arXiv:2302.06852v1 [cs.AI] 14 Feb 2023

利用人工智能助力气候临界点的科学发现

Jennifer Sleeman,[1] **David Chung,**[1] **Chace Ashcraft,**[1] **Jay Brett,**[1] **Anand Gnanadesikan,**[2] **Yannis Kevrekidis,**[2] **Marisa Hughes,**[1] **Thomas Haine,**[2] **Marie-AudePradal,**[2] **RenskeGelderloos,**[2] **Caroline Tang,**[3] **Anshu Saksena,**[1] **Larry White** [1]

[1] 约翰斯·霍普金斯大学应用物理实验室 11100 Johns Hopkins Road Laurel,Maryland 20723[2] 约翰斯·霍普金斯大学 3400 N. Charles St.Baltimore,MD 21218-2683[3] 杜克大学 Duke University Box 90586 Durham,NC27708{jennifer.sleeman,david.chung,chace.ashcraft, jay.brett,marisa.hughes,anshu.saksena,larry.white}@jhuapl.edu,{ gnanades,yannisk,thomas.haine,mpradal1,rgelder2}@jhu.edu,caroline.tang@duke.edu

摘要

我们提出一种混合式人工智能（AI）气候建模方法，借助一种面向气候的模拟方法，使气候建模人员能够开展科学发现。该方法基于深度神经网络与用于建模动力系统的数学方法这一创新组合。模拟以一种神经符号语言为基础，既能针对人工智能方法学到的内容进行问答，也提供了实现可解释性的途径。我们阐述了如何将这一方法应用于气候临界点的发现，尤其是大西洋经向翻转环流（AMOC）的崩溃。我们展示了该方法如何利用用于海洋相互作用的替代气候模型，高精度地预测 AMOC 崩溃。我们还展示了神经符号方法在自然语言问题与符号学习表示之间进行转换时的初步性能结果。我们的人工智能方法取得了令人鼓舞的早期成果，有望加速气候临界点相关研究，而这类研究若采用传统方式，在计算上可能难以实现。

引言

气候变化及其全球影响已不容忽视。极端事件日益频发，包括野火、热浪和极端洪水，因此，理解气候影响并寻找缓解之道已成为研究日益关注的重点。在这场讨论中，气候临界点越来越受到关注，因为这些临界点代表着环境中发生重大、突然且不可逆变化的状态，可能导致灾难性且加速的全球变化。令人担忧的是，人们尚未充分了解临界点的作用机制、发生可能性及潜在影响。政府间气候变化专门委员会在一份特别报告中总结了与气候临界点相关的一些主要因素（P¨ortner 等，2019），重点指出了陆地、海洋、粮食来源和人类健康面临的风险。Lenton 等（2019）最近发布的一份报告指出，目前有 15 个不同的临界点正处于“活跃”状态。例如，格陵兰冰盖正在以前所未有的速度融化，并且在变暖 1.5°C 时可能达到临界点（P¨ortner 等，2019；Lenton 等，2019）。

遗憾的是，研究临界点面临一项挑战：临界点是否会出现，取决于气候模型中的众多物理过程，而这些过程受制于约束不足的参数。在完整的全球环流模式中，这些参数所涵盖的整个状态空间都难以通过计算进行探索，而这类模式被用于气候预测。气候研究人员需要更好的方法，将注意力集中在那些既能高保真度模拟当今世界、又比当前一代模型更接近临界点的情景上。我们将以大西洋经向翻转环流（AMOC）的崩溃为例，展示如何运用人工智能助力发现临界点。

背景——AMOC

AMOC 是气候系统的重要组成部分，在热量和淡水的输送过程中发挥着关键作用（Buckley 和 Marshall，2016）。AMOC 常被称为海洋传送带，其环流模式包括温暖、含盐量高的上层海水流入北大西洋，在那里冷却后下沉至深海。它对调节地球气候有着重大影响（Zhang 等，2019），因此海表温度的微小变化也可能对全球气候产生重大影响。有证据表明，AMOC 已经减缓，但这一问题仍存在激烈争论。气候模型预测，AMOC 将在21 世纪减弱；一些海洋超高分辨率气候模型则表明，AMOC 可能会崩溃（Thornalley 等，2018；Jackson 和 Wood，2018）。

