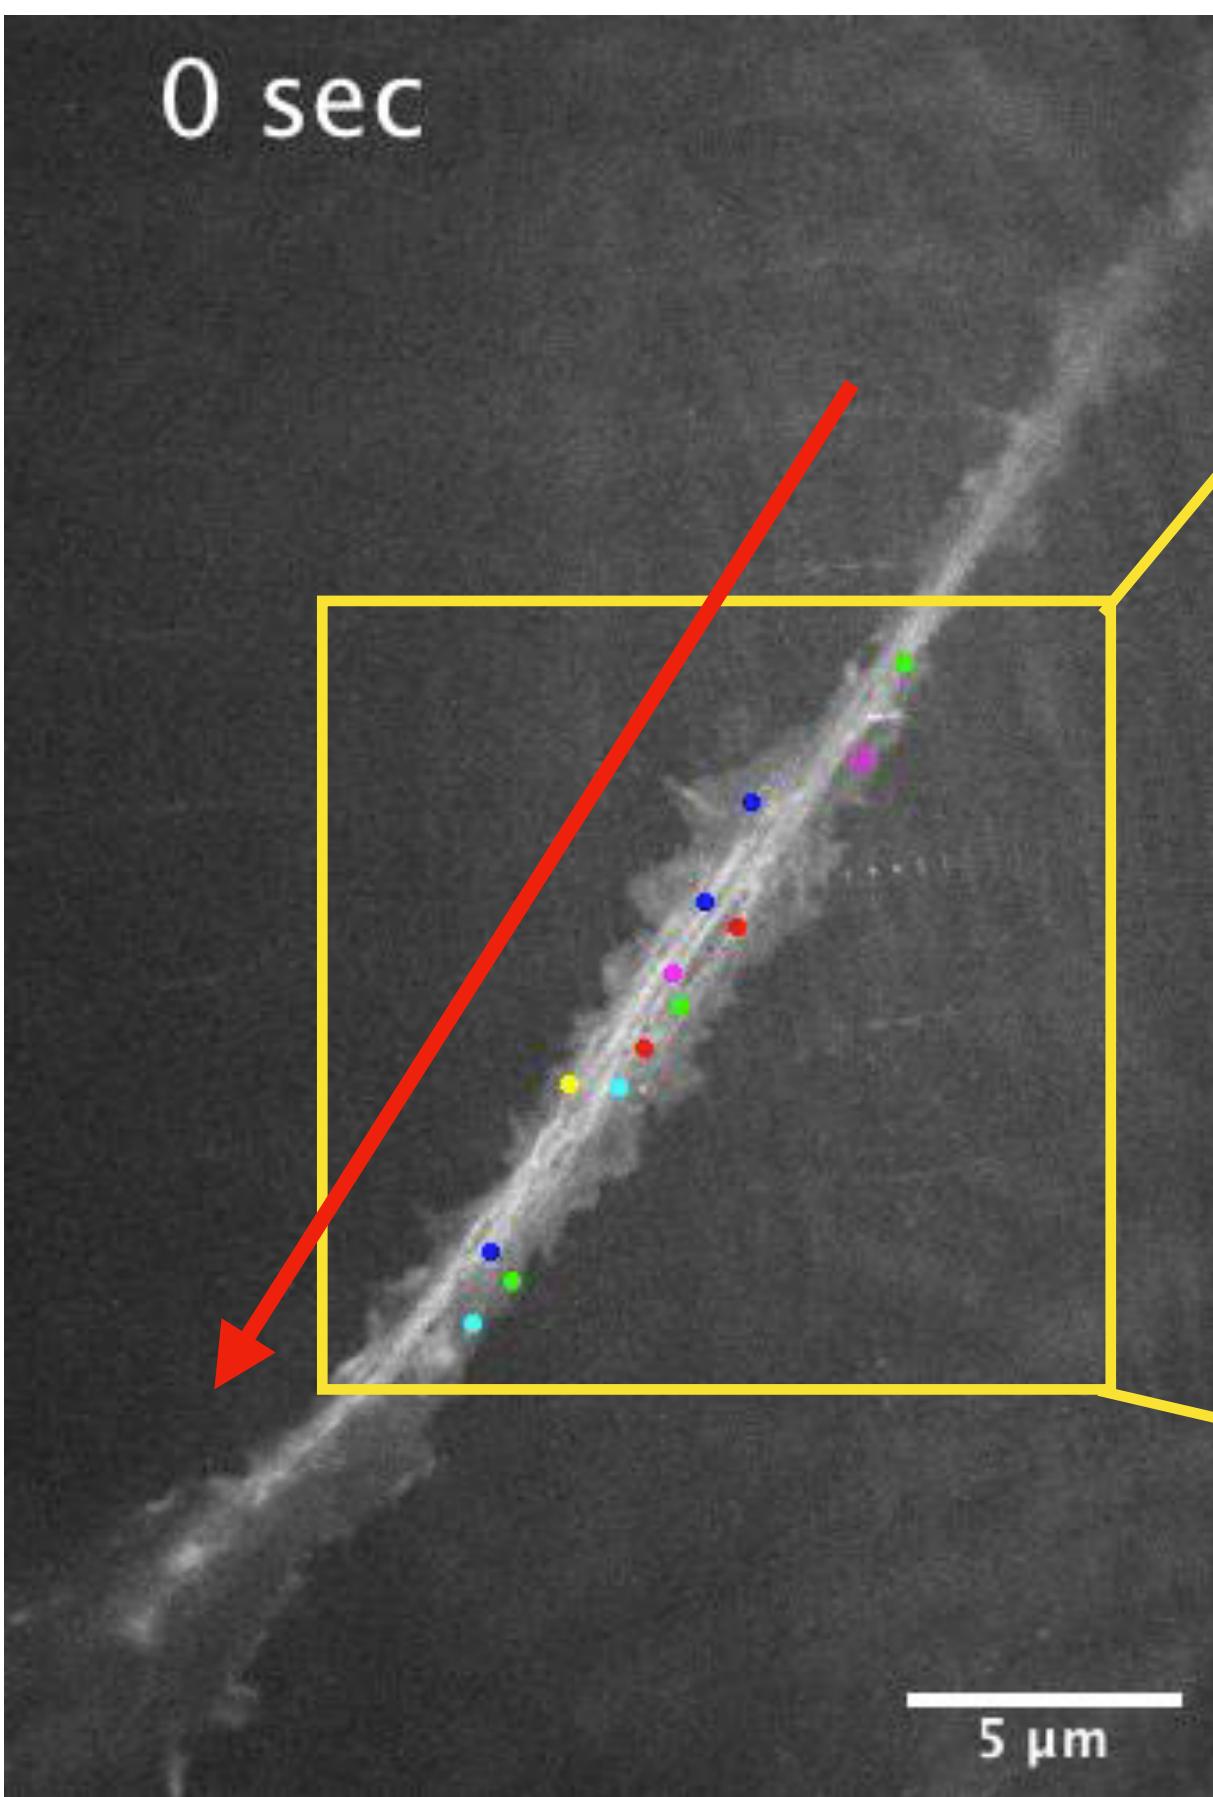
# 使用事例

タンパク質移動軌跡予測

# データ

## 神経系細胞軸索様構造内を移動する蛍光タンパク質

(学習データの一部)

