



На пути
К 100% генерации кода



Developer-first платформа с AI,
доступная в облаке

GETVERSE

ПРАВИЛО БЕЗОПАСНОЙ ГАВАНИ (SAFE HARBOR)

Это обязательный юридический слайд.

Всё содержимое этого доклада может быть художественным вымыслом или неправдой. Поэтому, нужно думать своей головой и не верить докладчику на слово.

Если вы пытаетесь внедрить решения и знания, полученные из этого доклада, **вам стоит нанять профессионалов**. Они расскажут, что стоит использовать, а что – нет.

2025 год. Цифры.

- \$202B – инвестиции в AI за год
- 800M еженедельных пользователей ChatGPT
- 50% всего венчурного капитала мира – в AI
- Брет Тейлор (OpenAI): «У нас тоже пузырь»

Кассовый вопрос: заменит ли AI-чат программистов?

Часть первая

Нужны ли вообще чаты?

80 лет битвы чатов с файлами

Этот вопрос задавали раньше

1961 – «Интерактивные терминалы заменят пакетную обработку!»

1973 – «Живая среда LISP заменит файлы!»

1985 – «Экспертные системы заменят специалистов!»

1997 – «UML-диаграммы заменят код!»

2022 – «ChatGPT заменит программистов!»

Каждый раз – файлы и работа людей над ними побеждали.

Цикл 1


Первый «чат» в истории

1961 – 1972


До 1961: компьютер размером с дом

- ENIAC (1945): 27 тонн, 174 кВт
- Программирование = **перекоммутация проводов**
- Перфокарты: пробил → сдал оператору → **ждёшь часы**
- Ошибка = повторить весь цикл

Программист **не видит** компьютер.



GE-645 SYSTEM



1961: CTSS – первый диалоговый интерфейс

Fernando Corbató, MIT. IBM 7094.

Несколько пользователей одновременно.

Печатаешь команду → получаешь ответ. Сразу.

«*Man-Computer Symbiosis*»
– Licklider, 1960

Интерактивные пользователи работали на порядок продуктивнее.





COMPILERS TOOK MY JOB

1966: ELIZA – первый чат-бот

Joseph Weizenbaum, MIT. ~200 правил.

Программа прикидывается психотерапевтом.

Чистый pattern-matching. Никакого «понимания».

Но секретарь Вейценбаума попросила его

выйти из комнаты –

чтобы поговорить с ELIZA приватно.

(Возможно, анекдот – но показательный.)

E.L.I.Z.A. Talking



Развязка: Unix, C и «всё есть файл»

Thompson и Ritchie уходят из Multics.

Создают Unix на PDP-7.

Философия: «всё есть файл»

- `ed` (1969) → `vi` (1976) – файловые редакторы
- `C` (1972) – файловый язык: редактируй → компилируй → запускай
- Pipe, текстовые потоки, конфиг-файлы

Файловый подход определил **следующие 50 лет**.

Цикл 2

Будущее, которое не случилось

1973 – 1983

Interlisp-D: IDE из будущего

Xerox PARC. Teitelman & Bobrow.

- DWIM – Do What I Mean (автоисправление)
- Structure-aware editing
- Live debugging – отладка прямо в работающей программе
- Программа – не файл, а живой объект в памяти

В некоторых аспектах – продвинутее Claude Code 2025 года.

Нечто подобное: JetBrains MPS (используется для исследований и на заводах)

User jack Pkg HCL-USER: Rdtbl XCL Tty EXEC Dir <Users>jack on (DSK) VMemo 17% Time 16-Jan-2021 22:49

Prompt Window

```
Exec (XCL)
Medley 3.5 Full Sysout 5-Jan-2021 ...
{DSK}<Users>jack>src>medley>greetfiles>SIMPLE-INIT.;3
File created 14-Jan-2021 21:50:10
SIMPLE-INITCOMS
Hi.

s>
```

IRM - Function Definition, Manipulation, and Evaluation

- Background and Acknowledgements
- Introduction
- Litatoms
- Lists
- Strings
- Arrays
- Hash Arrays
- Numbers and Arithmetic Functions
- Record Package
- Conditionals and Iterative Statements
- Function Definition, Manipulation, and Evaluation**
- Variable Bindings and the Interlisp Stack
- Miscellaneous
- Interlisp Executive
- Errors and Breaks
- Breaking, Tracing, and Advising
- List Structure Editor
- File Package
- Compiler
- Masterscope
- DWIM
- CLISP
- Performance Issues
- Processes
- Streams and Files
- Input/Output Functions
- User Input/Output Packages
- Graphics Output Operations
- Windows and Menus
- Hardcopy Facilities
- Terminal Input/Output
- Ethernet

Node: Function Definition, Manipulation, and Evaluation
Top! IRM Top
Parent! IRM Top
Previous! Defining New Iterative Statement Operators
Next! Function Types
Display: **Graph** **Menu** **Text** **History**
Find! Lookup!
IRM DInfo

#

10. FUNCTION DEFINITION, MANIPULATION, AND EVALUATION

The Interlisp programming system is designed to help the user define and debug functions. Developing an applications program in Interlisp involves defining a number of functions in terms of the system primitives and other user-defined functions. Once defined, the user's functions may be referenced exactly like Interlisp primitive functions, so the programming process can be viewed as extending the Interlisp language to include the required functionality.