近期的文章和已发表论文推测，AMOC 的完全崩溃可能会对粮食不安全（Benton，2020年）、海平面上升（Bakker，2022年）以及与北极相关的影响（Liu 和 Fedorov，2022年）产生长期影响。

相关工作

长期以来，人们一直在讨论是否可以使用深度学习取代数值天气/气候模型（Schultz 等人（2021年）），但许多将深度学习应用于气候和天气相关具体问题的小规模成功案例已经展现出良好前景（Rasp、Pritchard 和 Gentine（2018年）；Reichstein 等人（2019年）；Singh 等人（2021年））。在本研究中，我们重点探讨了如何通过为气候模型运行推荐能够诱发临界转变的参数，利用深度学习发现气候临界点。由于使用传统方法对气候临界点进行建模面临计算方面的挑战，这一方向的探索相对较少。然而，已有相关工作探索利用深度学习检测早期预警信号，其中包括 Bury 等人（2021年）和 Deb 等人（2022年）的研究；两者均开发了使用基于动力学训练的长短期记忆网络（LSTM）来预测临界点的系统，通过寻找临界减速模式，重点关注临界点附近的行为。尽管这些方法与本文涉及的分岔研究相关，但我们关注的是一个更大的问题，即构建能够利用这些输出的混合人工智能气候模型。

针对 AMOC 这一具体主题，人们采用了各种简化动力学框架，以深入了解翻转环流的动力学及其敏感性（Johnson 等人（2019））。可以说，这些框架的发展始于 Stommel（1961）；该研究展示了 AMOC 的双稳态。随后，Gnanadesikan（1999）进一步加入了南大洋风和涡旋过程。Johnson、Marshall 和 Sproson（2007）将其扩展为包含温度和盐度的预报方程，Jones 和 Cessi（2016）则将太平洋盆地纳入其中。最后，Gnanadesikan、Kelson 和 Sten（2018a）在 Johnson、Marshall 和 Sproson（2007）模型的基础上进行了扩展，加入了侧向示踪剂混合。这些模型各自采用了不同的简化假设，但其动力学在 AMOC 开启态下都与观测结果相似。

混合人工智能气候建模方法

混合人工智能气候建模方法包含一种基于生成对抗网络（GAN）（Goodfellow 等，2014）的人工智能模拟，该模拟通过代理模型和分岔（Dijkstra，2019）方法探索不同的气候模型，以学习如何触发气候临界点情景。分岔方法可识别状态空间中状态发生突变的区域，即临界点。训练生成对抗网络需要与神经符号方法交互，如图1所示。神经符号方法学习如何将气候建模人员可能向模型提出的问题转化为生成对抗网络可运行的“程序”，并将生成对抗网络生成的“想象”模型转化为气候建模人员能够理解的自然语言问题。这种独特的学习方法具有两大优势：1）能够实现人类可理解的可解释性——这是科学研究人员的一项重要要求；2）能够引导气候研究人员前往搜索空间中临界点可能所在的大致区域，以便开展深入的气候建模。

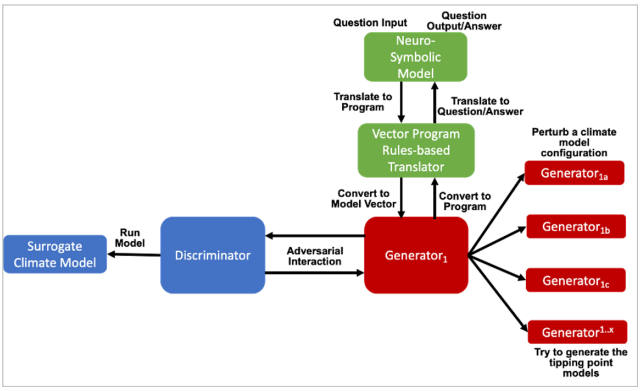

图1：学习将问题转换为程序，并将程序转换为问题。

我们的方法旨在实现普适性，因为这些问题基于气候领域的本体表征，而代理模型由气候建模人员提供。生成对抗网络和分岔方法并不专属于任何特定领域，可视为用于发现的一般性机制。

