

# 自动编程：大型语言模型及其他

MICHAEL R. LYU, Chinese University of Hong Kong, Hong Kong, China

BAISHAKHI RAY, Columbia University, USA

ABHIK ROYCHOUDHURY, National University of Singapore, [Corresponding Author], Singapore

SHIN HWEI TAN, Concordia University, Canada

PATANAMON THONGTANUNAM, University of Melbourne, Australia

由于依赖于大型语言模型 (LLM) 的 GitHub Copilot 等工具的出现, 自动编程越来越受欢迎。同时, 由于对质量和信任的担忧, 自动生成的代码在部署过程中面临挑战。在本文中, 我们研究了一般意义上的自动化编码, 并研究了围绕代码质量、安全性和程序员责任相关问题的挑战。这些是组织在决定使用自动生成的代码时的关键问题。我们讨论了软件工程的进步, 如程序修复和分析, 如何实现自动编程。最后, 我们以前瞻性的观点结束, 重点关注不久的将来的编程环境, 程序员可能需要切换到不同的角色才能充分利用自动编程的力量。自动修复从 LLM 自动生成的程序, 可以帮助从 LLM 生成更高的保证代码, 以及保证的证据。

## 1 自动编程的挑战

在过去的 50 到 60 年里, 无论是在意图捕获 (捕获用户的愿望) 方面, 还是在生成正确的代码—方面, 编程任务都占据了计算机专业的大部分时间。在建模和系统设计方面取得了重大进展, 以支持准确的意图捕获, 从而导致形式规范的增长。然而, 尽管取得了所有进展, 但软件工程师不愿意编写正式的规范, 对于大型软件系统来说, 没有正式的意图描述—导致调试和修复错误的巨大困难。自动化程序修复领域在微观代码生成方面显示出前景。关键问题是如何信任自动生成的代码。

从大型语言模型 (LLM) 自动生成代码的最新发展使自动编码中的信任问题更加突出。这不仅引发了自动生成代码正确性的整体问题, 而且提出了我们何时可以开始信任自动生成的代码以将其集成到我们的代码库中。在过去的几十年里, 利基行业已经从模型中生成了代码, 但是没有从自然语言规范中自动生成代码被广泛使用的先例。在本文中, 我们将彻底讨论此类自动生成代码的信任问题。虽然本文的直接动机是研究大型语言模型 (LLM) 代码中的信任问题, 但我们在本文中更广泛地研究了自动化编程的主题。

我们注意到, 越来越多的组织正在转向自动生成代码, 即使除了大型语言模型的普及之外。最近在 Oracle CloudWorld 2023 [?] 上的主题演讲中提到, Oracle 正在考虑放弃用 Java 编写软件, 而是用一种称为 Apex 的语言自动为新软件项目生成代码。Apex 是一个著名的低代码应用程序平台, 用于从应用程序页面中组装应用程序。这种向低代码的转变带来了其他好处, 例如轻松实现软件项目的安全审计。总的来说, 我们注意到自动编程超越了大型语言模型的使用, 并且隐含地包括了低代码无代码应用程序开发增长的最新趋势。

由于最近对自动编程的兴趣, 与自动生成的代码相关的一系列问题受到了广泛的关注。除了正确性之外, 还存在对代码的安全性、隐私性和可解释性的担忧—尤其是当从大型语言模型生成时。务实地说, 当包含自动生成代码的软件项目失败时, 人们可能仍然担心“推卸责任”。为了理解潜在的问题, 我们可以在应用软件和系统软件之间的交互之间进行类比, 这导致了众所周知的应用程序兼容性 (通常被开发人员称为 appcompat) 问题 (例如, 参见 [?])。通常, 由于操作系统 (OS) 等系统软件版本更改, 在操作系统上运行的特定应用程序 (如 PDF 阅读器) 可能会失败。但是, 这不一定是由于操作系统本身。这可能是由于对应用程序和操作

---

Authors' addresses: Michael R. Lyu, lyu@cse.cuhk.edu.hk Chinese University of Hong Kong, Hong Kong, Hong Kong, China; Baishakhi Ray, ray@columbia.edu Columbia University, New York, USA; Abhik Roychoudhury, abhik@comp.nus.edu.sg National University of Singapore, [Corresponding Author], Singapore, Singapore; Shin Hwei Tan, shinhwei.tan@concordia.ca Concordia University, Montreal, Canada; Patanamon Thongtanunam, patanamon.t@unimelb.edu.au University of Melbourne, Melbourne, Australia.

系统之间期望的错误理解。同样，当自动生成的代码和手动编写的代码在软件项目中共存时，由于错误地理解了不同软件组件之间的期望，错误可能会悄然出现。

因此，在本文中，我们将研究当我们把自动生成的代码集成到软件项目中时，信任边界如何变化。研究界可能感兴趣的技术问题之一是将 LLM 生成的代码集成到软件项目中的可接受性标准。正如最近提出的 SWEbench [?] 中所阐述的那样，程序分析工具增强了 LLM 在自动化关键编程任务（如错误修复和功能添加）方面的能力也值得研究。通过系统地使用程序修复 [?]，从 LLM 自动生成的代码的最后一英里改进仍然是一个探索的可能性 [?]。这种倒数第二个自动修复策略可以帮助提供正确性的具体证据（例如通过精选测试），从而建立对接受 LLM 生成的代码进入代码存储库的信心。

我们还研究了 LLM 在自动化非代码工件和流程（如测试生成、代码审查和代码摘要）方面的影响。更重要的是，从人类与 LLM 交互的角度来看，我们试图在未来的日常编程中提供一种新兴的新前景。传统上，当正式规范不可用时，软件工程师会求助于程序理解或规范推理来理解复杂软件系统的功能。当软件系统不是作为整体工件构建的，而是通过不同团队的合作或通过开源贡献进行组装时，这种做法尤其重要。

我们注意到，传统的程序理解问题是由人类完成的，可能涉及使用分析/调试工具来理解复杂软件系统的工作。在 LLM 驱动的编程时代，我们可以假设一个新的理解问题 - 基于自然语言要求，LLM 由程序分析工具增强，可以自动执行大部分理解任务。在理解过程的不同阶段，可以有结构化的规定来咨询人类以消除需求的歧义。研究这种人类与 LLM 协作的机制，并为 LLM/分析器向人类程序员咨询提供足够的原语，可以为我们指明不久的将来的编程环境。我们还强调了自动生成的代码的自动程序修复的可能性，作为可信自动编程的灵活机制。这些可能会在 2030-35 年及以后的未来编程环境中发挥作用。

## 2 历史里程碑和文献综述

在本节中，我们将深入探讨自动编程的发展，确定历史里程碑并进行彻底的文献综述。具体来说，我们将首先介绍推动该领域向前发展的几个关键任务，包括代码生成、程序修复、软件测试和日志记录。此外，我们将重点介绍 LLM 在自动编程方面的最新进展。

### 2.1 代码生成

代码生成，也称为程序合成，是指根据用户意图自动生成软件代码。这种技术通过减少手动编码和加快软件开发生命周期来提高开发人员的工作效率。代码生成的早期研究主要集中在演绎和归纳程序综合上，它基于规范和/或输入输出对制作代码。随着深度学习技术的出现，基于自然语言的代码生成以通俗易懂的语言描述用户的意图变得越来越突出。此外，还有其他专注于基于图像和结构化数据生成代码的工作。在本文中，我们将主要介绍基于演绎、归纳和自然语言的代码生成方法。

· 演绎和归纳程序综合 演绎程序综合从高级描述中制作程序，涉及力学定理证明和形式化方法 [??]。详细规范的要求有助于减少逻辑错误。它在机器人 [?] 和软件工程 [?] 等领域具有广泛的应用。例如，STRIPS [?] 是解决机器人问题的自动计划器，而 PROW [?] 通过结合涉及定理证明和代码生成的两步过程，从谓词演算中的规范生成 LISP 代码。另一部作品 [?] 使用遗传编程方法自动演化出符合规范的程序。相反，归纳式程序综合或示例编程 (PBE) 直接从特定的输入输出对生成程序。这种方法比演绎综合更简单、更人性化，并且已经得到了广泛的研究。它使不熟悉编程的用户能够通过示例指导计算机。例如，FlashFill [?] 是现实世界上最受欢迎的程序综合应用程序之一，它从很少的输入输出示例中为 Excel 等电子表格生成程序。类似的方法 [?] 也用于为关系型数据库生成程序，用于模式重构。

· 基于自然语言的代码生成 现有的基于自然语言的代码生成主要采用深度学习技术，通常可分为三类：基于序列的、基于树的和预训练的模型方法。在基于序列的模型领域，生成过程采用序列到序列范式，并将此过程

视为机器翻译过程，以将自然语言描述转换为源代码。例如，Ling et al. [?] 采用具有结构化注意力机制的神经网络来处理用于代码生成的半结构化输入。对于基于树的模型，这些方法考虑了程序的固有结构性质，并将它们解析为树，例如抽象语法树（AST）。例如，Yin 等人 [?] 训练 LSTM 生成一系列树构建动作，然后根据这些动作构建 AST。Rabinovich 等人 [?] 提出了抽象语法网络，并直接生成了源代码的树结构。另一项工作 [?] 设计 Transformer 模块来对自然语言和之前生成的语法规则进行编码，然后预测序列中的后续语法规则。近年来，预训练模型 [??] 的出现，在该领域取得了显著的进步。这些模型在广泛的数据集上进行预训练，然后在与代码生成相关的数据集上进行微调。此外，一些研究从代码重用实践中汲取灵感，使用检索-增强生成来增强代码生成模型。Hayati et al. [?] 通过检索类似于输入的代码并从检索到的代码中复制 n-gram 操作来改进代码生成。Xu et al. [?] 介绍了 Stack Overflow 和 API 文档中的两个外部知识库，用于检索和提高模型性能。Parvez et al. [?] 通过将类似的代码片段与输入描述一起引入生成器并训练模型以有选择地合并可重用的代码来改进生成过程。

## 2.2 程序修复

最初引入的自动程序修复（APR）方法 [?] 用于自动修复程序错误并减少对密集手动调试的需求。在本文中，我们还将研究自动修复自动生成的代码的可能性。APR 利用自动化技术来分析错误代码并生成正确的补丁以解决已识别的问题。APR 技术的研究主要可分为三类：基于搜索的、基于约束的和基于学习的 [?]