Functions are defined with a list expression known as an "expr definition." An expr definition specifies if the function has a fixed or variable number of arguments, whether these arguments are evaluated or not, the function argument names, and a series of forms which define the behavior of the function. For example:

(LAMBDA (X Y) (PRINT X) (PRINT Y))

A function defined with this expr definition would have two



* Welcome to the **Claude Code** research preview!



Login successful. Press **Enter** to continue

Smalltalk: вся программа – живая

Alan Kay, Dan Ingalls. Xerox Alto.

Image-based: вся программа – живой образ в памяти.

Нет файлов. Нет компиляции. Всё – **прямо сейчас.**

Вдохновил Macintosh.

Но: нет контроля версий, нет совместной работы.

Classes

AllClasses	CharLine	ClassDefinition	complementfrom:
SystemOrganization	Dispframe	ClassOrganization	compRect:
'Kernel Classes'	Font	'all'	reversefrom:to:
'Numbers'	FontSet	'start & finish'	selection
'Basic Data Structures'	Paragraph	'menu messages'	
'Sets and Dictionaries'	RemoteParagraph	'accessing'	
'Graphical Objects'	StyleSheet	'coloring'	
'Text Objects'	Textframe	'editing keys'	
'Windows'	TextImage	'selecting'	
'Panes and Menus'		'character shapes'	
'Compiler'		'indicating'	
'NoteTaker Classes'		'copying'	

```
compRect: r
    ["Reverse the rectangle r from white to black as part of a selection"
     ((r intersect: frame) intersect: window) comp.
     (((r copy translate: 2@2) intersect: frame) intersect: window) comp.]
```

UserView.workspace

XEROX - Learning Research Group

This is a resurrected version of the Smalltalk-78 system running on the Notetaker computer in 1979.

Tended from the original, mainly bugs (the Notetaker never went into production), and by restoring features from Smalltalk-76 that were stripped out to fit the Notetaker's limited hardware. Other changes have been added to take advantage of modern machine speeds.

Enjoy!
Dan, Ted, Yoshiki, Alan
2014

100 factorial
factorial/99 factorial

The Jobs Demo

To recreate my change to text selection, first execute "Rectangle from user comp." a few times to see how simple black/white complement works.

Then browse to
'Text Objects' / TextImage / 'selecting' / complementfrom:to: and observe that it calls compRect: to complement the three parts of any selection.

Then browse to compRect:, and below the line:
((r intersect: frame) intersect: window) comp.
add another that complements a second offset rectangle:
(((r copy translate: 1@1) intersect: frame) intersect: window) comp.
The circle dot is infix to make an x-y point; it's typed as an at-sign.
You can just copy the whole line from here.
Choose 'compile' from the edit menu - poof - selections are now outlined!

Change the offset to 2@2 to look even better. Note how long it takes to recompile this change to the heart of the system.

Reset ■ Load image Go to 0 Step ▶ Running ○ Free oops: 18014 Help File... error

Развязка: \$100K vs \$49.99

LISP-машина	IBM PC + Turbo Pascal
\$100 000	\$1 565 + \$49.99
Специализированная	Универсальная
Живая среда	Edit → compile → run
~10 000 продано	600 000 за 3 года


Будущее проиграло настоящему.

Файлы: 2, Чат: 0.

Цикл 3

«Заменим программистов диаграммами»

UML · 1997 – 2016



UML + MDA: «модель это код»

IBM купил Rational за \$2.1B (2003)

- 14 типов диаграмм
- Обещание: рисуешь диаграмму → получаешь код
- Освоить UML **сложнее**, чем написать код, который он призван заменить

Сгенерированный код – раздутый, неidiоматичный, неподдерживаемый.

Agile убивает UML

2001, Snowbird, Юта. 17 практиков.

«Работающий софт важнее исчерпывающей документации.»

Martin Fowler – автор UML Distilled – среди подписавших.

2016: Visual Studio убирает поддержку UML.

Черное зеркало

UML (1997)	AI Chat (2022)
Заменим код диаграммами	Заменим код промптами
Модель это код	Промпт это код
Сгенерированный код – неподдерживаемый	Сгенерированный код – ?
Последняя миля – код пишется вручную	Последняя миля – код пишется вручную?