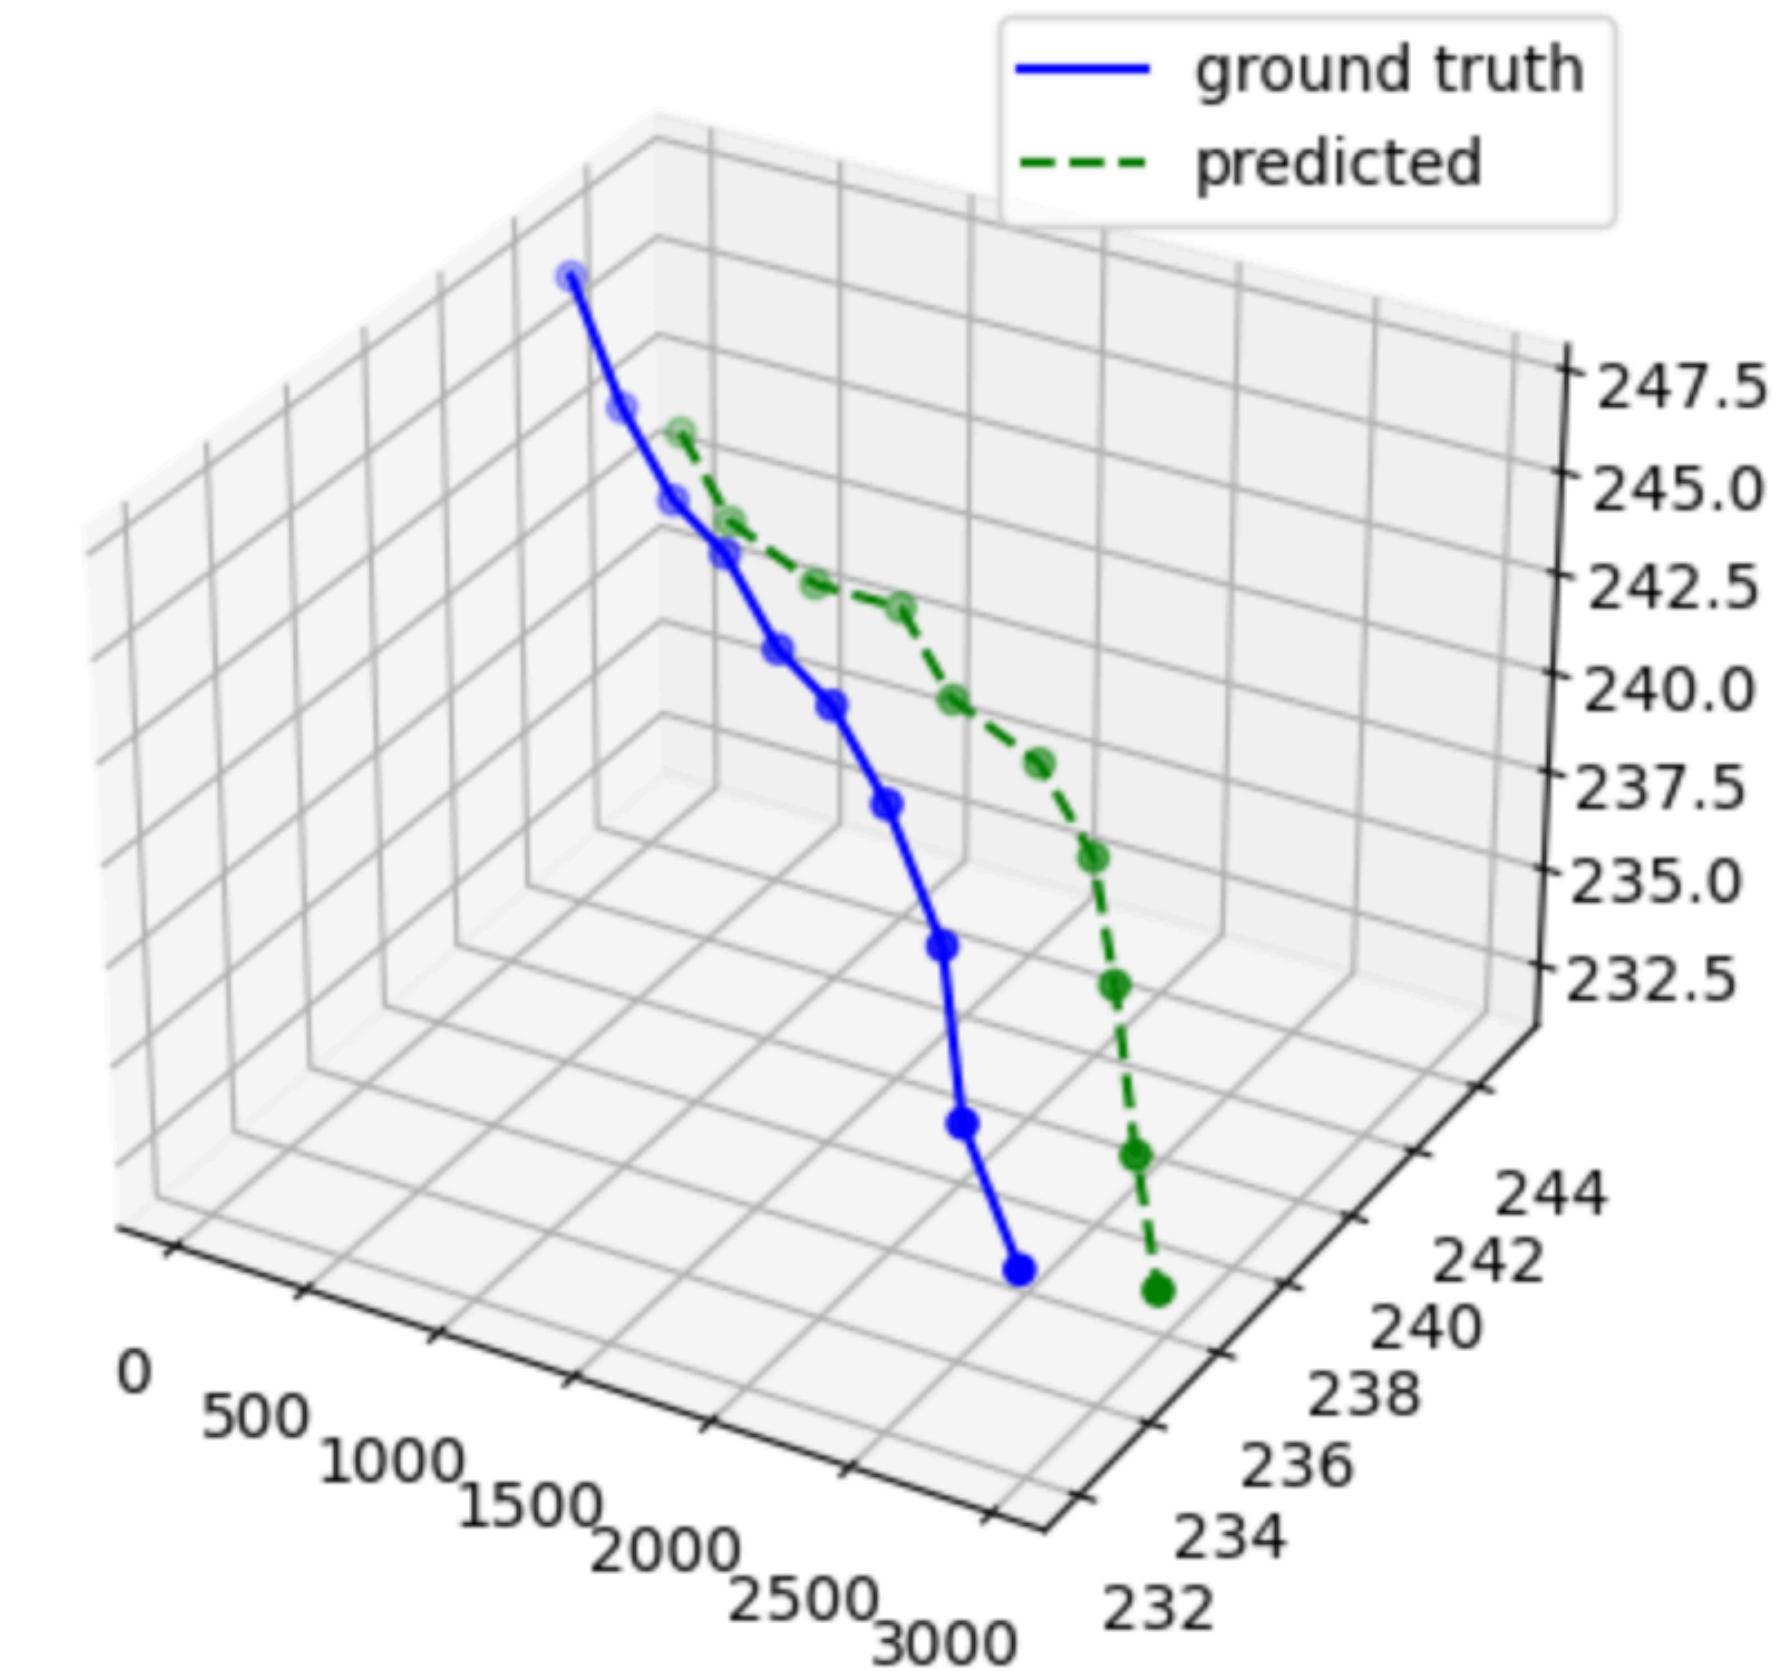


cometNo	time[msec]	X	Y	Velocity[nm/sec]	angle[degree]	normpix[μm]	Distance
1	0	242	247	0	63	1985	0
2	0	289	279	0	22	1795	0
4	0	193	180	0	90	1743	0
6	0	271	247	0	34	3335	0
1	330	241	245	144	45	1696	0.288
2	330	284	277	347	45	1628	0.695
4	330	193	179	65	63	1333	0.129
6	330	268	245	233	27	2845	0.465
1	660	240	244	91	0	1320	0.182
2	660	281	274	274	0	1702	0.547
4	660	192	177	144	27	1077	0.288
5	660	223	220	0	45	2221	0
6	660	266	244	144	63	2913	0.288
1	990	239	244	65	45	1145	0.129
2	990	279	274	129	0	1568	0.258
4	990	188	175	288	27	1187	0.577
5	990	220	217	274	90	2036	0.547
6	990	265	242	144	45	2833	0.288
1	1320	238	243	91	0	1244	0.182
2	1320	277	274	129	90	1287	0.258
4	1320	186	174	144	45	1285	0.288
5	1320	220	217	0	0	2763	0
6	1320	263	240	182	27	3024	0.365
8	1320	58	60	0	45	3141	0