· 基于搜索的程序修复 基于搜索的 APR 方法采用启发式算法在预定义的补丁空间中搜索正确的修复程序 [?]。这些方法使用启发式方法来识别潜在的错误位置并生成修复候选者。例如，GenProg [?] 使用扩展形式的遗传编程来生成程序变体，这些变体可以修复错误并保留所需的功能。RSRepair [?] 采用了 GenProg 中使用的突变技术，并使用随机搜索来生成修复补丁。ARJA [?] 将自动程序修复表述为多目标搜索问题，并使用 NSGA-II [?] 来寻找更简单的修复。基于搜索的 APR 的一个挑战是通过测试 [?] 来验证补丁的成本很高。为了提高效率，已经提出了各种策略，试图最大限度地减少候选补丁和用于验证的测试用例。例如，AE [?] 引入了 RepairStrat 和 TestStrat，它们利用等效的补丁来修剪语义上等效的补丁，并对补丁进行采样验证以降低成本。Relifix [?] 针对使用以前的程序版本和上下文修复运算符的回归错误修复。[?] 的工作重点是软件回归错误，并建议利用错误程序的先前版本。基于搜索的修复技术可能会因必须浏览较大的搜索空间而受到影响，为了缓解此问题，建议修复模板引导修复（例如 PAR [?] 的工作）。基于搜索的修复存在更严重的测试数据过拟合问题，即生成的修复可以通过给定的测试，但不能通过其他测试。程序修复中的过拟合问题，特别是基于搜索的程序修复，在基于约束的程序修复方法中已经提到过 [?] 通过符号分析构建给定测试的泛化来缓解这些问题。

· 基于约束的程序修复 基于约束的 APR 方法利用约束规范，通过将修复问题转换为约束求解器问题来指导修复。例如，SemFix [?] 通过创建修复约束来使用符号执行来修复单行错误。DirectFix [?] 通过约束求解和程序合成改进了补丁生成，扩展了修复多行 bug 的能力，但由于 maxSMT 求解开销而存在可伸缩性问题。为了克服这个问题，Angelix [?] 建议采用基于轻量级价值的规范（angelic forest）来获得更好的可扩展性。Nopol [?] 被提议使用 SMT 修复 if 条件错误。它使用值替换而不是符号执行。另一项名为 SPR 的工作执行枚举搜索，以找到在循环 [?] 的不同迭代中由布尔表达式返回的合适值。修复工具 Prophet [?] 是对 SPR 的改进，其中机器学习模型被用作对候选补丁进行排名的最后一步。

· 基于学习的程序修复 随着机器学习的出现，已经提出了许多方法，这些方法利用基于学习的模型来捕获程序语义以修复错误。早期基于深度学习的 APR 方法 [??] 利用神经模型来学习代码语义以帮助修复任务，而不是直接生成补丁。DeepRepair [?] 识别错误代码和潜在修复之间的相似性，以指导补丁生成。最近的方法 [???] 采用神经机器翻译（NMT）技术，使用编码器-解码器模型来理解错误代码的语义，并将错误代码转换为固定

代码。例如，CoCoNuT [?] 将代码标记成文本等序列，以将有缺陷的代码转换为正确的代码。DLFix [?] 利用抽象语法树和基于树的模型来捕获代码结构信息。CURE [?] 在基于 NMT 的 APR 中集成了预训练模型，并提出了一种代码感知搜索策略来查找可编译的补丁。与生成补丁相比，Recoder [?] 建议生成编辑，以保证补丁程序的语法正确性。最近的工作 RewardRepair [?] 通过使用程序执行信息训练模型来提高修复性能和补丁的成功编译率。

安全漏洞修复 程序修复技术在自动修复安全漏洞方面显示出前景。这对于从 LLM 自动生成的代码具有重大的前景和相关性，因为 LLM 生成的代码中的安全漏洞仍然是一个大问题。ExtractFix [?] 的工作使用地址清理器来提取防撞规范，然后使用符号推理通过修复增强的最弱前提条件计算生成补丁。这导致了一种完全自动化的内存错误漏洞修复方法。SenX [?] 的工作需要安全属性，然后使用这些属性自动生成漏洞补丁。最后但并非最不重要的一点是，Crashrepair [?] 的工作提出了一个很有前途的工作流程，其中通过灰盒模糊测试的漏洞检测和漏洞修复被融合到一个步骤中 - 优先考虑可以更好地区分候选补丁的测试。随着 LLM 自动生成的代码（可能充满安全漏洞）在未来变得司空见惯，这样的工作流可能会很有希望。

### 2.3 基于 LLM 的智能编程

在本节中，我们将首先详细介绍最近具有代表性的大型语言代码模型，然后介绍一些利用 LLM 来提升上述编程任务的作品。

**2.3.1 大型语言代码模型** 最近，预训练技术技术的出现极大地推动了自动编程的进步。预训练代码模型首先使用自监督学习任务在大规模未标记数据集上进行预训练，然后针对下游任务进行微调或提示。由于这个过程不需要人工注释，因此可以应用于大规模的未标记数据集，使模型能够获得大量的通用编程知识。最近的研究 [??] 表明，增加这些模型的大小可以显著提高它们的能力，一旦模型超过某个参数阈值，性能就会大幅提高。术语“大型语言模型”（LLM）已被提出，以根据其参数的范围来区分这些模型。在本节中，我们将详细介绍著名的大型语言代码模型，其大小从类似 Bert 的模型到像 ChatGPT 一样大的模型。

预训练代码模型的一个开创性工作 CodeBERT [?]，它是一个基于六种编程语言的纯编码器预训练模型，具有两个自监督任务，即掩码语言建模和替换令牌检测，明显优于以前的非预训练模型。另一个模型 CodeT5 [?] 是一个编码器-解码器预训练模型，遵循与 T5 相同的架构。它使用不同的特定于任务的前缀以序列到序列范式的形式制定所有任务，并在各种代码智能任务上取得了有希望的结果。CodeGPT [?] 是一个仅限解码器的模型，它在编程语言数据集上进行预训练，并且具有与 GPT-2 相同的架构。PLBART [?] 使用去噪序列到序列预训练来理解程序和生成。UniXCoder [?] 涉及多模态对比学习和跨模态生成目标，以学习代码片段的表示。最近，还有一些预训练的代码模型是为特定的编程任务而设计的，例如 CodeReviewer [?] 和 CoditT5 [?]

除了学术界的这些较小的预训练模型外，近年来业界还提出了许多具有更大尺寸的预训练代码模型。INCODER [?] 是一个对代码填充和合成都采用因果掩码训练目标的模型，有两个版本，参数分别为 1.3B 和 6.7B。CodeGen [?] 是一个具有 16B 以上参数的大型预训练模型，在多线程程序合成方面取得了可喜的结果。Codex [?] 是 OpenAI 提出的一个大型代码预训练模型，支持 Copilot 的服务。它擅长理解和生成代码，促进编程任务的自动化，并支持开发人员更有效地编写代码。除了 Codex，OpenAI 最近发布的模型，如 ChatGPT [?] 和 GPT-4 [?]，也都经过了源代码数据的预训练，展示了令人印象深刻的编程能力。AlphaCode [?] 经过训练，可以生成具有 715G 数据和 41B 参数的编程竞赛代码。它可以为看不见的编程问题提供新颖的解决方案，并在超过 5,000 名参与者的竞争性编程中胜过大约一半的开发人员。StarCoder [?] 是用于辅助编程的高级 LLM。它的基本版本在具有 15.5B 参数的 Stack 数据集上进行训练，并将输入大小增加到 8000 个令牌，以便能够处理更长的代码。Code Llama [?] 是由 Meta 开发的一系列大型代码语言模型，具有包括基础模型、Python 专用模型和指令跟踪模型在内的变体，参数范围从 7B 到 34B 不等。这些模型擅长处理高达 100k 代币的序列，并可在许

可下用于研究和商业用途。来自 Microsoft Research 的 Phi-1 [?] 是一个 1.3B 参数仅解码器转换器模型，在 7B 样本的精选数据集上进行训练，专为代码相关任务而设计。WizardCoder [?] 是基于 StarCoder 的开源 LLM，使用基于指令的数据集进行微调，以增强各种复杂程度的代码生成能力。DeepSeek Coder [?] 在代码和自然语言的混合语料库上进行训练。它专注于项目级代码的完成和填充，并在各种基准测试中以多种编程语言实现最先进的性能。Magicoder [?] 是最近的一项工作，它使用开源代码片段增强了合成指令数据进行训练。其主要目标是生成多样化、现实和可控的数据，解决 LLM 生成的合成数据中通常存在的偏见。