Оба недооценивают **сложность реального софта**.

Цикл 4

Отражение 2025 года


Экспертные системы · 1981 – 1993



BACKWARD CHAINING

GOAL: Make \$20.00

RULE: If the lawn is shaggy and
the car is dirty and you mow
the lawn and wash the car,
then Dad will give you \$20.00



*** The inference engine will test each rule or ask the user for additional information.

Экспертные системы: хайп 1980-х

- DENDRAL, MYCIN, R1/XCON
- DEC экономит **\$40M/год** с R1/XCON
- **\$1B+/год** инвестиций к 1985
- «Новые AI-компании – по одной в неделю»
- Япония: Fifth Generation Computer, **\$850M**

Крах за один год

1987: Рынок LISP-машин **уничтожен за один год.**

- 300+ AI-компаний закрылось
- Symbolics – банкрот
- Шенк и Минский предупреждали ещё в 1984

Джек Шварц (DARPA):

«Это просто хитрое программирование.»

Параллели

	1985	2025
Инвестиции	\$1B+/год	\$200B+/год
Обещание	AI заменит экспертов	AI заменит программистов
Реальный результат	Экономия в нишах	Экономия в нишах
Хрупкость	Не обобщает	Галлюцинации
Доверие ↓	Минский: «хайп»	SO: 70% → 60%

Между циклами

Три победы файлов, о которых забывают

Три «тихие» победы

GUI (1984 → 1995)

Macintosh, Windows 95. Самая массовая интерактивная революция.

Но метафора рабочего стола – это **папки и файлы**.

Save As. Drag-and-drop. GUI = визуализация файлов.

Cortana Chat в Windows 11 не взлетел.

Веб (1993 → сегодня)

Четвёртый великий интерфейс. HTML/CSS/JS – файлы.

URL – адрес ресурса. HTTP GET – «дай файл».

В Chromium Developer Tools экспериментируют, а не пишут в прод.

Jupyter (Python, 2014) и Zeppelin (Scala, 2015)

10M Jupyter-ноутбуков на GitHub. Но стандартный workflow:

«Исследуй в notebook → перенеси в .ру файлы.»

Очень медленный прогресс.

Текущий цикл

AI-революция в реальном времени

2022 – 2025

ChatGPT: Optimizing Language Models for Dialogue


We've trained a model called ChatGPT which interacts in a conversational way. The dialogue format makes it possible for ChatGPT to answer followup questions, admit its mistakes, challenge incorrect premises, and reject inappropriate requests. ChatGPT is a sibling model to InstructGPT which follows an instruction in a prompt and provides a response.

TRY CHATGPT →

November 10, 2023
15 minutes

ChatGPT: Optimizing Language Models for Dialogue

We've trained a model called ChatGPT which interacts in a conversational way. The dialogue format makes it possible for ChatGPT to answer followup questions, admit its mistakes, challenge incorrect premises, and reject inappropriate requests. ChatGPT is a sibling model to InstructGPT which follows an instruction in a prompt and provides a response.



Directed by
ROBERT B. WEIDE

ChatGPT: восьмой «чат»

Ноябрь 2022. 100M пользователей за 2 месяца.

Восьмая итерация **того же паттерна**:

CTSS → ELIZA → MS-DOS → VB/Delphi →
→ Jupyter → ChatGPT

Новейший «чатовый» интерфейс computing.

А дальше?

Файлы контратакуют

Copilot (2021) → **Cursor** (2023)

AI интегрирован в файловые IDE.

Cursor: \$1B ARR. AI-first, но **файловый**.

Claude Code / Codex CLI

Терминальные агенты. Читают и пишут **файлы**.

`CLAUDE.md` – конфиг через markdown-файл.

Kiro (AWS, 2025)

`requirements.md` → `design.md` → `tasks.md` → код

AI-революция породила инструмент,
генерирующий **спецификации в файлах**.

Git – финальный аргумент

Linus Torvalds, 2005. Distributed VCS.

`diff` – только для файлов

`merge` – только для файлов

`branch` – только для файлов

`code review` – только для файлов

Git не работает с чат-сессиями,
REPL-историями или живыми образами.

Контроль версий – структурное преимущество файлов.

Git не работает с чат-сессиями?

А если найду?

Thomas Dohmke, стартап EntireHQ

- \$60 млн в сид раунде с оценкой в \$300 млн
- AI-first Git Platform
- Checkpoints: автоматическое сохранение контекста агентов в Git

Всё это тоже файлы, хоть и гибридные

Почему файлы побеждают. Каждый раз.

1. Контроль версий

diff, merge, branch, blame – только текстовые файлы

2. Совместная работа

Code review, pull requests, CI/CD – только файлы

3. Воспроизводимость

Файл на моей машине = файл на вашей машине = файл на сервере

Эти свойства **не зависят от технологии.**

Они работали в 1972. Работают в 2025.