多生成器临界点生成对抗网络

基于以往使用多个生成器来稳定生成对抗网络训练的研究（Hoang等人，2018年），我们探索了利用多个生成器来挖掘状态空间中临界点出现的区域。多生成器临界点生成对抗网络（TIP-GAN）是一种新颖的对抗博弈，由一组生成器和一个判别器组成。生成器学习生成能够导致气候临界点的气候模型配置。判别器经过训练，用于判断是哪个生成器生成了模型配置，以及哪些模型配置会导致临界点。此设置采用定制的损失函数，其中包括学习预测是否会发生崩溃，以及学习识别生成模型配置的生成器。在此设置中，我们假设判别器会向替代气候模型询问临界点是否发生。在AMOC的研究中，所探讨的临界点是AMOC崩溃。

知识引导的神经符号学习

为支持混合人工智能气候建模，我们采用一组神经符号深度架构，在 TIP-GAN 学到的内容与气候建模人员提出的自然语言问题之间实现转换。在该系统中加入神经符号层后，我们便能够处理气候建模人员在科学探索过程中可能提出的复杂问题，并利用人工智能模拟环境来获得这些问题的答案，从而为气候建模人员指出搜索空间中值得进一步采用传统气候建模技术探索的区域。这为气候建模人员提供了一种途径，帮助他们发现气候临界点，而这

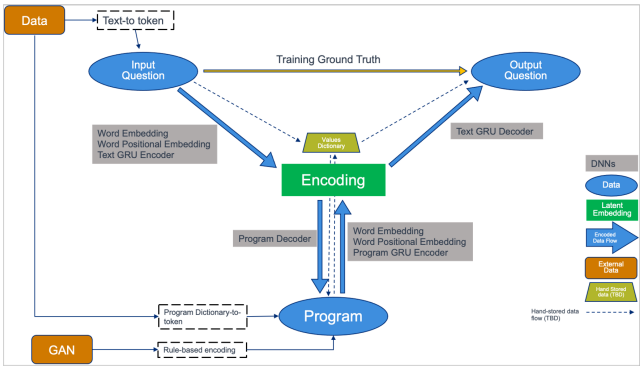

图 2：将问题转换为程序并将程序转换为问题。

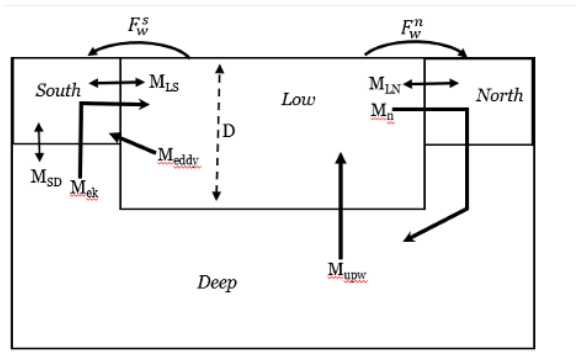

图 3：四箱模型。

些临界点若不采用穷举法，原本将无法发现。

在 Yi 等人（2019）的早期工作基础上，我们开发了一种翻译方法，将自然语言转换为程序式符号表示，以结构化地表示自然语言问题。所开发的程序用于捕捉与可能导致临界点出现的参数变化相关的问题。TIP-GAN 的生成器随机生成扰动后的模型配置，以触发气候临界点。这些生成器以程序的形式生成扰动，随后使用代理模型运行这些程序。借助经过训练的神经符号翻译架构，这些程序被翻译成自然语言问题，并附带由生成器通过与判别器交互而获得的答案。

在图 2 中，我们展示了所提出的神经符号翻译网络。该网络是一个三角模型，包括问题编码器、问题解码器、程序解码器和程序编码器。它具有双向性，能够将问题翻译为程序，也能将程序翻译为问题。各网络共享词嵌入和词位置嵌入，用于支持翻译。文本编码器网络将文本编码到这一共享空间中。解码器网络将编码解码为问题和程序。另一个编码器网络则将程序编码为文本。TIP-GAN 在由气候模型处理的向量层面运行，其经过扰动的模型配置从向量转换为程序，再由程序转换为自然形式的问题。

实验设置

本节将介绍本研究的实验设置，其中包括使用四箱模型（Gnanade- sikan、Kelson 和 Sten，2018年b）作为人工智能模拟中的代理模型。该四箱模型专门用于研究 AMOC 翻转环流的行为及其潜在的崩溃状态。我们对 TIP-GAN 进行了设置，使其扰动该四箱模型的参数。我们使用经过神经符号训练的翻译器，学习将由生成对抗网络的扰动生成的程序翻译为自然语言问题。这一过程在生成对抗网络训练期间进行。生成对抗网络训练完成后，我们将自然语言问题翻译为 TIP-GAN 可以在其潜在空间（训练后的模型）上运行的程序。