**2.3.2 利用 LLM 进行智能编程**。最近，除了训练基础 LLM 之外，还有很多工作专注于如何通过调整或提示它们进行自动编程来利用这些强大的 LLM [????]。在代码生成中，人们越来越关注利用思维链提示来生成更好的代码和解决更复杂的编程问题的方法。例如，TIP [?] 在进行详细编码任务之前，利用 LLM 来制定高级代码草图，从而提高生成代码的精度和可靠性。Dong et al. [?] 提出了一种自协作方法，通过雇用多个 LLM 作为不同的专家并使它们相互交互，在复杂的编码任务中推进 LLM。此外，除了在函数级生成代码外，最近的许多工作还探索将代码生成的范围扩展到类级 [?] 和存储库级 [?]。至于程序修复，也有很多研究利用 LLM 来修复软件错误。Xia et al. [?] 首先利用完形填空预测将 LLM 用于程序修复。Huang et al. [?] 研究了不同 LLM 和不同程序修复场景的影响。Peng et al. [?] 建议挖掘领域感知修复模板，并将它们合并到代码提示中，以修复 Python 类型错误。除了上述仅以一站式方式生成修复补丁的工作外。ChatRepair [?] 利用了 ChatGPT 等高级 LLM 的对话特性，并从之前的测试失败信息中学习，为模型提供即时反馈。借助来自测试用例的反馈信息，它可以生成更精确且上下文相关的修复程序。对于日志记录活动，Li et al. [?] 首次对用于日志记录语句生成的 LLM 进行了广泛的评估。此外，Sridhara 等人 [?] 探索 ChatGPT 在总结日志方面的熟练程度，取得了超越现有方法的可喜成果。为了提高 LLM 对日志解析的有效性，[?] 利用 LLM 和上下文学习 (ICL) 进行日志模板提取，另一项工作 [?] 改进了 ICL 的日志解析和解析缓存。在日志生成方面，最近的一项工作 [?] 建议将静态上下文合并到代码提示符中，并采用自我细化的方式进一步纠正以前的错误。LLM 还有利于从自然语言描述生成测试用例，从而增强软件开发人员和测试人员之间的协作。其中包括各种场景的自动化测试用例生成，例如增强测试的覆盖面 [??] 和可能的缺陷检测 [?]。Ryan et al. [?] 建议为 LLM 提供路径约束和代码上下文，以提高生成的测试用例的覆盖率。ChatUniTest [?] 提取基本信息，并为 LLM 创建自适应焦点上下文以生成测试。

### 3 程序修复和自动编码

程序综合将正式或半正式规范转换为表达式或代码片段。早在 [?] 年就对该地区进行了研究，最近的一项调查出现在 [?] 年。驱动程序综合的规范通常可以作为 (输入、输出) 示例的集合给出 - 为给定的输入提供预言机。程序修复 [?] 涉及对代码库的更正或纠正，以便它能够满足某些正确性标准。正确性标准可以根据整个软件系统需要通过的系统级测试用例给出。由于驱动这些过程的规范不完整，程序合成和修复都存在过拟合问题。如果规范是作为测试套件给出的，则过拟合可能以生成的代码的形式出现，过度拟合测试数据。举个简单的例子，让我们假设我们有 (输入、输出) 根据输入输出对的集合给出的规范，如下所示。

```
(input = 2, output = 4)
(input = 3, output = 9)

output = input + input;

if (input == 2) output = 4;
else if (input == 3) output = 9;

output = input * input;
```

这个简单的例子也清楚地表明了程序综合方法背后的“泛化”核心问题，特别是那些由输入输出示例驱动的方法。通过生成具有以下原理图的代码，始终可以合成完全适用于给定输入输出示例的代码

```
if (input == input1) return output1
else if (input == input2) return output2
else ...
```

概括给定的输入输出示例。虽然存在大量综合方法，但其中许多方法通常对表达式的搜索空间执行枚举搜索。枚举搜索可以通过选择出现在表达式中的运算符（基于组件的综合 [?]）或对通常通过语法捕获的表达式的语法的某些限制（语法引导的综合 [?]）来指导。无论使用何种技术机制进行综合，合成代码的过度拟合问题仍然存在。需要关注的是，合成的代码可能会返回给定输入输出示例的预期输出，但不会返回其他输入的预期输出。对于程序综合问题，这个问题有时仍然是隐含的 - 因为除了给定（输入、输出）示例中出现的输入之外，输入的预期输出甚至可能没有被完整记录。在程序修复问题中，给出了一个有缺陷的程序 - 过拟合的问题更加明确。在这里，固定程序可以通过用于指导维修的测试套件中的给定测试；同时，固定程序可能无法通过给定测试套件之外的测试。

现在，我们将程序修复作为一个领域进行讨论，并对潜在的挑战（例如过度拟合）进行一些技术上的一瞥。该处理来自第三作者 [?] 的开源未发表文章。

### 3.1 程序修复

过拟合问题在程序修复 [?] 领域得到了很好的研究和阐述。在提高人们对这个问题的认识的同时，这些工作也表达了超越测试不完整的问题。众所周知，任何作为（输入，预期输出）对集合的测试套件都是对预期程序行为的不完整规范。因此，使用测试套件  $T$  作为指导生成的修复可能无法通过  $T$  以外的测试。然而，对产生过拟合修复的担忧超出了  $T$  的不完整性。例如，如果某些测试的预言机说不应引发异常，则修复可能只是删除引发这些异常的代码并满足要求。

因此，自动化程序修复技术必须

- 对给定的测试套件  $T$  进行充分的泛化，以便修复不仅适用于  $T$
- 除了通过给定的测试外，还满足某些代码质量指标，以避免明显不可接受的修复，例如删除代码检查预言机。
- 为了确保补丁的质量，某些修复技术强调补丁的简洁性 - 这意味着对代码库的较小破坏在某种程度上“更好”。

现在，我们详细描述了一种具体的程序修复方法，该方法旨在通过对  $T$  中的给定测试进行符号分析来实现这些目标。在这里，对  $T$  中测试的测试执行进行符号分析，相当于计算一个泛化，我们也希望将其用于  $T$  之外的测试。通过对  $T$  中的测试进行符号分析，修复方法以修复约束的形式提取有关补丁代码的规范。这些修复约束可以用作通过搜索或程序合成生成补丁的指南。我们在这里向读者强调，这只是程序修复的一种方法，还有其他几种基于搜索和学习 [?] 的方法。提出这种基于约束的程序修复方法的一个动机是说明程序修复技术中自动生成的代码如何避免测试过度拟合问题的想法。从概念上讲，我们总是可以定义一个程序编辑域，然后在这个域中进行随机搜索，以找到通过给定测试的编辑。但是，这种搜索的输出将在很大程度上依赖于搜索启发式方法，并且很难对补丁的质量做出任何保证。因此，我们不是在补丁空间中随机搜索 - 而是展示了如何“指导”修复技术以产生更高质量的补丁。

我们在之前的工作中阐述的方法 [?]，修复技术是由修复约束“引导的，该约束是通过以一种新颖的方式在给定的测试套件  $T$  中象征性地执行测试而产生的。因此，主要的概念步骤是使用约束来减少可能补丁的搜

```

1 int tri_detect(int a, int b, int c) {
2   if (a <= 0 || b <= 0 || c <= 0)
3     return INVALID;
4   else if (a == b && b == c)
5     return EQUILATERAL;
6   else if (a == b || b == c)
7     return ISOSCELES;
8   else return SCALENE;
9 }

```

a	b	c	Output	Outcome
-1	1	1	INVALID	Pass
2	2	2	EQUILATERAL	Pass
2	2	3	ISOSCELES	Pass
2	3	2	SCALENE	Fail
3	2	2	ISOSCELES	Pass
2	3	4	SCALENE	Pass

Fig. 1. 来自 [?] 的三角形程序和程序随附的测试数据

索空间，而不是在补丁域中搜索。我们不详细讨论约束的计算，而是在高层次上概念化这种约束的存在如何帮助生成高质量的修复并避免补丁过拟合。

让我们考虑一个程序，它接受三角形的三条边，并确定由这三条边构造的三角形的类型。该程序可能类似于图 ?? 中的程序。该程序有几个错误。对于违反三角形不等式的三条边 - 它应该返回 *INVALID*，但它没有这样做。同样，等腰三角形的定义应该检查三条边中的任何两条是否相等。现在，如图 ?? 中的测试套件所示，让我们展示一个真实的测试套件，包括一个无效三角形的测试，一个等边三角形的测试，三个等腰三角形的测试（取决于哪两条边相等），以及一个斜角三角形的测试。基于需求的合理构建的测试套件确实具有这种性质。现在让我们假设，通过对通过和失败测试的控制流分析，将第 6 行推断为修复位置。修复本地化过程与基于搜索的 APR 技术的本地化过程相同。此处未显示修复本地化的确切过程。它可能涉及找出在未通过测试中出现频率明显高于通过测试的位置。确定定位位置后，该位置中的表达式将替换为未知变量或符号变量 X。

```

...
6   else if (X)
7     return ISOSCELES;
...