8 циклов. Один паттерн.

1961 Time-sharing → Unix: «всё есть файл»

1973 LISP-машины → IBM PC + Turbo Pascal

1984 GUI-революция → Рабочий стол = папки + файлы

1985 Expert Systems → Крах за один год

1993 Веб-браузер → HTML/CSS/JS = файлы

1997 UML: модель→код → Agile: «работающий софт»

2014 Jupyter → «Исследуй → перенеси в .ру»

2022 ChatGPT → Cursor, Claude Code, Kiro

Вопрос не «чат или файлы?»

Интерактивные инструменты **не умирают**.

REPL жив. Jupyter жив. ChatGPT будет жить.

Вопрос: **сколько времени мы используем чат, и сколько файлы?**

Исследуй в чате.

Разрабатывай в файлах.

Это не что-то новое, это **80 лет эволюции**.

Часть вторая

Новое лето искусственного интеллекта

Как мы дошли до 100% генерации кода

Hardware → Science → Products → Practices

Пять волн AI-революции в разработке

Февраль 2026


Каскад: от железа до нашей повседневной работы

- **Hardware** – железо определяет границы возможного
- **Science** – учёные осваивают новые горизонты
- **Products** – то, что вы можете скачать и запустить
- **Practices** – как вы реально изменили подход к работе

Задержка каскада:


4 года в 2017 → 6 месяцев в 2025.

Волны ускоряются и **перекрываются**.



Transformer

Attention Is All You Need



Волна Tensor Cores

2017 → 2021. Четыре года от чипа до продукта

V100 → Transformer + RLHF → Copilot → Comment-Driven Dev

Самая длинная волна. Четыре года тишины между открытием и продуктом.

■ V100: железо, которое зажгло искру

125 TFLOPS для deep learning. Tensor Cores: матричные операции 5-12× быстрее

■ Transformer: архитектура, которая победила всех

Self-attention заменяет рекуррентность.

Параллельная обработка всей последовательности. O(1) между любыми позициями

В том же году – RLHF foundations (Christiano et al.). Семя, которое прорастёт через 5 лет

Без Tensor Cores Transformer остался бы академическим курьёзом.

Это первый пример каскада: чип делает науку возможной.

Technical preview

Your AI pair programmer



The screenshot shows a dark-themed code editor interface. At the top, there's a navigation bar with file tabs: 'fetch_pic.js' (selected), 'push_to_git.py', 'd3_scale.js', 'fetch_stock.js', and 'material_ui.js'. Below the tabs, a code editor displays the following JavaScript code:

```
1 const fetchNASAPictureOfDay = () => {
2   return fetch('https://api.nasa.gov/planetary/apod?api_key=DEMO_KEY', {
3     method: 'GET',
4     headers: {
5       'Content-Type': 'application/json',
6     },
7   })
8     .then(response => response.json())
9     .then(json => {
10       return json;
11     });
12 }
```

At the bottom left of the code editor, there's a small button labeled 'Copilot' with a circular icon containing a person icon.



■ ■ Четыре года тишины → Copilot

2018-2020: ученые работает, продуктов нет.

- BERT (2018), GPT-2 (2019), GPT-3 (2020)
- Программисты ещё не заметили

Июнь 2021 – GitHub Copilot Preview


Codex (GPT-3, дообученный на коде). Первый массовый AI-ассистент для кода

27% кода в файлах генерирует AI. 1M+ пользователей за год

Новая практика: Comment-Driven Development

Комментарии стали входом, а не выходом. Напиши что – AI напишет как

Задержка волны 1: 4 года от железа до продукта



Волна Масштаба

2020 → 2023. Больше = лучше (пока не перестало)

A100 → GPT-3, Scaling Laws, CoT, InstructGPT → ChatGPT → SO умирает, Prompt Eng, RAG

Scaling is all you need

Волна, в которой масштаб породил эмерджентность

И парадокс: маленькая модель + RLHF лучше, чем огромная модель

■ A100 → ■ Scaling Laws + парадокс InstructGPT

A100: 80 ГБ HBM2e, 2 ТБ/с. GPT-3 (175B) тренировался на кластерах A100

Scaling Laws (Kaplan et al.): loss = степенная функция от параметров, данных, compute
«Закон Мура для AI»: предсказуемая отдача при 10× увеличении


Парадокс 2022: маленькая побеждает большую

InstructGPT: 1,3B с RLHF побеждает 175B GPT-3 без

Chain-of-Thought (Wei et al.): «Let's think step by step» – кратно улучшает точность

Pre-training scaling работает, но post-training определяет полезность.

H100 с нативным FP8 (4x throughput vs A100) делает это масштабируемым.