# 結果

時刻, 座標, 速度, 角度 → 軌跡推定

cometNo	time[msec]	X	Y	Velocity[nm]	angle[degree]	normpix[μm]	Distance
1	0	242	247	0	63	1985	0
2	0	289	279	0	22	1795	0
4	0	193	180	0	90	1743	0
6	0	271	247	0	34	3335	0
1	330	241	245	144	45	1696	0.288
2	330	284	277	347	45	1628	0.695
4	330	193	179	65	63	1333	0.129
6	330	268	245	233	27	2845	0.465
1	660	240	244	91	0	1320	0.182
2	660	281	274	274	0	1702	0.547
4	660	192	177	144	27	1077	0.288
5	660	223	220	0	45	2221	0
6	660	266	244	144	63	2913	0.288
1	990	239	244	65	45	1145	0.129
2	990	279	274	129	0	1568	0.258
4	990	188	175	288	27	1187	0.577
5	990	220	217	274	90	2036	0.547
6	990	265	242	144	45	2833	0.288
1	1320	238	243	91	0	1244	0.182
2	1320	277	274	129	90	1287	0.258
4	1320	186	174	144	45	1285	0.288
5	1320	220	217	0	0	2763	0
6	1320	263	240	182	27	3024	0.365
8	1320	58	60	0	45	3141	0