数据与代理模型

气候模型（例如模拟 AMOC 的模型）可以用简单的箱式模型近似表示（Levermann 和 F¨urst，2010）。箱式模型减少了系统参数的数量，同时力求保留表征 AMOC 临界点的基本动力学特征。我们采用了 Gnanadesikan、Kelson 和 Sten（2018b）的四箱模型（见图 3），其中包含深海箱、南大洋表层箱、低纬度表层箱以及北大西洋／北冰洋表层箱。该模型以 MATLAB 开发。AMOC 强度以质量输运变量 M_n 表示，它取决于北部低纬度箱与高纬度箱之间随时间变化的密度差，以及低纬度箱的深度 D_{low}。当质量从低纬度箱移出时，AMOC 处于“开启”状态；当质量回流至低纬度时，AMOC 则处于“关闭”状态。D_{low} 由质量平衡方程决定，该方程受到南大洋风驱上升流强度 M_{ek} 的影响，而风驱上升流会调节高密度深层水向低密度表层水的转化。大气淡水通量 F_w^n 和 F_w^s 会使高纬度箱的水变轻、低纬度箱的水变密，而热通量的作用则相反。在此报告的实验中，我们监测 M_n，同时手动扰动其他变量，使其在各自给定的范围内变化。该模型包含九个方程：模型随时间运行时，会预测四个箱中的温度和盐度，以及 D_{low}。AMOC 临界点以翻转输运 M_n 随淡水通量 F_w^n 变化的关系来绘制。随着气候变暖，预计 F_w^n 会增加，并缩小低纬度与高纬度之间的密度差。F_w^n 增加到何种程度会导致翻转环流崩溃（以及降低它能否使翻转环流重新启动），取决于 M_{ek} 的大小以及 D_{low} 的初始值，如图 4 所示。

我们编写了 Python 代码，用于复现四箱模型，并构建大型模型配置数据集，其中参数的初始值覆盖一系列

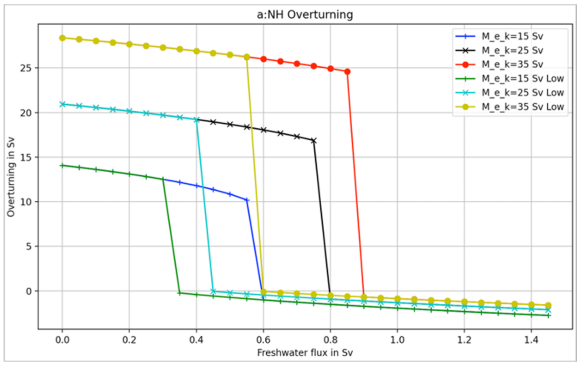

图 4：使用 Python 生成的工具，基于四箱模型创建机器学习数据集，并重现崩溃。随着南大洋上升流通量 M_{ek} be- 增大，翻转环流的幅度 M_n。使模型崩溃所需的 F_w^n 值会随着 D_{low} 或 M_{ek} 增大而增加。

参数名称	参数说明	范围
D_{low0}	低纬度初始跃层深度（米）	[100.0, 400.0]
M_{ek}	南大洋埃克曼通量（Sv）	[15, 35]
F_w^n	北部淡水通量（Sv）	[0.05, 1.55]

表 1：不确定性实验中受到扰动的参数。

可接受的取值范围，并标注结果，以指明 AMOC 的开启或关闭状态，供机器学习训练和评估使用。我们验证了，使用图 4 所示的 Python 工具，能够复现原始模型中相同的 AMOC 崩溃。

TIP-GAN

我们使用四箱模型数据进行了三项实验，以训练生成对抗网络。我们重点研究了表 1 所示的三个有界参数的扰动。每项实验都包含对其中一个变量进行扰动的生成器。其他所有变量均保持不变。完整的模型配置如图 5 所示。