■ ChatGPT → ■ Stack Overflow умирает за 24 месяца

30 ноября 2022 – ChatGPT. Самая быстрая adoption в истории

Stack Overflow

- ноябрь 2022: 108 563 вопросов/мес
- январь 2023: 96 377 (-11%)
- декабрь 2024: 25 566 (-76,5%)


PNAS Nexus: -25% каузальное снижение. SO: увольнения 10% + 28%

Одновременно – рождение трёх практик

Prompt Engineering: Indeed: 2 → 144 вакансии/млн за 3 месяца

QLoRA: 65B модель на одном 48GB GPU – «уравниватель»

RAG: 51% enterprise AI. Pinecone \$100M, Weaviate \$50M



Волна Эффективности

2022 → 2025. Не «больше» – а «умнее при тех же ресурсах»

H100 FP8, MI300X, MXFP4 → MoE, Mamba, KV cache → Cursor, AI IDEs → AI-native IDE, «write less»

Волна, где MoE стала доминирующей архитектурой, а Cursor – самым быстрым SaaS в истории

■ Мощное и эффективное железо

H100 FP8 (2022): обучение и inference в пониженной точности **без деградации**. 4× throughput

MI300X (2023): 192 ГБ единой памяти – AMD конкурирует с NVIDIA

MXFP4 (2025): 4-битная квантизация. 120В на одном H100 (90% MMLU)

■ MoE: архитектурный ответ на проблему масштаба

Mixtral 8×7B: из ~47B параметров **работают ~13B на токен**

Качество большой модели при стоимости маленькой

К 2025: Qwen3-235B (128 экспертов, top-8), DeepSeek-V3, Grok-3

ResMoE: **75% сжатие. Каждая frontier-модель 2025 – MoE**

Параллельно: Mamba (SSMs) – $O(n)$ вместо $O(n^2)$. Единственный реальный конкурент Transformer, но для кода пока не победил

■ Cursor: самый быстрорастущий SaaS в истории

AI-native IDE – не «плагин в IDE», а «AI с IDE вокруг»

\$1M ARR → \$100M ARR за ~12 месяцев. К 2026: \$29,3B валюация, \$1B+ ARR
1 миллиард строк принятого кода в день. Ни одного доллара на маркетинг

Cursor 2.0

Composer model (MoE + RL)

4× быстрее, ~250 т/с

До 8 параллельных агентов

Под капотом

RAG + Merkle tree для изменений

Turbopuffer vector DB

Сотни ТБ эмбеддингов

| Jensen Huang назвал Cursor «*my favorite enterprise AI service*»

■ Практики волны эффективности

«Пиши меньше, ревьюй больше»

Google: >25% кода AI-сгенерировано (Pichai, Q3 2024)

46% кода у активных Copilot-юзеров – AI. Java-разработчики: 61%


Werner Vogels: «**Verification debt**» – ревью AI-кода **сложнее**, чем своего AI-native IDE как категории

Cursor + Windsurf → десятки тысяч переходят. 85% используют AI daily (JetBrains 2025)

MCP – «USB-C для AI» (ноябрь 2024)

Anthropic выпускает открытый стандарт. JSON-RPC, вдохновлён LSP.

Пока мало кто заметил. Но через год – 97M downloads



Волна Reasoning

2024 → 2026. «Думай дальше, а не больше»

B200 FP4, Groq, TPU v6 → TTC, GRPO ★, DPO → o1, R1, Claude Code, Codex → Vibe Coding, Agents, AI Review

Волна, которая перевернула парадигму: reasoning – emergent property из чистого RL

■ Железо эры инференса

B200: нативный FP4, 192 ГБ HBM3e, ~2.5× inference/GPU vs H100

Groq LPU: только inference. SRAM, детерминизм. ~300 т/с Llama 70B

TPU v6: 4,7× vs v5e. Google работает на своём железе

Inference-железо ≠ training-железо.

Конец эпохи «один GPU для всего».

NVIDIA купила Groq за \$20B (2025)

■ Test-Time Compute: переворот

Llemma-7B + tree search > Llemma-34B на MATH

«Дай модели подумать» вместо «сделай модель больше»

DPO: убирает reward model → alignment для команд без тысяч своих GPU

■ ★ GRPO: reasoning возникает из ничего

DeepSeek-R1-Zero – чистый RL, без SFT, без примеров рассуждений
Только сигнал «правильно/неправильно». И reasoning **возник сам**

AIME 2024: 15,6% → 71,0% pass@1. Nature, сентябрь 2025

Что появилось без программирования:

- Self-reflection – модель проверяет свои шаги
- Verification – модель ищет ошибки в своём ответе
- «Aha moments» – модель поправляет себя mid-reasoning

Открытие уровня «Attention Is All You Need».

Раньше: нужны человеческие примеры рассуждений.