```

现在，需要找出有关 X 的属性，这将使程序通过给定的测试用例。

- 前两个测试甚至没有到达第 6 行。
- 在到达第 6 行的其余四个测试中，X 在第三个、第四个和第五个测试中应为真。此外，在第六个测试中，X 应该是假的。

获得上述要求，虽然直观地放在这里，但并不简单。它涉及对给定测试的测试执行的分析。从本质上讲，它相当于找到 X 的所需值（在本例中为布尔值，因为它表示布尔表达式），以便它可以通过测试。这是由修复约束捕获的。

如何在 X 上正式捕获这些要求或约束，它本质上是插入第 6 行的代码的占位符？理解此修复约束的正式方法是，未知 X 本质上是第 6 行中变量上的未知函数。因此，从本质上讲

$$X = f(a, b, c) \tag{1}$$

其中 f 是一个要合成的未知函数。有关函数 f 的信息由以下修复约束给出。

$$f(2, 2, 3) \wedge f(3, 2, 2) \wedge f(2, 3, 2) \wedge \neg f(2, 3, 4) \tag{2}$$

此修复约束可以馈送到程序合成引擎。合成引擎可以输入表达式中可能出现的成分：变量、常量和运算符。在这种情况下，变量是 a、b、c，常量是整数常量，运算符是关系运算符和逻辑运算符。有了这些成分和

提供的修复约束，基于组件的合成引擎 [?] 将产生正确的修复

$$f(a, b, c) = (a == b || b == c || a == c) \quad (3)$$

现在让我们介绍修复约束计算的形式化处理。应用统计故障定位 [?] 或其他离线分析技术来识别潜在的修复位置。这种离线分析可能涉及程序依赖性分析，或者只是对通过/失败测试的控制流分析。让我们来看看在统计故障定位的支持下，通过/失败测试的控制流分析将如何进行。在这种方法中，程序中  $s$  的每个语句都会根据通过/失败测试中  $s$  的发生率给出一个可疑性分数。基于约束的 APR 技术还依赖于故障定位来确定要修复的线路。一旦确定了固定线，就会构建修复约束。这是对表达式的约束，作为修复，要放在相应的行中。为了便于解释，我们假设修复是一个布尔表达式或算术表达式，它是赋值的右侧。如何构造修复约束？对于布尔表达式，可以简单地将表达式替换为新的符号变量  $X$  如下所示。

$$\text{if}(e) \rightarrow \text{if}(X) \quad (4)$$

对于算术表达式，引入了一个新的符号变量  $X$ ，如下所示。

$$y = e \rightarrow y = X \quad (5)$$

这里要注意的是， $y$  是一个程序变量， $e$  是由程序变量组成的表达式，而  $X$  是一个符号幽灵变量，由我们引入，用于自动程序修复。请注意，符号变量  $X$  是在被视为的修复位置引入的，现在让我们假设我们正在生成一个单行修复。

给定这样一个幽灵符号变量  $X$ ，修复约束根据  $X$  定义如下。对于给定的测试  $t$ ，到固定位置  $L$  的路径是具体的。从修复位置  $L$ ，有几种可能的路径，具体取决于  $X$  的值。因此，可以定义从  $L$  到  $\pi$  路径的路径条件以及沿路径的符号输出（以  $X$  表示）。让它们分别  $pc_\pi$  和  $out_\pi$ ，如图 ?? 所示。然后，路径  $\pi$  的约束可以表示为

$$pc_\pi \wedge out_\pi = oracle(t) \quad (6)$$

其中  $oracle(t)$  是测试用例  $t$  的预期输出。考虑到测试  $t$  执行  $L$  的各种路径，测试  $t$  通过的修复约束为

$$C_t \equiv \bigvee_{\pi} pc_\pi \wedge out_\pi = oracle(t) \quad (7)$$

总体修复约束是从所有给定测试中收集的修复约束的组合，因为修复的程序应通过所有给定的测试。换言之，修复约束  $C$  给出如下。

$$C \equiv \bigwedge_t C_t \quad (8)$$

### 3.2 基于语言模型的代码生成

近年来，设计基于人工智能的系统来自动解决编程任务引起了人们的广泛关注。其中最引人注目的是基于转换器的大规模语言模型，用于转换自然语言文本。Codex [?] 和 AlphaCode [?] 等大型语言模型，也成功地地为 Python、Java、C 等许多编程任务生成了代码。

用于修复语言模型生成的代码的程序修复。Codex 和 AlphaCode 已经显示出为许多编程任务生成正确解决方案的能力。然而，现有语言模型的成功率仍然很低，特别是对于复杂的编程任务。原因之一是语言模型缺乏对程序语义（例如，类型信息、运行时程序状态等）的认识，从而导致程序不正确。Codex 造成的很大一部分错误是语法错误或算法错位，即未编译的程序或算法不正确的程序。同时，一些错误需要小的更改，例如，更改






Fig. 2. 推断程序修复的规范（确认未发表的文章 [?]）

```

1 //A fancy string is a string where no three consecutive characters are equal.
2 Given a string s, delete the minimum possible number of characters from s to make it fancy.
3 Return the final string after the deletion. It can be shown that the answer will always be unique.
4 public String makeFancyString(String s) {
5     StringBuilder sb = new StringBuilder(s);
6     for (int i = 2; i < sb.length(); i++) {
7         if (sb.charAt(i) == sb.charAt(i-1) && sb.charAt(i) == sb.charAt(i-2)) {
8             sb.deleteCharAt(i);
9 -           i -= 2;
10 +          i -= 1;
11         }
12     }
13     return sb.toString();
14 }
    
```

Fig. 3. Codex 生成的 LeetCode 编程任务的程序。

运算符、修改表达式或更改语句。例如，图 ?? 显示了 Codex 为 LeetCode<sup>1</sup> 中的编程任务生成的示例程序。图 ?? 中的注释为程序说明，作为提示提供给食典，代码由食典自动生成。不幸的是，生成的程序有一个错误，导致程序在某些测试用例上失败。正确的解决方法是将第 9 行的语句  $i -= 2$  更改为  $i -= 1$ 。与语言模型相比，典型的修复工具通过根据给定的规范对程序语义进行推理来生成补丁。因此，修复技术有可能提高语言模型的成功率。在上面的示例中，一些现有的修复工具可以自动修复错误并使其通过所有测试用例。

程序修复的语言模型。语言模型也可用于修复软件错误。2022 年 3 月，发布了新版本的 Codex 编辑模式。Codex 编辑模式不仅可以将程序描述转换为程序<sup>2</sup>，还可以更改完整程序中的现有代码。这项新功能使使用 Codex 进行程序修复变得切实可行。Codex 编辑模式要求用户提供指导代码更改的说明，例如“修复第 2 行的错误”或“修复索引越界异常”。要修复错误，用户需要提供精确而清晰的说明。与基于学习的修复技术相比，基于大型语言模型的修复甚至可以在修复软件错误方面产生更好的性能。与现有的基于学习的修复（例如 SequenceR 和 Recoder）相比，Codex 在比 Recoder 大得多的数据集上进行训练，这有助于 Codex 学习更多的修复模式（比较结果见 [?]）。事实上，大型语言模型从大量现有的编程工件（包括代码、提交、注释等）中学习

<sup>1</sup><https://leetcode.com>

<sup>2</sup><https://openai.com/blog/gpt-3-edit-insert>

The given code snippet aims to remove characters from the string `s` to ensure no three consecutive characters are the same, thereby making it a "fancy string." However, there's an issue with the logic that might not always yield the correct result because of how the index `i` is managed after deletion. When you delete a character at index `i`, you do not need to decrement `i` by 2. Instead, you should decrement `i` by 1 to ensure the loop checks the next set of characters properly after a deletion.

Let's correct the code:

...

Here's the corrected version:

```
```java
public String makeFancyString(String s) {
    StringBuilder sb = new StringBuilder(s);
    for (int i = 2; i < sb.length(); i++) {
        if (sb.charAt(i) == sb.charAt(i-1) && sb.charAt(i) == sb.charAt(i-2)) {
            sb.deleteCharAt(i);
            i--; // Corrected to decrement i by 1 instead of 2
        }
    }
    return sb.toString();
}
```
...

```

Fig. 4. GPT-4 生成的修复示例 (缩写)

代码编辑模式。然而，修复自动生成的代码的任务仍然是一个挑战。最近的一项 [?] 研究表明，即使是简单的 *Leetcode* 问题，自动生成的代码也包含大量出现的“错位算法”。这种错位的算法构成了任务（或其子任务之一）的编程即使在算法级别上也是不正确的情况 - 因此需要完全重写代码。

. 使用最新的 LLM 提示一些最大的商业模型，如 *Gemini 1.5*、*GPT3.5* 和 *GPT4*，表明 *Codex* 生成的示例可以成功修复。不提供有关错误的信息（“请修复问题”）或仅提供错误行（“第 9 行有错误”）就足以获得补丁。此外，这些模型通常用于聊天，并生成人类可读的故障解释。图 ?? 是与 *OpenAI* 的 *GPT4* 模型进行此类交互的一个示例。这种模型的灵活性和功能是以（小）成本为代价的。如果提示不精确，模型可能会以意外格式响应，该格式无法用于自动修复程序。解决方案是描述模型应如何返回修复。一个示例修改是附加字符串“以三反引号返回修补的代码，仅此而已。随着模型规模和架构的进步，我们假设在未来几年中，大型商业模型的输出中通用语言的语法错误将减少。另一方面，由于自然语言本质上是模棱两可的，算法错位的问题仍然存在。当尝试为任务编写代码时，语言模型甚至在算法级别为某些子任务生成不正确的解决方案时，就会发生算法不一致 [?]。必须定义验证技术来缓解这种情况，并且必须提供模型响应的保证，以确保安全的代码集成。

. 语义方法评注 我们假设基于语言模型的代码生成以及基于语言模型的修复方法可以在未来发挥作用。同时，基于语言模型的修复方法与程序综合的关系在今天还不是很清楚。由于语义修复方法或基于约束的修复方法依赖于符号推理，因此未来存在将语义修复方法与基于语言模型的修复相结合的机会。在这里，我们需要注意我们使用什么样的后端进行基于约束的修复方法。我们注意到，程序合成后端可以被生成式 AI 模型取代