我们使用权重相等的生成器和用于停机分类的交叉熵损失函数训练了 TIP-GAN。TIP-GAN 训练了约 250 个训练轮次，并针对每个 $n \in [1, 2, 4]$ 进行了实验，其中 $n =$ 代表生成器的数量。我们对数据进行增强，以便在三维空间中均匀采样。崩溃与未崩溃样本的分布为 743/413。随后，我们使用训练好的 TIP-GAN 生成样本，这些样本分别导致 AMOC 崩溃和未崩溃。

神经符号学习

我们设置了两组实验，其中一组使用 CLEVR 数据的一个小型子集，该子集包含分词后长度不超过 11 个词元的问题。训练数据集包含 59,307 个样本，测试数据集包含 12,698 个样本。程序序列最长可达 43 个词元。我们使用 Adam优化器训练模型，训练了两个训练轮次

- Perturbed variables (3):M_{ek}, D_{low0}, F_{wn}
  - Ranges:
    - $M_{ek} = [1.5 * 10^7, 3.5 * 10^7]$
    - $D_{low0} = [100, 400]$
    - $F_{wn} = [5.0 * 10^4, 1.55 * 10^6]$
- Constants:
  - $N = 4000$
  - $K_v = 10^{-5}$
  - $A_{GM} = 1000, A_{Redi} = 1000$
  - $M_{SD} = 1.5 * 10^7$
  - $T_{north0} = 2, T_{south0} = 4, T_{low0} = 17, T_{deep0} = 3$
  - $S_{north0} = 35, S_{south0} = 36, S_{low0} = 36, S_{deep0} = 34.5$
  - $F_{ws} = 1.0 * 10^6$
  - $\varepsilon = 0.00012$
  - $Area = 3.6 * 10^{14}, Area_{low} = 2.0 * 10^{14},$
  - $Area_s = 1.0 * 10^{14}, Area_n = 1.0 * 10^{14}, Area_n = 0.6 * 10^{14}$
  - $D_{high} = 100$
  - $t_{step_yrs} = 0.25$

图 5：TIP-GAN 中复现的四箱模型实验配置。

批量大小为 64，学习率为 0.001。我们通过评估文本到文本翻译、文本到程序翻译以及程序到文本翻译，来衡量双向方法的性能。还可以根据每个问题的长度进一步区分这三项任务，长度以词元数量衡量。由于每个问题都包含**句首**（**BOS**）和**句末**（**EOS**）词元，因此我们分析的最短序列由 7 个词元组成，最长序列则由 13 个词元组成。

我们还基于四箱模型中一组与 AMOC 崩溃相关的问题和程序，构建了一个自定义数据集，其中包含一个以自然语言表示的问题：“如果将参数 [x] 设为值 [y], AMOC 会在 [时间内崩溃吗t]? ”盒模型中有 20 多个参数可供考虑，它们的取值范围都很大。同样， t 的取值也可能无限延伸。最终的数据集包含 1,066 个问题—程序样本。我们使用在 CLEVR 数据上训练的双向模型，利用四箱模型生成的训练数据进行了迁移学习。该模型的程序形式如下：

$$ChangeSign(box_model(SetTo(...)), M_n)$$

其中省略号表示各种盒模型参数及其期望值。采用这种方法，我们通过使用迁移学习训练神经符号翻译网络，评估了翻译架构的性能。

早期结果

我们分享了 TIP-GAN 和神经符号学习器的早期实验结果。

TIP-GAN 结果

判别器对配置是否发生崩溃进行分类的早期表现如表2所示。

	精确率	召回率	F值
1 个生成器	1.0	1.0	1.0
2 个生成器	0.993	1.0	0.997
4 个生成器	0.929	1.0	0.963

表2：测试分类结果。

	生成器 1	生成器 2	生成器 3	生成器 4
1 个生成器	0.854			
2 个生成器	0.992	0.998		
4 个生成器	0.982	0.986	0.972	1

表3：导致崩溃的样本比例。

较高的 F值表明，判别器能够准确地将留出测试集中的 AMOC崩溃与未崩溃运行区分开来。增加生成器的数量会使性能略有下降。我们观察到，这是因为随着生成器数量增加，判别器倾向于将更大比例的真实样本错误地分类为合成样本。

训练生成对抗网络后，我们生成了 500 个样本。从这些样本中，我们观察到生成器倾向于探索关断区域，如表3所示。尽管训练数据存在一些轻微的不平衡，但这些结果令人信服。