Теперь: дай сигнал «верно/неверно» – reasoning **возникнет сам**.

■ Два подхода к агентному кодированию

Claude Code

Терминальный, **in-the-loop**

72,7% → **80,9%** SWE-bench (Opus 4.5)

90% своего кода пишет сам

\$1B ARR

Codex (OpenAI)

Облачный, **async**

56,8% SWE-bench Pro (SOTA)

77,3% Terminal-Bench 2.0

10 задач параллельно

o1 (2024): первая reasoning-модель в проде. 30 сек → правильный ответ

DeepSeek-R1 (open-weight): 7B = 55,5% AIME. **Каждый может запустить**

Copilot: 20M+ юзеров, 42% рынка, 1.2M PR/мес через coding agent

VIBE CODING



■ Vibe Coding + Background Agents

«There's a new kind of coding I call 'vibe coding', where you fully give in to the vibes, embrace exponentials, and forget that the code even exists.»

– *Andrey Karpathy*, 2 февраля 2025. *Collins Word of the Year*

Y Combinator W25: **25%** стартапов – 95% AI-код

Но **72% профи**: «это не мой метод»

Агентное программирование: делегируй фичу

«AI реализует фичи, **пока я занят другим»**

Задача → sandbox → PR. Claude Code + Codex + Copilot Agent

AI Code Review: **14% → 51%** за 10 месяцев

AI в **1/7 PR**. Qodo: **81%** улучшение качества

Волна Спецификаций

2025 → ... Только начинается

NVFP4 → Astrogator, Free Transformer, EvoMAC → Kiro, Antigravity, Verified GenCode → Spec-Driven Dev, MCP стандарт, Teams Shrink

Волна, которая отвечает на вопрос: «как доверять AI-коду?»

■ ■ Железо и наука о верификации

NVFP4: 4-bit KV-кеш. **50%** сокращение памяти → **50% больше контекста** на GPU
QuantSpec + ShadowKV + MagicDec → **128K контекст управляем**

Наука верификации

Подход	Результат	Вердикт
Astrogator (domain-specific)	83% верификация, 92% детекция	Работает!
CoT+RAG (general)	100% спеки, 58% верификация	Недостаточно
Full auto-formalization	58% – непригодно	Тупик

Free Transformer (Meta): планирует **до** генерации. +11% код на 8В
EvoMAC: агенты **перестраивают свою топологию**. +26,5% на Website

Путь к верифицированному коду – **domain-specific**, не general

■ Продукты волны спецификаций

Kiro (AWS)

Spec-driven development

requirements.md → design.md → tasks.md → code

Контроль через спецификации, не промпты

Antigravity (Google)

Agent-first IDE

Manager View: **5+ параллельных** агентов

Артефакты + скриншоты как доказательства

SWE-BENCH VERIFIED

2023: **2%** → 2025: **75%** 37× за два года



```
1 | # Implementation Plan
2 |
3 | ✓ Task completed
4 | [x] 1. Create the EmailOptInForm component
5 | - Create a new React component for the email opt-in form with
6 |   basic structure
7 | - Implement form UI with input field and submit button
8 | - Add Tailwind CSS styling to match the application design
9 | - _Requirements: 1.1, 1.2, 1.4_
10|
11| ⚡ Start task
12| [ ] 2. Implement form validation and state management
13|
14| ⏴ Task in progress
15| [ ] 2.1 Add form state management using React hooks
16| - Implement state for email input, loading state, success
17|   state, and error state
18| - Create handlers for input change and form submission
```

Great! Now that we have the design approved, let's create the implementation plan with specific tasks:

Created tasks.md

Each task references specific requirements from the requirements document and focuses only on coding activities that can be performed within the development environment.

Do the tasks look good?

Move to the next phase

Ask a question or describe a task

Auto

■ Практики волны спецификаций

MCP: стандарт, который приняли все

Ноя 2024 → ноя 2025: **97M+ downloads, 10 000+ серверов**

OpenAI, Google, Microsoft. → **Linux Foundation**

Команды сжимаются

Google: **30-60** → **2-5**. Stripe CEO: «Minimum viable team collapsed»

23% перераспределяют бюджет headcount → AI tools

Кризис джуниоров

Stanford: **-20%** занятость 22-25 лет. **44%**: падают фундаментальные навыки

Prompt Engineer → роль умирает

Indeed: 144/млн → **20-30/млн**. Навык: **68%** обучают. Роль: исчезает

Центральный парадокс: adoption ≠ trust

85%

используют АИ ЕЖЕДНЕВНО

29%

доверяют результатам

66%

«ПОЧТИ ПРАВИЛЬНО, НО НЕ СОВСЕМ»

Favorability: 77% (2023) → 60% (2025). «Willing but reluctant»