# 使用事例

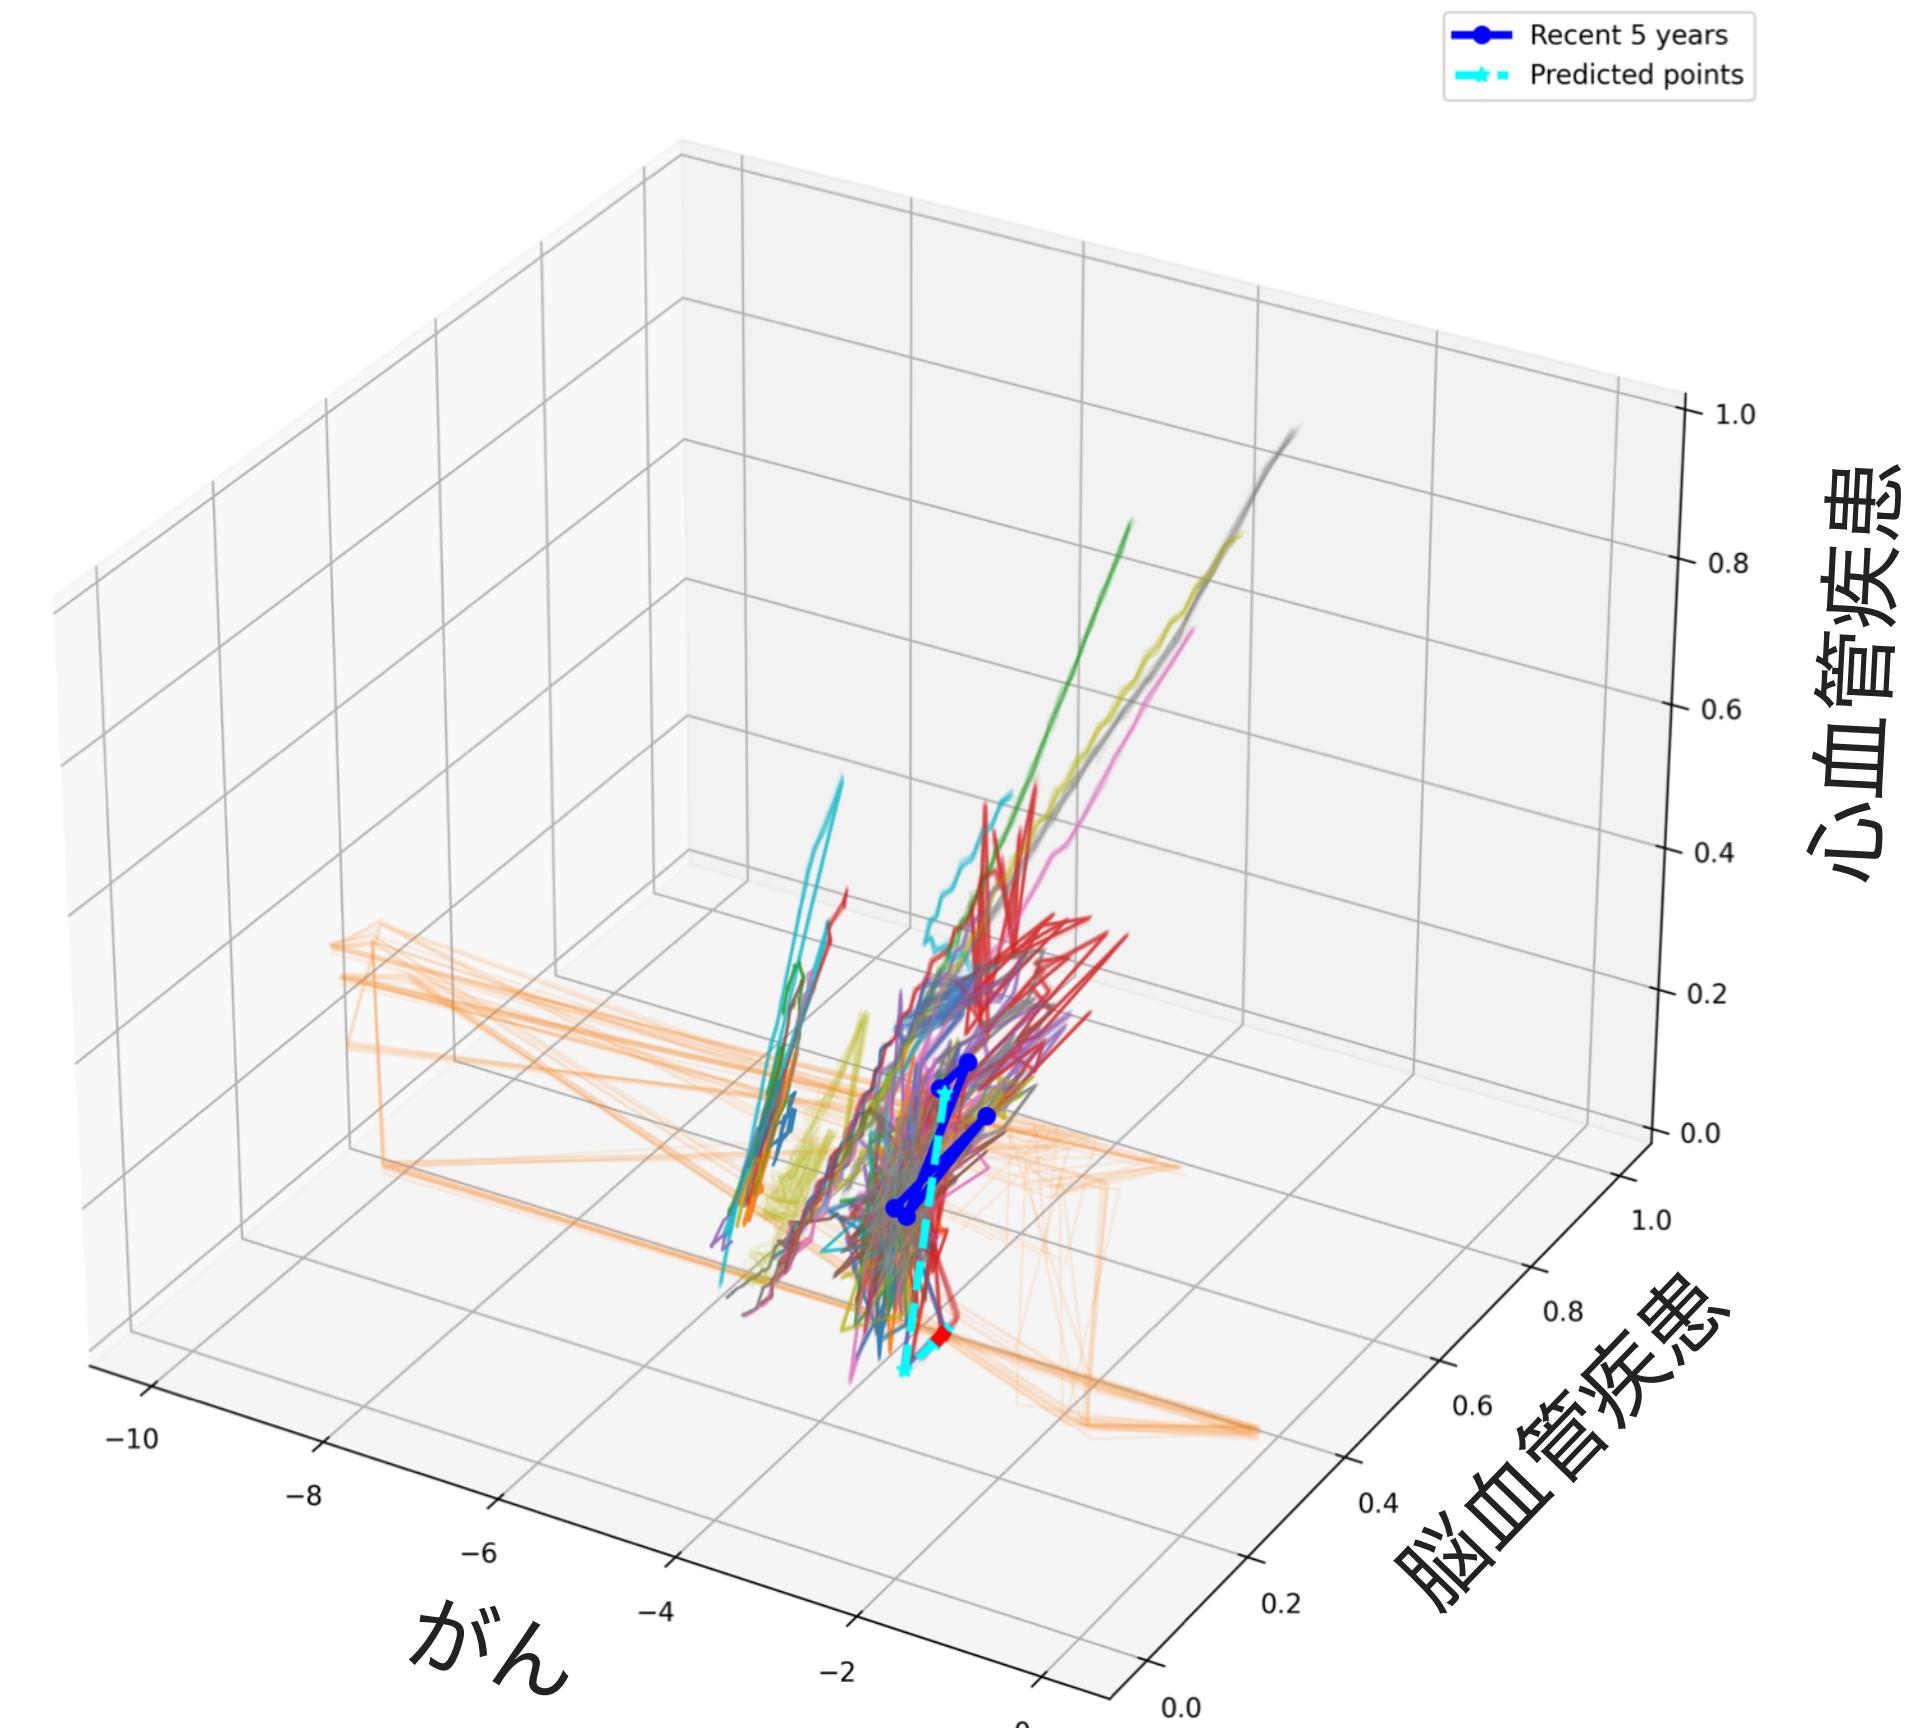
健康データ推移予測

(学習データの一部)