神经符号结果

所有任务（文本到文本翻译、文本到程序翻译以及程序到文本翻译）的整体准确率（逐词计算）约为 70%。在这三项任务中，文本到文本翻译的准确率最高，而程序到文本翻译的准确率最低。

除了测量准确率外，我们还使用归一化的 Levenshtein 距离（Yujian 和 Bo，2007年）来衡量性能。对于准确率而言，如果翻译预测与真实值不完全一致，就会被视为错误。在某些情况下，预测结果只是在空格上有出入，或重复了一个词。另一些情况下，预测出错是因为它选择了一个与预期词语同义的词。Levenshtein 距离衡量的是将一个字符串转换为另一个字符串所需的替换次数。虽然它无法计入同义词，但对于了解预测结果与真实值的接近程度，它可以提供更准确的衡量。未来的测量将纳入基于语义相似度的指标。

如图6所示，Levenshtein 距离的表现与各项任务的准确率一致。对于11词元模型，文本到文本的表现最好，而程序到文本的表现最差。图7展示了11词元模型的归一化 Levenshtein 距离累积分布函数（CDF）。

对于使用迁移学习的四箱模型问题程序数据集，我们进行了过拟合评估，其中训练集和测试集相同。该模型的文本到文本准确率达到99.9%，文本到程序准确率达到

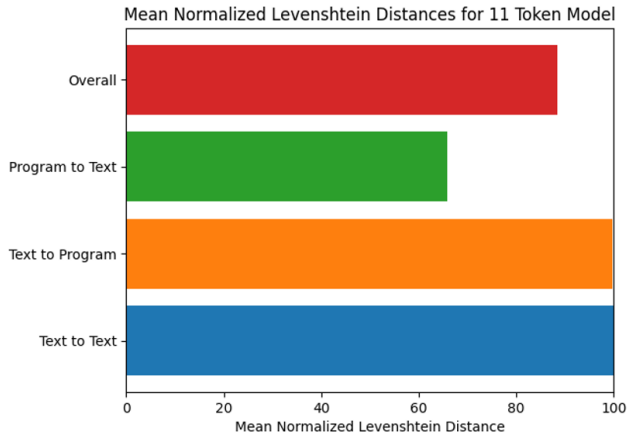

图6：使用莱文斯坦距离衡量11词元模型的神经符号翻译性能。

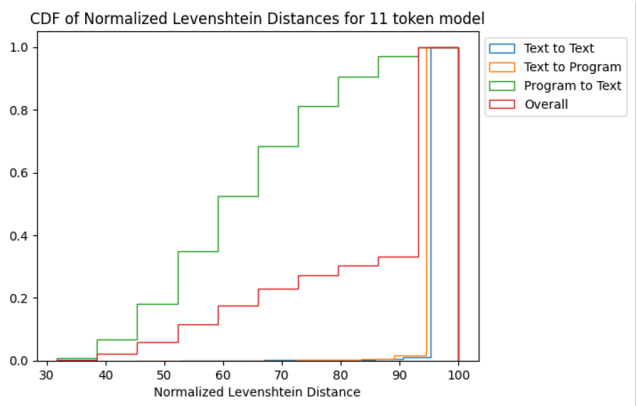

图7：11词元模型的归一化莱文斯坦距离累积分布函数（CDF）。

99.8%，程序到文本准确率达到100%。根据莱文斯坦距离计算的得分也相近。按序列长度划分的结果如图8所示。由于该数据集规模较小，在对这些数据进行训练集和测试集划分时，样本数量不足，无法实现泛化。

除了根据自然语言生成的问题外，我们还尝试翻译基于生成对抗网络（GAN）的输出。我们针对生成对抗网络在探索过程中改变的参数，构建了相应的程序。我们测试了三个参数与两个问题的每种组合，模型均以100%的准确率完成翻译。以下是一些程序示例：

- *ChangeSign(盒模型(SetTo(M ek,28496768)),M n)*
- *ChangeSign(盒模型(SetTo(Fwn,638758), SetTo(D low0,288)),M n)*