，而基于约束的修复可以提供一种系统的选择机制，用于在候选补丁中进行选择。这些工作流可以在将来进行检查。

#### 4 代码 LLM、软件质量和可信度

LLM 在自动编程中的应用显示出巨大的潜力。然而，这一进展带来了对这些模型生成的代码的可信度的担忧。例如，Jesse et al. [?] 发现代码 LLM 倾向于在代码库中引入简单的错误。估计 LLM 生成的代码的正确性变得有问题，尤其是在缺乏明确规范的情况下。事实上，LLM 生成的代码被发现包含安全漏洞的情况已经存在 [?]?。识别生成代码中的安全漏洞具有挑战性；开发人员可能不会详细审查每段代码，从而导致忽略的错误。LLM 还存在被不良行为者利用的风险，他们可能会篡改训练数据或操纵查询阶段使用的提示 [?]。LLM 的不透明性为分析和调试自动生成的代码的任务增加了另一层复杂性。驱动代码生成过程的复杂算法对开发人员来说并不完全透明，这使得他们很难掌握代码是如何存在的。在不断编辑代码的编程环境中，这个问题变得更加明显。集成开发环境 (IDE) 不仅可以高效生成代码，还可以提供清晰、非侵入式的解释，这一点至关重要。

##### 4.1 质量

为了系统地访问 LLM 自动生成的代码的软件质量，我们参考了 ISO/IEC 25010 指南。具体而言，ISO/IEC 25010 包括八个质量特征：(1) 功能适用性（即功能完整性、功能正确性和功能适用性）、(2) 性能效率、(3) 兼容性、(4) 可用性、(5) 可靠性、(6) 安全性、(7) 可维护性和 (8) 可移植性。总的来说，我们注意到最近的大多数研究都集中在研究功能适用性 [?]、可用性 [?]、可靠性 [?]?、安全性 [?] 和可维护性 [?]。从这些现有的研究中，我们得出了一些观察结果。首先，尽管 ChatGPT 等 LLM 最近取得了进步，但 LLM 仍然通常根据涵盖不同质量特征的最新评估生成低质量代码。其次，最近有一种研究趋势，即通过提出新的基准来涵盖更多的质量特征。例如，LMDefects [?] 包含 LLM 生成的功能不正确的程序，而最近提出的 NoFunEval benchmark [?] 用于评估非功能性需求，包括性能效率和安全性，并且对基准测试的研究注意到代码生成模型在非功能性需求中的低性能。第三，现有的研究依赖于人类编写代码的传统指标来获取自动生成代码的质量，并且这些传统指标仍然普遍适用于自动生成的代码。例如，之前的研究依靠静态分析工具来衡量可维护性 [?]，发现 ChatGPT 生成的代码存在可维护性问题。

[?]? 中出现了对代码的大型语言模型的实验评估，我们向读者推荐这些文章。评估包括从这些模型生成的代码的 Pass@1 率，即随机生成的代码示例通过所有给定单元测试的百分比。尽管最近对 LLM 生成的代码进行了许多研究，但我们注意到兼容性和可移植性等质量特征仍未得到充分探索。值得注意的是，现有的研究主要集中在与测试脚本生成相关的兼容性问题 [?] 和库相关问题 [?]。例如，最近有一种方法 [?] 提出增加对第三方库信息的感知，以提高生成代码的准确性和可重用性。由于增加对质量特征的认识在提高生成代码的质量方面显示出可喜的结果 [?]，一个可行的解决方案是将所有八个质量特征融合到 LLM 中，以提高生成代码的整体质量。但是，由于某些特性可能具有相互冲突的要求，因此一个可行的解决方案是指导 LLM 为不同的任务或应用程序确定某些质量特性的优先级。例如，由于额外的安全检查，安全代码的效率可能较低，因此在使用 LLM 为某些安全关键系统生成代码时，我们需要将安全性优先于性能效率进行编码。另一个可行的解决方案是定义一组针对各种质量特征的反模式 [?]，并将这些“坏补丁”编码到 LLM 中作为规则来提高生成的补丁的质量。

现在，我们将讨论更具体的问题，即 LLM 生成代码的可信度，以及如何信任将 LLM 生成的代码作为方法集成到我们的软件项目中。

| <i>Dimension</i>      | <i>Explanation</i>  |
|-----------------------|---|
| <i>Code-specific</i>  | <i>Security</i> <i>The code generated by LLMs should not have any security vulnerabilities.</i>                       |
|                       | <i>Reliability</i> <i>LLM generated code should be free of bugs.</i>  |
|                       | <i>Privacy</i> <i>Code LLMs will not leak unauthorized information.</i>   |
| <i>Model-specific</i> | <i>Explainability</i> <i>The model should be able to explain its rationale of producing certain code or decision.</i> |
|                       | <i>Robustness</i> <i>Code LLMs should maintain their performances under diverse noisy inputs.</i>                     |
|                       | <i>Consistency</i> <i>The models' outputs should be consistent and reproducible.</i>                                  |
|                       | <i>Fairness</i> <i>The model should not produce any code or decision exhibiting unethical or unfair behavior.</i>     |
|                       | <i>Ethics</i> <i>The model should not produce any code that intentionally causes harm to humanity.</i>                |

Table 1. 代码 LLM 的可信度属性

## 4.2 集成 LLM 生成代码的可信度

在不久的将来，确保 LLM 生成的代码以更高的可靠性无缝集成到现实世界的代码库中至关重要。当务之急是深入研究可信性的概念，特别是关于 LLM 生成的代码，并开发系统的方法来评估这种可信度。这种探索不仅将为模型的未来开发提供信息，还将塑造围绕模型的整个软件工程生态系统。通过理解和解决这些方面，我们可以在编码应用程序中更强大、更可靠地利用 LLM 铺平道路。

为此，我们回顾了现有的关于软件的可信度 [??] 和通用 LLM 的可信度 [?] 的文献。它们中没有一个单独足以达到我们的目的。根据这项研究，我们确定了评估代码 LLM 可信度所必需的八个主要属性，如表 ?? 中所述。这些属性可以大致分为两大类：(i) 与生成代码的属性相关的属性和 (ii) 与 LLM 广泛相关的属性，但它们可以用于代码 LLM。通过描述这些属性，将来必须建立一个全面的框架来评估 LLM 生成的代码的可信度，从而促进有关它们在实际应用程序中的使用的明智决策。在下一段中，我们将详细阐述这一点，特别是对于与代码相关的属性。

**安全。** 鉴于 LLM 是在大量开源代码语料库上训练的，预训练的代码语料库很可能包含包含安全漏洞的未经验证的代码。LLM 从这些易受攻击和可利用的例子中学习。这引发了对其生成的代码安全性的担忧。为了检查这个问题，Pearce 等人 [?] 有条不紊地检查了 GitHub Copilot 可能生成不安全代码的普遍性和情况。他们的分析涉及提示 Copilot 在与高风险网络安全漏洞相关的情况下生成代码，例如 MITRE 的“前 25 名”常见弱点枚举 (CWE) 列表中确定的漏洞。他们提出了 89 个独特的场景供 Copilot 处理，从而创建了 1,689 个程序。其中，大约有 40 个 % 被发现容易受到攻击。在其他独立研究中也发现了类似的观察结果 [??]。

**可靠性。** 代码 LLM 也往往会产生微妙的琐碎错误。事实上，Jesse et al. [?] 报告说，Codex 和其他 LLM 产生的逐字单语句错误频率是已知的两倍，用于逐字正确的代码。

**隐私。** 训练这些模型所需的大量代码数据成为障碍，因为公司对共享此类敏感数据犹豫不决是可以理解的。这种不情愿源于对专有信息潜在泄露的恐惧，包括姓名、电子邮件、密码等敏感信息 [?]。即使在考虑第三方基金会 LLM 时，公司仍然对向外部实体公开其代码持谨慎态度。在这种情况下，核心挑战之一围绕着利用 LLM 的能力，同时确保对专有信息的保护。在利用这些模型的强大功能完成软件工程任务和保护敏感数据之间取得平衡是研究界必须克服的重大障碍。随着 LLM 的使用变得越来越普遍，解决这些安全和隐私问题对于实现它们在软件工程领域的全部潜力至关重要。

可能的补救措施。将 LLM 生成的代码合并到项目中时，确保生成的代码没有明显的漏洞、错误或敏感信息泄露至关重要。将检查集成为自动化开发过程的一部分，对于维护软件的安全性和完整性将更加重要。为了实现这一目标，我们概述了一些策略：

- 首先，我们应该优先使用 LLM 的高质量训练数据。这需要在经过彻底审查且不存在已知漏洞或错误的数据集上训练模型。通过从干净可靠的数据开始，可以大大降低 LLM 生成有缺陷的代码的可能性。
- 此外，开发和使用轻量级静态分析工具有助于评估 LLM 生成的代码的质量。这些工具可以自动分析代码中的潜在漏洞、语法错误或其他问题，而无需执行代码。通过对 LLM 生成的代码运行静态分析，开发人员可以在将其集成到项目之前识别并解决任何问题。请注意，此类静态分析工具应该是轻量级和快速的，因为它们需要与 IDE 集成，并且不应显著阻碍开发人员的工作效率。静态分析应该能够分析部分程序，因为在 IDE 中生成的代码可能不完整。此外，通过自动程序修复，可以实现对 LLM 生成的代码的最后一英里改进。
- 为了提高 LLM 的智能性和可靠性，集成分步逻辑推理和自调试能力是关键。这使模型能够更好地掌握代码上下文，从而获得更准确的输出。自调试使 LLM 能够自动识别和修复错误，从而可能减少漏洞。这些增强功能增强了整体模型的可靠性，从而实现了更高质量、更安全的代码。
- 最后但并非最不重要的一点是，在大型语言模型的帮助下，存在生成经过验证的代码的诱人可能性。这可以采取多种形式，包括 (a) 从 LLM 生成代码并系统地改进它以生成经过验证的代码，或 (b) 使用经过验证的编程语言生成代码。我们注意到，这方面的一些努力已经开始，例如 [?] 报告 LLM 辅助合成经过验证的 Dafny 方法。