METR RCT: 40 п.п. perception gap

Разработчики думали: +20% быстрее. Реальность: -19% медленнее

Sonar: toil = 23–25% – с АИ и без. Работа сместились, не исчезла

«AI magnifies the strengths of high-performing organizations and the dysfunctions of struggling ones.» – DORA 2025

Безопасность: цена скорости

Package `hallucination` – «slopsquatting»

19,7% зависимостей в AI-коде – **несуществующие** пакеты (USENIX 2025)

43% повторяются → атакующие регистрируют с `malicious code`

Уязвимости

40% GPT-кода с уязвимостями (Trend Micro). **73%** CWE (Georgetown)

CodeRabbit: vibe-coded PR = **1.7×** major issues, **2.74×** security vulns

Доверие на цифрах

SO 2025: **3%** «высоко доверяют». **75%** ревьюят каждый AI-snippet

MCP CVE-2025-6514: **437 000+** скомпрометированных dev-окружений

Пять волн – один каскад

Волна 1	TENSOR CORES	V100 → Transformer, RLHF → (4 года) → Copilot
Волна 2	МАСШТАБ	A100 → GPT-3, Scaling → ChatGPT → S0 умирает
Волна 3	ЭФФЕКТИВНОСТЬ	H100 FP8, MI300X → MoE, KV → Cursor → Write Less
Волна 4	REASONING	B200, Groq → GRPO ★ → Claude Code, Codex → Agents
Волна 5	ВЕРИФИКАЦИЯ	NVFP4 → Astrogator → Kiro, Antigravity → Specs

Задержка: 4 года → 3 года → 2 года → 1 год → 6 мес

Волны **перекрываются**: пятая начинается, когда третья ещё не закончилась

Hardware определяет всё.

V100→Transformer. A100→GPT-3. H100→MoE. B200→Reasoning. NVFP4→Verification.

Что забрать с собой

1. Каждая волна начинается с **железа**. Следите за железом – оно предсказывает, куда пойдет наука, какие появятся продукты и практики на 1-3 года вперёд
2. GRPO – открытие уровня Transformer: **reasoning возникает** из чистого RL, без примеров
3. Три закона масштабирования **сходятся**: pre-training + post-training + inference.
Оптимум – баланс по трём осям
4. AI = **усилитель способностей людей**, а не замена людей. 85% adoption, 29% trust.
Работа **изменила характер**, не исчезла. METR: -19% при ощущении +20%
5. Будущее за **спецификациями + верификацией**. Domain-specific, не general. Spec-driven, не prompt-driven

Цитаты, определяющие момент

«Forget that the code even exists. I Accept All always.»

– *Karpathy. Collins Word of the Year 2025*

«AI magnifies the strengths of high-performing organizations and the dysfunctions of struggling ones.»

– *Google DORA 2025*

«A specification is a kind of (version controlled, human-readable) super prompt.»

– *Marc Brooker, Amazon*

«Programming without these tools just feels primitive.»

– *Armando Solar-Lezama, MIT CSAIL*

Уроки (горькие)

Уроки: Волна Железа

- Качество результата зависит не только от твоего навыка, но и от инструментов
- Нет инструментов и железа - ничего не можешь сделать, и это нормально

Уроки: Волна Масштаба - Публичные сервисы

- Claude Sonnet и Opus, тариф Max x20 - 200\$ в месяц (API дороже)
- Grok Super Heavy - 300\$ в месяц
- GigaChat Max - 9 750 ₽ за 15 миллионов токенов по API
- Любые средства для понижения стоимости!!!

Уроки: Волна Масштаба - Локальное железо

Кринж

- Скорость инференса на CPU - 1-3 токена в секунду, это **невыносимо**
- RTX 4090/5090 стоят 200+ тысяч рублей, опасность расплавить питание
- Старые Tesla (K80, P100) - очень мало VRAM, не поддерживают FP16, а GGUF/llama.cpp работает на деквантизации в FP32, придется строить целый датацентр (минимум 40 карт)



\$50,000

Уроки: Волна Масштаба - Локальное железо

Дорого-богато

- Соберем всё на Exo + Mac! <https://github.com/exo-explore/exo>
 - MoE модели параллелятся хуже, чем densed – железа надо больше
- Максимум VRAM в MacMini
- 2-терабайтный массив из Mac Studio стоит около 10 миллионов рублей
- Аналогичный сетап на Nvidia/B200 стоит 40+ миллионов ₽, не найдёте в продаже
- Любые средства для понижения стоимости!!!
 - MoE, QLoRA, RAG ...

Главный способ экономить

Не стройте свой домашний датацентр

Попросите работодателя купить учётки и железо

В AI-компаниях (Anthropic, OpenAI, GitVerse) у сотрудников нет лимитов на токены при использовании своих собственных инструментов

Масштаб требует роста, рост требует скидок!