尽管针对 AMOC 的神经符号翻译所用的问题和程序结构较为简单，但这是首次尝试学习特定领域的问题到程序的翻译。这些结果，加上更全

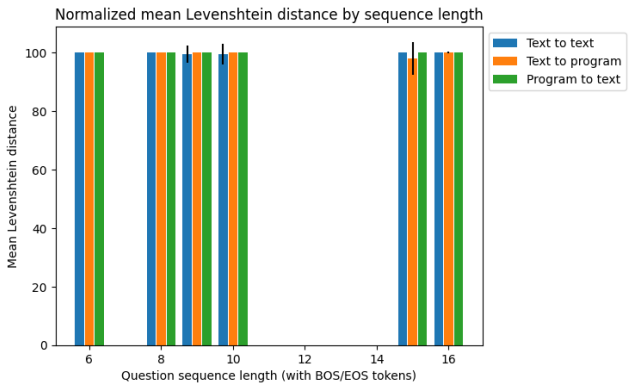

图8：AMOC临界点问题的翻译。

面的 CLEVR 结果，令人鼓舞。我们目前正在扩展问题和程序，使其更加贴近现实。例如，目前正在学习的问题之一是如果我将埃克曼通量增加一定数值，翻转环流会增加吗？。我们也在构建本体，以支持神经符号语言。

未来工作与结论

我们展示了混合人工智能气候建模方法的初步成果。新颖的生成对抗网络架构包含多个生成器，能够根据使用三种参数扰动从四箱模型生成的数据集，准确预测 AMOC 的崩溃与否。增加生成器的数量后发现，生成器倾向于关注可能发生崩溃的区域。我们目前致力于改进底层分岔方法，并使用经过校准、与四箱模型相匹配的大型全球模型，以便继续构建用于训练生成对抗网络的数据集。此外，初步结果表明，我们的神经符号翻译架构能够利用 CLEVR 数据集，在自然语言问题与程序之间进行准确转换。将其应用于一小组紧密耦合的 AMOC 问题时，我们证明迁移学习是针对 AMOC 特定问题训练架构的一种可行方案。不过，这些结果还处于非常初步的阶段，而且问题数量和程序种类都不足以实现良好的泛化。然而，我们的第二代数据集包含规模大得多的问题和程序集合。采用神经符号表示，一方面是为了让气候研究人员能够针对生成对抗网络所学到的内容提出问题，另一方面则是为了增强可解释性。未来的工作将纳入更多与 AMOC 相关的具体问题，并为神经符号语言设计更先进的语法。我们也已开始开发支撑这种语言的底层本体。

参考文献

Bakker, P. 2022年。《海洋对淡水的敏感性》。《自然》气候变化，12(5)：419–420。

Benton, T. G. 2020. 农业经济中的AMOC运行。《自然·食品》，1(1)：22–23。Buckley, M. W.; and Marshall, J. 2016. 大西洋经向翻转环流的观测、推断与机制：综述。《地球物理学综论》，54(1)：5–63。Bury, T. M.; Sujith, R.; Pavithran, I.; Scheffer, M.; Lenton, T. M.; Anand, M.; and Bauch, C. T. 2021. 利用深度学习识别临界点的早期预警信号。《美国国家科学院院刊》，118(39)：e2106140118。Deb, S.; Sidheekh, S.; Clements, C. F.; Krishnan, N. C.; and Dutta, P. S. 2022. 基于简单模型训练的机器学习方法可预测复杂自然系统中的临界转变。《英国皇家学会开放科学》，9(2)：211475。Dijkstra, H. A. 2019. 应用于气候模型的数值分岔方法：超越模拟的分析。《非线性地球物理过程》，26(4)：359–369。Gnanadesikan, A. 1999. 海洋密度跃层结构的简易预测模型。《科学》，283(5410)：2077–2079。Gnanadesikan, A.; Kelson, R.; and Sten, M. 2018a. 通量校正与翻转环流稳定性：来自动力箱式模型的见解。《气候杂志》，31(22)：9335–9350。Gnanadesikan, A.; Kelson, R.; and Sten, M. 2018b. 通量校正与翻转环流稳定性：来自动力箱式模型的见解。《气候杂志》，31(22)：9335–9350。Goodfellow, I.; Pouget-Abadie, J.; Mirza, M.; Xu, B.; Warde-Farley, D.; Ozair, S.; Courville, A.; and Bengio, Y. 2014. 生成对抗网络。神经信息处理系统进展，27。Hoang, Q.; Nguyen, T. D.; Le, T.; and Phung, D. 2018. MGAN：使用多个生成器训练生成对抗网络。载于国际学习表征会议。Jackson, L.; and Wood, R. 2018. 涡旋许可型全球气候模式中AMOC的滞后性与韧性。《地球物理研究快报》，45(16)：8547–8556。Johnson, H. L.; Cessi, P.; Marshall, D. P.; Schloesser, F.; and Spall, M. A. 2019. 理论对我们认识大西洋经向翻转环流的近期贡献。《地球物理研究杂志：海洋》，124(8)：5376–5399。J ohnson, H. L.; Marshall, D. P.; and Sproson, D. A. 2007. 调和机械驱动的经向翻转环流理论与温盐强迫及多重平衡。《气候动力学》，29(7)：821–836。Jones, C. S.; and Cessi, P. 2016. 经向翻转环流的跨海盆输送。《物理海洋学杂志》，46(4)：1157–1169。Lenton, T. M.; Rockstr¨om, J.; Gaffney, O.; Rahmstorf, S.; Richardson, K.; Steffen, W.; and Schellnhuber, H. J. 2019. 气候临界点——冒险押注其不会发生，风险过高。Levermann, A.; and F¨urst, J. J. 2010. 使用耦合气候模型审视大西洋密度跃层理论。《地球物理研究快报》，37(14)。