## 5 程序员与 LLM 的交互

鉴于人工智能，特别是大型语言模型 (LLM) 在自动编程方面的能力不断增强，基于 *code-fluent* 和 LLM 的工具的开发和集成激增，以充当编程助手。本部分概述了人类如何使用 AI 模型和大型语言模型 (LLM) 进行自动编程。具体来说，我们重点介绍了两种主要的常见交互模式：自动完成和提示。然后，我们将讨论程序员在利用 LLM 时面临的挑战。

### 5.1 交互模式

自动完成代码的自动完成是指将 AI 模型无缝集成到集成开发环境 (IDE) 中，而无需显式用户调用。一般来说，该工具会持续查询 AI 模型的代码建议，并及时将其显示给用户。用户通过选择和验证生成的建议来与 AI 模型互动。一个值得注意的例子是 *GitHub Copilot* [?]，它充当 AI 对程序员。*Copilot* 将前面的代码注释或源代码（例如，函数头或部分实现）作为输入。然后，它会提供建议，以便在用户暂停时完成剩余的实现。基于 AI 的自动完成的一个突出优势是它能够在一个建议中完成多行代码。与传统的完成工具相比，此功能显著提高了可用性，传统完成工具通常一次建议一个后续令牌。凭借这一优势，程序员还可以利用该工具作为互联网搜索 [?] 的替代品。这将减少认知负荷，因为程序员可以专注于 IDE 中的任务。

促使：程序员不依赖 AI 模型从代码注释或前面的源代码中推断任务，而是显式提供称为提示的专用输入，这些输入提供有关 LLM 应如何生成代码的说明。在程序员显式调用的交互模式下，程序员可以通过多种方式与 AI 模型进行交互。例如，*GenLine* [?] 提供了一种类似命令的交互风格，程序员在代码中指定一个命令（例如，“[[html: make an OK button]]”）来调用 AI 模型。或者，AI 模型可以充当 IDE 中的虚拟编码助手，允许程序员通过专用用户界面（如文本框 [?]）提供指令。通过这种交互，程序员可以提供结构化的指令（例如，思维链）作为提示。为了实现与 AI 模型的更多互动，程序员可以通过对话交互与 AI 模型互动，其中将之前的调用作为输入提示的附加上下文 [?]。开发人员使用这些工具的两个共同意图是 1) 加速和 2) 探索 [?]。在

加速模式下，程序员打算在脑海中考虑特定的编程任务时使用模型，并利用 AI 模型快速完成它们而不是打字。这些任务通常是小而合乎逻辑的子任务，需要更少的分析和更直接的编码，通常被视为乏味的工作。因此，为了在编码中利用 AI 模型的加速潜力，必须首先分析复杂任务并将其分解为更小的逻辑子任务。当程序员遇到新问题并且不确定如何分解任务时，就会出现探索模式。由于该工具可以接受代码注释，这是描述编程意图的自然文本来生成建议，因此程序员可以制作各种代码注释作为输入，然后探索多个实现建议。即使这些建议不完全正确，它们仍可能提供代码框架或起点 [?]。或者，在探索模式下，程序员使用基于 AI 的自动完成，而不是在 *Internet* 或 *StackOverflow* [?] 上搜索解决方案。

## 5.2 可用性挑战

虽然 LLM 在编码帮助方面取得了可喜的成果，为程序员提供了快速完成实现或为探索替代编程解决方案开辟新的途径，但当程序员与他们互动时，新的挑战就出现了。

第一个挑战在于精心设计输入。这些模型采用自然语言文本（例如，代码注释、提示），该文本将编程意图描述为输入。几项研究发现，人工智能模型对这些输入很敏感。稍有偏差就可能代码生成 [??] 明显不同。因此，程序员可能需要花时间探索、制作和修改输入，以生成正确的解决方案 [?]。有时，程序员必须为输入编写广泛而详细的描述，以使模型生成正确的解决方案。但是，与直接编写代码相比，此过程可能会花费更多时间 [?]。随着当前与 AI 模型的交互，创建有效提示的能力可能会成为编程中的一项重要技能。

第二个挑战围绕着理解和验证生成的代码。由于代码是由人工智能模型生成的，程序员的主要关注点已经从编程转移到评估建议。与传统的代码完成工具不同，传统的代码完成工具通常一次建议一个后续标记，而 LLM 可以生成一个冗长的标记序列来完成整个实现。因此，理解生成的代码并验证它是否符合编程意图可能需要大量的时间和认知负荷 [??]。[?] 发现，程序员倾向于寻找某些关键字或控制结构的存在，以快速验证建议。他们还可以执行代码或运行静态分析器来帮助验证建议。这也证明了我们的假设，即随着基于 LLM 的编码的到来，程序理解活动的性质可能会从手动代码理解转变为与 LLM 的迭代对话。这种迭代对话的第一步当然是对 LLM 生成的工件进行验证或消除歧义。

第三个挑战涉及调试和修复生成的代码。即使程序员可以理解生成的代码，它可能仍然需要修复或改进。但是，AI 模型可能会生成难以调试的复杂代码 [?]。程序员还需要考虑调试和修复生成的代码所需的时间；否则，他们可能会陷入耗时的调试过程 [?]。此外，在编程和调试模式之间不断切换上下文会给程序员带来巨大的心理要求。

## 5.3 用于维护 & 演进的 LLM

LLM 和基于 AI 的代码模型在自动编程中加速编码方面取得了重大进展。然而，至关重要的是，自动编程不仅专注于加速编码过程，还有助于软件维护并促进未来的发展。在为 LLM 开发方法以各种方式实现这一目标方面，已经投入了相当大的努力。在本节中，我们将讨论基于 AI 的方法，其中将源代码作为输入来生成非源代码工件，从而促进维护和演进。具体来说，我们重点关注与编程任务密切相关的三个主要任务，即代码汇总、代码变更汇总和代码审查。

**代码摘要** 代码摘要是指对所提供的代码片段的行为或目的进行摘要 [??]。当开发人员需要理解源代码时，这对他们来说特别有用，尤其是他们自己没有编写的代码。最近的 LLM 如 *GPT*、*Codex*、*CodeT5*、*CodeBERT*、*UniXCoder* 已经被研究用于代码汇总目的，因为这些模型是用多模态数据训练的 [?????]。因此，模型可以从源代码生成自然语言描述。一些研究还发现，当模型学习少样本（又称上下文学习）[??] 时，LLM 的性能可以得到提高。

· **代码更改摘要** 代码更改摘要是指汇总对代码库所做的代码更改（例如，提交或拉取请求）集合的过程。它涉及描述更改的概述和目的。此任务对开发人员至关重要，因为它可以帮助开发人员和其他利益相关者理解和跟踪代码的演变，提高代码的可理解性并促进调试过程。人工智能模型在生成描述 [??] 及其标题 [?] 方面都显示出有希望的结果。最近的研究也证明了 LLM（例如 *ChatGPT* 和 *GitHub Copilot* [?]）执行这些摘要任务的能力。

· **自动代码审查** 自动代码审查是指自动分析源代码并提供反馈以遵守编码标准和最佳实践的过程。重点可以涵盖代码质量的各个方面，例如代码样式、格式、性能、安全性和可维护性。自动化代码审查可以帮助开发人员在开发过程的早期发现问题，提高项目之间的代码一致性，并确保代码符合质量标准。最近的几项工作表明，代码审查的各种子任务是可以自动化的。这包括估计代码的质量 [?], 建议代码细化 [??], 生成评论评论 [??], 以及建议评论评论解决 [????]。虽然大多数用于代码审查的 AI 模型都是使用代码审查数据集训练的，但 *ChatGPT* 最近也显示出执行代码审查任务的可喜结果 [??]。

· **总结** 如前所述，研究表明，LLM 和 AI 模型可以帮助开发人员增强其人类编写代码的维护和演变。这为进一步改进自动编程技术铺平了新的方向，以生成满足维护和演进的 **非功能性质量** 的代码。例如，采用摘要技术自动描述生成代码的行为或目的，以帮助开发人员理解。此外，自动化代码审查技术有助于评估生成代码的质量。

## 6 自动生成编码的增强功能

LLM 不仅仅是编码助手；他们已经发展成为软件开发过程中的多功能合作伙伴。然而，尽管当前的 LLM 取得了重大进展，但它们完全集成到现实世界软件开发的旅程仍然充满挑战。增强的“最后一英里”对于在实际编程工作中无缝应用 LLM 至关重要。当我们探索 LLM 在自动编程中的未来发展时，我们的路线图涵盖了几个关键的发展领域，旨在释放这些智能系统的最大潜力。

· **多模态编码** 第一个领域是多模态编码。目前，代码 LLM 仅限于处理文本数据。但是，重要的是要认识到开发人员在开发过程中经常使用多模态数据。例如，从图像和视频生成软件 UI 需要 LLM 来分析视觉元素，理解其上下文，并将其转换为代码。此功能将使开发人员能够通过简单地提供可视化示例或原型来简化 UI 设计过程，并查询 LLM 以自动生成相应的代码。除了 UI 生成之外，多模态编码对软件开发还有更广泛的影响。考虑在需求和设计阶段使用数字、表格和流程图。配备多模态功能的 LLM 可以分析这些可视化表示并自动将它们转换为代码片段。此外，多模态编码将增强开发人员与人工智能模型之间的交互。开发人员可以通过使用多模态信息传达他们的想法和要求，从而促进与 AI 模型的更好协作。这将使交互更加自然和直观。在 LLM 中集成多模态编码有可能彻底改变软件开发过程。通过弥合可视化设计和代码实现之间的差距，LLM 可以显著提高生产力、代码质量和整体用户体验。