日本三大死因と結び  
つく血液検査データ

	A	B	C	D	E	F	G
1	mmsi	x1	CEA	TMAO	LOX-index	HbA1c	
2		x2		x3		x5	x6
3	1	3.75		6.2	1.05	4.6	1991
4	1	3.76		8.3	1.06	6.2	1992
5	1	3.75		6.5	0.95	5.5	1993
6	1	3.77		7.9	1.47	4.1	1994
7	1	3.75		7.2	1.59	4.8	1995
8	1	3.76		7.3	1.43	4.7	1996
9	1	3.75		6.4	0.06	4.2	1997
10	1	3.8		7.1	0.064	4.9	1998
11	1	3.75		7.4	0.06	4.6	1999
12	1	4		6.3	1.04	4.3	2000
13	1	4.22		7	1.37	5	2001
14	1	3.76		7.5	1.16	4.7	2002
15	1	3.88		6.6	1.29	4.4	2003
16	1	3.75		6.9	1.02	5.1	2004
17	1	4.28		7.6	1.69	4.8	2005
18	1	3.78		6.7	1.33	4.5	2006
19	1	3.76		6.8	1.75	5.2	2007
20	1	4.23		7.7	1.86	4.9	2008
21	1	4.1		6.8	2	4.6	2009
22	1	3.91		6.7	2.1	5.3	2010
23	1	4.27		7.8	2	5	2011
24	1	3.76		6.9	2.2	4.7	2012
25	1	3.81		6.6	2	5.4	2013
26	1	4.24		7.9	1.9	5.1	2014
27	1	3.75		7	2.1	4.8	2015
28	1	3.89		6.5	2	5.5	2016
29	1	4.26		8	1.9	5.2	2017

Future Prediction based on the Trained Data



(推定結果に基づくメンターシステム)

Recommendations based on x1/x2/x3 dominance:

† mmsi 1 (dominant: x3) -> Showing messages:

- 1 適度な運動：適度な運動は、体力の向上や筋力の維持に効果的です。また心臓の負担を減らすことにもつながります。
- 2 バランスの良い食事：1日の食事に「主食」「主菜」「副菜」がそろっていることが理想です。偏った食事にならないように心がけましょう。
- 3 節酒：お酒の飲みすぎは、体内の水分バランスを乱し血圧を上げ心臓の負担となります。適量の範囲内で楽しみましょう。
- 4 減塩：塩分の摂りすぎは高血圧やむくみの原因となり、心臓の負担になります。1日6g未満の摂取を目指しましょう。
- 5 便通を整える：便秘による排泄のいきみは血圧を上げ、心臓に負担をかけます。いきまず排便できるよう便通を整えましょう。
- 6 禁煙：タバコは血管を収縮させて血圧や脈拍を上げ、不整脈を引き起こす作用があるので禁煙をしましょう。
- 7 体に優しい入浴：急激な温度変化は血圧を上げる原因です。部屋と浴室の温度差をなくし、お湯の温度は40~41°Cに設定しましょう。入浴は10分以内が適切です。
- 8 感染症を予防：感染が起こると身体や心臓に負担がかかります。しっかりと予防して体調不良時は早めに医療機関を受診しましょう。
- 9 ストレス・過労をためない：ストレス・過労があると生活習慣が乱れます。規則正しい生活をして十分な睡眠や休息が大切です。

## 実用化に向けた課題

- ▶ 特にヒトの行動や健康に関する予測を行う場合、  
実データを入手できる必要がある。

## 想定される用途

- ▶ 動物・移動機器等の軌跡予測  
(社会的・経済的效果) 自然保護、機器故障リスクの低減
- ▶ 人間行動予測：犯罪、自殺等に対する実行前の介入  
(社会的・経済的效果) 被害回避・保険事業等のコスト削減
- ▶ 健康状態推移：現在の生活習慣を続けた場合に予測される死因などから、行動変容を促し、決定的な疾患の罹患を回避または遅らせる  
(社会的・経済的效果) 医療費の削減、新しい医療事業の創出
- ▶ 経済動向推移：具体的な時系列データから、将来の時系列推移を予測する。  
(社会的・経済的效果) 損失回避等

## 希望する連携体制

- ▶ **共同研究を希望します**

データを提供可能な企業様、団体様、  
リスク予測による事業運営管理を重要視している企業様、公官庁 等

- ▶ **共同研究により**

データ活用による予測可能項目の具体化、精度向上による実用化  
などの機会を提供可能

# 本技術に関する知的財産権

- ▶ 発明の名称 情報処理装置、情報処理システム、方法およびプログラム
- ▶ 出願番号 出願番号 特願2025-106097
- ▶ 出願人 学校法人幾徳学園
- ▶ 発明者 広井賀子、高橋昂也、座間快人、柴田陽平、遠藤 空

## お問い合わせ先

神奈川工科大学  
研究推進機構 研究支援部門

046 - 291 - 3304  
e-mail: [liaison@kait.jp](mailto:liaison@kait.jp)