Liu, W.; and Fedorov, A. 2022. 变暖气候下北极海冰与大西洋经向翻转环流之间的相互作用。《气候动力学》，58(5)：1811–1827。P¨ortner, H.-O.; Roberts, D. C.; Masson-Delmotte, V.; Zhai, P.; Tignor, M.; Poloczanska, E.; and Weyer, N. 2019. 变化气候中的海洋与冰冻圈。*IPCC*海洋与冰冻圈特别报告。Rasp, S.; Pritchard, M. S.; and Gentine, P. 2018. 利用深度学习表征气候模型中的子网格过程。《美国国家科学院院刊》，115(39)：9684–9689。Reichstein, M.; Camps-Valls, G.; Stevens, B.; Jung, M.; Denzler, J.; Carvalhais, N.; et al. 2019. 深度学习与过程理解助力数据驱动的地球系统科学。《自然》，566(7743)：195–204。Schultz, M. G.; Betancourt, C.; Gong, B.; Kleinert, F.; Langguth, M.; Leufen, L. H.; Mozaffari, A.; and Stadtler, S. 2021. 深度学习能否胜过数值天气预报？《皇家学会哲学汇刊*A*辑》，379(2194)：20200097。Singh, M.; Kumar, B.; Rao, S.; Gill, S. S.; Chattopadhyay, R.; Nanjundiah, R. S.; and Niyogi, D. 2021. 利用深度学习改进数值天气预报系统中的全球降水预测。*arXiv*预印本 *arXiv:2106.12045*。Stommel, H. 1961. 具有两种稳定流动状态的热盐环流。《*Tellus*》，13(2)：224–230。Thornalley, D. J.; Oppo, D. W.; Ortega, P.; Robson, J. I.; Brierley, C. M.; Davis, R.; Hall, I. R.; Moffa-Sanchez, P.; Rose, N. L.; Spooner, P. T.; et al. 2018. 过去150年拉布拉多海对流和大西洋翻转环流异常减弱。《自然》，556(7700)：227–230。Yi, K.; Gan, C.; Li, Y.; Kohli, P.; Wu, J.; Torralba, A.; and Tenenbaum, J. B. 2019. Clevrer：用于视频表征与推理的碰撞事件。*arXiv*预印本 *arXiv:1910.01442*。Yujian, L.; and Bo, L. 2007. 一种归一化的Levenshtein距离度量。*IEEE*模式分析与机器智能汇刊，29(6)：1091–1095。Zhang, R.; Sutton, R.; Danabasoglu, G.; Kwon, Y.-O.; Marsh, R.; Yeager, S. G.; Amrhein, D. E.; and Little, C. M. 2019. 大西洋经向翻转环流在大西洋多年代际变率及相关气候影响中作用的综述。《地球物理学综论》，57(2)：316–375。

致谢

已获准公开发布；分发不受限制。本材料基于国防高级研究计划局（DARPA）根据编号为 HR00112290032 的协议资助的工作。