· **域** 其次，我们专注于大规模特定领域软件的赋能。在实际的开发和维护过程中，开发人员经常会遇到需要不同领域知识的大型项目。这需要自定义 LLM 来有效地管理和导航这些项目的复杂性。软件开发人员经常在特定的业务和技术领域（如电子商务和汽车）中应对复杂的软件开发挑战。为此类软件生成代码需要 AI 模型理解各种特定领域的概念。通过有效地将专业领域知识整合到 LLM 中，这些模型可以为开发人员提供更准确、更相关的支持。然而，处理大型项目带来了额外的挑战。当前上下文长度的限制使得 LLM 难以在大型软件项目中处理代码。即使上下文更长，在如此广泛的代码中理解和定位基本信息仍然是一个挑战 [?]。克服这些限制对于最大限度地发挥 LLM 的潜力并确保它们能够在实际使用中有效地满足复杂项目的需求至关重要。

. 知识更新 第三个战略领域涉及 LLM 的知识修复和更新能力，LLM 以其庞大的模型规模而闻名。例如，GPT-3 有 1.75 亿个参数，需要投资约 460 万美元进行训练，排放二氧化碳 552 吨，相当于 123 辆汽油动力乘用车行驶一年 [?] 的排放量。尽管如此，API 和编程的发展引入了源源不断的新知识，这对于为开发人员提供最新服务至关重要。此外，在代码存储库的维护过程中，预训练模型可能会无意中遇到以前未发现的错误信息。当训练代码包含未检测到的错误代码时，可能会发生这种情况，从而导致模型学习并可能合并不准确的知识。因此，生成的代码的质量也可能降低。因此，有效地编辑大型生成式人工智能模型的知识，而不是从头开始对这些模型进行定期重新训练，是一个重要且相对未开发的研究领域。

#### . 可靠性和程序修复

第四个重点领域是 LLM 生成的内容的质量和可靠性保证。尽管语言模型在代码生成方面非常熟练，但它们固有的黑盒性质引起了人们对生成代码正确性的担忧。对自动化编程的日益依赖凸显了对符合最高质量标准的输出的需求。这种追求不仅限于代码的准确性；它扩展到确保代码的可维护性、性能和可伸缩性。因此，提高代码的可靠性并创建自动化方法来评估和验证 LLM 生成的代码的质量至关重要。

总的来说，我们想做出以下两个预测：

- 使用自动程序修复技术对自动生成的代码进行最后一英里修复 [?] 有一个地方。
- 对自动生成的代码进行最后一英里修复的可能性仍然很诱人，这为“改进”代码的正确性提供了证据。这种正确性的证据可以以测试套件的形式出现，该测试套件是作为自动程序修复过程的副产品生成的。我们注意到，文献中作为自动程序修复的副产品生成的此类测试套件已被研究 [?]

. 安全 第五个改进领域涉及安全一致性，这是增强“最后一英里”的关键组成部分。当务之急是解决由于敏感或不安全内容的生成以及潜在的隐私风险而产生的信任问题。主要问题之一是生成包含漏洞的不安全代码，这可能导致软件崩溃。此外，在使用 LLM 生成的代码时，隐私保护至关重要。这些模型处理的大量数据和信息引发了对敏感用户数据的处理和存储的担忧。必须保护用户的隐私，以确保 LLM 不会无意中泄露或滥用个人信息。防止有害内容不仅是一项技术挑战，也是一个道德问题，确保这些强大的工具为软件开发社区做出积极贡献。因此，安全一致性的目标是以避免生成潜在有害或不安全内容的方式设计 LLM，从而提高 LLM 的可信度并促进其广泛采用。我们注意到，LLM 生成代码的可靠性和安全性对于第 ?? 节中研究的 LLM 输出的可信度至关重要。

. 数据 最后，由于不同的 LLM 使用不同的基准进行训练，因此准备高质量和多维数据集是公平评估自动生成的代码的关键。一般来说，当前的基准测试主要集中在突出 LLM 生成的代码的局限性上。我们预计 LLM 的下一个里程碑是生成更复杂的代码并解决更复杂的 GitHub 问题。随着 LLM 的发展和能力的提高，我们预见到更新的基准测试将侧重于更新的功能（例如，从多模态输入生成代码）或更新的领域（例如，自主设备）。

总之，在自动化编程中增强大型语言模型的路线图既雄心勃勃又至关重要。通过解决这六个关键观点，我们可以预见到一个未来，LLM 不仅能力更强，而且更符合软件开发的细微差别和不断变化的需求。

## 7 数据

我们对用于评估和研究代码生成模型的可用数据集进行了文献综述。具体来说，我们首先在谷歌学术搜索中使用关键字“代码生成数据集”进行初步搜索，我们选择了所有相关论文，然后使用反向滚雪球的方法跟踪其他相关工作。我们进一步过滤了收集多个数据集（例如，CodeXGLUE [? ]）的基准，因为它们的特征将被派生集合的原始数据集捕获。

表 ?? 显示了用于代码生成的现有数据集。在现有数据集中，HumanEval [?] 和 MBPP [?] 是最早衍生出较新基准的基准测试之一（例如，MultiPL-E [?] 通过支持更多编程语言来扩展 HumanEval 和 MBPP）。HumanEval



Table 2. 用于代码生成的数据集

| Benchmark                   | Natural Languages              | Programming Languages               | Supported Tasks                        | Size  | Test case  | Unique Features  |
|-----------------------------|--------------------------------|-------------------------------------|--|---|--|--|
| APPS [?] ]                  | English                        | Python                              | Text-code                              | 10,000 problems   | 130,000 total test cases                                   | One of the earlier dataset with crowd-sourced questions for program synthesis                    |
| HumanEval [?] ]             | English                        | Python                              | Text-code                              | 164 problems  | Average 7.7 tests per problem                              | Handwritten problems to evaluate functional correctness and measure problem-solving capabilities |
| MBPP [?] ]                  | English                        | Python                              | Text-code                              | 974 python functions  | 3 test cases for each problem                              | Measure the ability of these models to synthesize short Python programs                          |
| CONCODE [?] ]               | English                        | Java                                | Text-code                              | 100,000 (classes, NL, code) tuples                                  | No test  | Classes from diverse domains   |
| PandasEval, NumpyEval [?] ] | English                        | Python                              | Text-code                              | 101 programming problems  | 20 tests for each problem                                  | Library-oriented code generation   |
| MCoNaLa [?] ]               | Spanish, Japanese, and Russian | Python                              | Text-code                              | 896 NL-Code pairs   | No test  | Support several natural languages beyond English   |
| LLMDefects [?] ]            | English                        | Java                                | Text & code-code                       | 113 programming tasks from recent contests, 335 incorrect solutions | 1-3 public tests for each problem                          | Contains mistakes in code generated by LLMs.   |
| ClassEval [?] ]             | English                        | Python                              | Text-code                              | 100 tasks   | Contain method-level and class-level tests                 | Class-level code generation  |
| AixBench [?] ]              | English, Chinese               | Java                                | Text-code                              | 175 samples for automated Test, 161 NL Task Description             | Contain hand-crafted tests                                 | Contain hand-crafted automated test cases  |
| MultiPL-E [?] ]             | English                        | 19 languages (e.g., Julia, Swift)   | Text-code                              | 161 problems from HumanEval [?] ], 974 from MBPP [?] ]              | Use tests from prior benchmarks [?] ]                      | Extend HumanEval [?] ] and MBPP [?] ] to 18 languages by translating programs and unit tests     |
| SWE-Bench [?] ]             | English                        | Python                              | Text & code-code                       | 2294 problems from 12 projects                                      | Average 120.8 total tests for each problem                 | Evaluate the ability to resolve real-world GitHub  |
| CodeScope [?] ]             | English                        | 43 languages                        | 8 tasks                                | 200-5,382 samples for each task                                     | Contain tests for some tasks                               | Evaluate generated code on difficulty, efficiency, and length                                    |
| NoFunEval [?] ]             | English                        | Python, Java, C, JavaScript, Kotlin | Text & code-code, classify correctness | 47-397 samples for each task  | No test  | Evaluate non-functional requirements (latency, security, efficiency)                             |
| LiveCodeBench [?] ]         | English                        | Python                              | Text & code-code                       | Collect new problems over time                                      | Use tests from programming problems or LLM-generated tests | Mitigate contamination issues by crawling new problems   |

基准测试包含手动编写的问题，其中 OpenAI Codex 模型已被评估。最近，有人提出 SWE-Bench [?] ] 来评估 LLM 是否可以用于自动解决现实世界的 GitHub 问题。根据在这些数据集中进行的研究报告的结果，我们注意到这些数据集中的大多数都显示了现有 LLM 在解决与代码相关的任务方面的局限性，突出了对可以进一步改进这




Fig. 5. DALL-E 捕获的程序员角色的演变: 程序员角色 (a) 作为代码编写者和设计者而不是代码编写者, (b) 作为质量保证专家而不是代码编写者。

些 LLM 的革命性技术的需求。例如, 对 SWE-Bench [?] 的评估表明, 他们微调的模型 SWE-Llama 只能解决最简单的 GitHub 问题。我们注意到, SWE-bench 正在获得从业者的关注, 他们试图在单个提示之外实现软件工程自动化。最近一个名为 Devin [?] 的创业公司报告说, SWEbench 在自主修复 GitHub 问题 (错误修复和功能添加) 方面具有合理的效率。开源代理 AutoCodeRover [?] 报告了比 Devin 更高的效率, 因为它考虑了本地化和修复中的代码结构。

一般来说, 我们观察到大多数现有的数据集需要几个软件工件: (1) 自然语言描述 (主要以英语为中心), (2) 用常用的编程语言编写的代码 (主要集中在 Python 和 Java), (3) 测试用例来验证生成的程序的正确性。如“支持的任务”列所示, 大多数现有数据集都支持文本到代码任务 (从自然语言描述生成代码)。

虽然有些基准测试 [??] 使用真值程序和生成程序之间的文本相似性来验证正确性, 但表 ?? 的“测试用例”列表明, 大多数基准测试都依赖于测试用例来验证生成程序的正确性。这些测试用例要么是 (1) 手工制作的, 要么是 (2) 从其他编程语言翻译而来的。总体而言, 我们观察到测试驱动的方法已被广泛用于验证生成程序的正确性。这表明提高用于指导代码生成的测试套件质量的重要性。基于“独特功能”一栏, 我们观察到最近的数据集通常会增加一个新的维度来研究 LLM 在特定条件下的有效性 (例如, 支持不同的自然语言集 [?], 研究自动生成的代码中的缺陷 [?])。研究代码生成模型的不同视角有助于指出 LLM 的局限性和潜在偏差。由于大多数 LLM 都是使用开源存储库中的程序进行训练的, 因此用于评估 LLM 代码生成有效性的数据集的主要挑战之一是数据泄露问题 (例如, 过度拟合训练数据)。现有的数据集通常通过使用 (1) 手写 [?] 或众包问题 [?], 或 (2) 最近发布的问题 [?] 来解决这个问题。最近, LiveCodeBench [?] 被提出通过不断从编程竞赛平台 (LEETCODE, ATCODER 和 CODEFORCES) 中抓取新问题来缓解数据泄露 (本文中称为污染问题)。

## 8 未来: 2030-35 年及以后的编程环境

在 2030-35 年的编程环境中, 基于 LLM 的自动编程技术已经达到了一定的成熟度, 程序员可能需要切换到不同的角色才能充分利用自动编程的力量。

程序员作为代码编写者和设计者, 而不是代码编写者。随着基于 LLM 的自动编程的进步, 许多需要编写代码的软件维护任务可以通过调用相应的 LLM 自动解决。图 ?? (a) 显示了 Image Creator 使用 DALL·E, 程序员充当代码编写者和设计者, 而不是代码编写者。他们不再扮演传统的程序员角色, 为解决不同的任务而精心

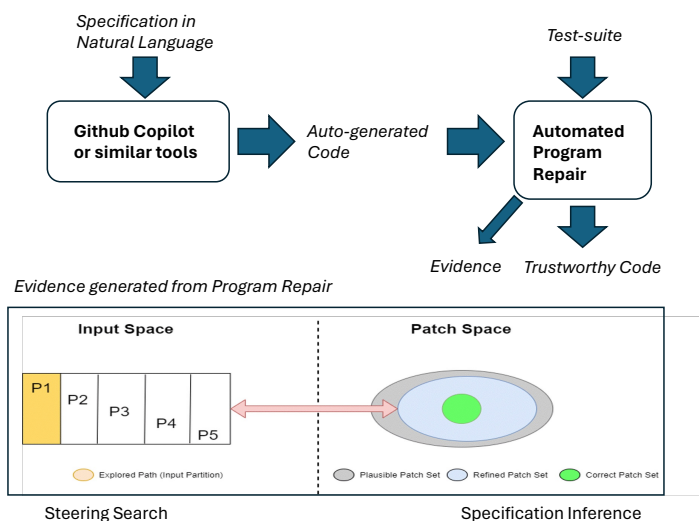


Fig. 6. 自动修复自动生成的代码

编写代码，而是专注于需要对需求有高度理解的任务（例如，设计程序的整体结构和试探性算法），允许自动化工具为相关维护任务选择最有效的模型，其中相关代码将自动生成。由于目前的技术主要集中在将 LLM 专门用于自动编码的特定下游任务（例如，程序修复、日志语句、测试生成）以提高给定任务的有效性，因此未来的编程环境将根据下游任务的上下文智能地预测和选择要调用的适当模型。在两种情况下，基于 LLM 的自动编程可以改变未来的编程环境：(1) 在集成开发环境 (IDE) 设置中，(2) 在持续集成 (CI) 工作流中。例如，在需要自动编码工具的即时反馈以实现高效交互的 IDE 设置中，未来的技术可以设计一个轻量级工具，该工具可以根据 (1) 当前周围的代码和 (2) 可用任务列表（例如，建议为新编写的 Java 方法添加 JUnit 测试或在程序正常退出之前添加日志语句）自动完成和建议相关代码片段。同时，在 CI 工作流中，代表软件系统异常行为的某些事件（例如，测试失败、构建失败）可以自动触发对软件维护任务的需求（例如，可以在测试失败后触发修复需求）。在这种情况下，可以使用更复杂的技术来进一步确认触发器的有效性（例如，区分测试失败或片状测试）。这些技术包括程序分析技术（如符号执行）、测试生成技术（基于提交中的代码更改）和日志分析（程序监视）。

程序员作为质量保证专家。尽管许多任务可以自动化，但我们预计对自动生成代码质量的担忧仍然存在。由于一些自动生成的代码可能与程序员的意图不一致，因此程序员需要扮演质量保证专家的角色，并花费更多时间检查生成代码的有效性。除了使用传统的测试和静态分析工具外，还可以设计更专业的自动化程序修复技术（例如，参考先前研究调查自动生成代码错误的 [?]），以减少检查自动生成代码质量所涉及的时间和精力。图 ?? (b) 显示了 AI 生成的图片，说明程序员的主要角色是质量保证专家。图 ?? 显示了一个示意图，该示意图具体化了自动生成代码的最后一英里改进 P 这些代码是使用 Copilot 等工具从自然语言描述生成的。自动生成的代码可能会受到给定测试套件 T 指导的程序修复。但是，修复过程会检查或检查（显式或隐式）程序编辑域，一试图缩小适合改进程序 P 的候选编辑空间。这样，修复后的程序 P' 从 P 生成。在检查程序编辑域（并可能排除大量候选编辑）的过程中，程序修复过程会生成许多额外的测试，这些测试 T' 用于指导程序修复过程的测试套件 T。这些附加测试的预言机（或预期行为）T' 可以通过对自然语言描述进行一些处理来获得 P 从中派生出来的。然后，T' 的附加测试输入（以及它们的预言机）可以作为修复程序 P' “正确性”的证据。

我们设想未来的代码生成器将不仅仅是 *LLM*，而是增强了程序分析/修复功能的 *LLM* 代理。然后，这些增强的代码生成器可能会尝试像人类程序员一样提交代码，同时以生成的测试的形式提交证据， $T'$  作为 (*LLM* 诱导的) 代码提交正确性的证据。

. 编程器辅助安全自动编码 我们设想大型语言模型 (*LLM*) 生成的代码可以集成到现有软件项目的遗留代码库中。这可以是库执行特定任务的形式，其中库代码是使用 *LLM* 生成的。为了将此类 *LLM* 生成的代码安全地集成到人工编写的软件项目中，可能需要 消毒剂代码 (例如 [?])，以便更大的软件项目可以安全地使用 *LLM* 生成的代码。在我们达到完全自动化生成整个软件项目的阶段之前，可能需要研究 (a) 自动修复或改进 *LLM* 生成的代码，或 (b) 以 包含 的方式执行 *LLM* 生成的代码，以便它可以对软件系统的其余部分造成有限的伤害，或者 (c) 在适当的形式规范可用时生成经过验证的 *LLM* 代码。验证 *LLM* 代码的第一步是用支持验证的编程语言生成代码 (例如，参见 [?])。我们还可以从 *LLM* 生成程序和证明 (关于程序满足某些形式属性)。这种形式属性可以从自然语言中获得，其中有一些工作 [?]。最近还研究了从 *LLM* 自动生成证明 [?]。所有这些都为从 *LLM* 转向更高的保证代码提供了动力。

. 自主程序改进 我们认为，与调整或限制 *LLM* 以生成安全输出相比，对 *LLM* 生成的不安全代码进行程序修复的方法是一种更灵活的自动生成安全代码的方法 (因为它基于代码转换)。展望未来，研究人员可以研究这一行工作，以及在提示工程和 *LLM* 调整方面的重要短期努力。基于测试修复自动生成的代码为我们提供了更大的灵活性，部分原因是我们还可以选择用于指导程序修复的测试。修复以及其他任务 (如功能添加) 可以由 *LLM* 代理自主完成，这些代理知道代码的结构。最近在 *AutoCodeRover* [?] 上的工作就是这个方向的一个例子。在不久的将来，重点将是提高这些药物的疗效。自然语言的自动编码和使用 *LLM* 的自主软件改进相结合，是一个诱人的可能性，可以在 2030 年之前实现。这将使未来软件工程师的角色转向通过专注于自主工件的 信任 来实现 保证 的自主性，而不是在 规模 设计软件系统。软件系统的规模很可能在未来自动实现，从而将注意力转移到 trust。

. 看得更远 自动生成代码的自主改进不必局限于应用程序级编程。我们可以研究自动修复自动生成的概率程序的可行性。概率编程简洁地表达了概率模型上的统计推理任务 [?]，并在后端得到 *Pytorch* [?] 等机器学习框架的支持。最近，有人提出了概率程序的符号执行 [?] 这提高了语义感知概率程序修复的可能性，在最初的 *LLM* 引导下自动生成概率程序片段之后。这项工作可以帮助我们朝着学习任务的自动自我改进方向发展，这是未来研究的推测方向。

## 9

确认这项工作得到了新加坡教育部 (MoE) Tier3 拨款 MOE-MOET32021-0001 的部分支持。作者感谢 Prem Devanbu 对本文的宝贵评论。通讯作者 Abhik Roychoudhury 感谢 Xiang Gao 和 Martin Mirchev 提供了一些示例程序来说明基于 AI 的编码问题。