- Тарифы Claude и Grok - дотационные
- Cursor дешевый, но становится всё дороже
- GigaCode пока бесплатный

Уроки: Волна Эффективности

- Ключевое: Выбор правильных инструментов
- Точный подбор модели
- Точный подбор железа
- Точный подбор методологии

Уроки: Волна Reasoning

- Только Reasoning и Extended Thinking
- Точный подбор агентного тулинга
- Точный подбор модели
- Вайбкод для кастомных задач `human-in-the-loop`
- Background Agents для масштабных задач

Уроки: Волна Спецификаций

- Spec-First: спецификации пишутся раньше кода
- Closed-Loop-Specs: спецификации обновляются автоматически
- Specs + Skills, оба вместе, а не что-то одно
- Использование очень конкретных инструментов (Kiro, Antigravity, GigaCode Agents, etc)

Главный урок:

Доверять нейросетям нельзя

(Но придётся)

И вот когда у нас есть на всё это ресурсы, инструменты и практики, когда мы умеем работать в ситуации неопределенности – 100% генерация кода ИИ возможна.

100% автоматическая генерация кода?

Автоматически ≠ бесплатно

По факту, очень дорого

Автоматически \neq ничего не нужно знать

Огромный инструментарий, растянутый на 80 лет эволюции

И продолжает расти

Автоматически \neq без участия человека

Нужно писать спецификации, собирать железо, много всего

"Программистов" могут заменить,

но людям придется работать больше, а не меньше

Новое лето искусственного интеллекта

ЧЕТЫРЕХСЛОЙНАЯ ВИЗУАЛИЗАЦИЯ – ФЕВРАЛЬ 2026

Hardware → Science → Products → Practices

Как железо порождает открытия, открытия превращаются в инструменты, а инструменты меняют то, как разработчики и data scientists работают каждый день. Нажмите на узел – увидите связи и подробности.

HARDWARE • GPU / Accelerator | SCIENCE • Архитектура • Рассуждения • Инфраструктура • Верификация • Агенты | PRODUCTS • IDE / Copilot • Coding Agent • Платформа • Модель | PRACTICES • SWE • DS / ML • Обе аудитории

2017

HARDWARE

Июн NVIDIA V100
Первые Tensor Cores. 125 TFLOPS для глубокого обучения. Матричные операции в 5–12x быстрее.
Без этого чипа Transformer остался бы академическим курьезом. Tensor Cores сделали attention реализуемым на практике.

SCIENCE & ENGINEERING

Transformer – "Attention Is All You Need"
Self-attention заменяет рекуррентность. Параллельная обработка всей последовательности. O(1) между любыми позициями.
Фундамент всего. Каждая модель и каждый продукт стоят на этой архитектуре.

RLHF Foundations – Christiano et al.
Обучение на основе человеческих предпочтений через reward models. PPO как алгоритм оптимизации.
Мост от «мощного движка» к «полезному инструменту». Без RLHF модели не следовали бы инструкциям.

PRODUCTS

• DEPLOYED

PRACTICES

2020

Май

NVIDIA A100 – 80 GB HBM2e
Tensor Cores 3-го поколения. MIG. 2 ТБ/с пропускной способности.
GPT-3 (175B) тренировался на кластерах A100. Без 80 ГБ памяти модели такого масштаба были бы невозможны.

GPT-3 & Scaling Laws – Kaplan et al.
175B параметров. Loss масштабируется степенным законом. Эмерджентные способности при масштабировании.
Scaling laws – «закон Мура для AI». Предсказуемая отдача при увеличении модели в 10x.

• DEPLOYED

Transfer Learning – Fine-Tune
BERT (2018) → GPT-3 (2020): fine-tune pre-trained вместо обучения с нуля.
Смерть кастомных word embeddings. «Просто дообучи» – новый стандарт.

2021

Июн

NVIDIA H100 – FP8 & HBM3
Tensor Cores 4-го поколения. Нативный FP8. 3,35 ТБ/с, 4x throughput vs A100.
FP8 – качественный скачок: обучение и inference в пониженной точности без деградации.

Speculative Decoding
Маленькая модель генерирует кандидатов, большая верифицирует параллельно.
Acceptance rate >85%.
2–3x ускорение inference без потери качества.

• DEPLOYED

GitHub Copilot (Preview)
Codex (GPT-3, дообученный на коде). Первый массовый AI-ассистент для кода.
Создал рынок AI-кодогенерации. 1M+ пользователей за год.

AI-автокомплит: первая волна
Copilot preview: 27% кода в enabled-файлах генерируется AI.
Новый воркфлоу: напиши комментарий → AI допишет. Comment-driven development.

2022

Янв–Ноя

NVIDIA H100 – FP8 & HBM3
Tensor Cores 4-го поколения. Нативный FP8. 3,35 ТБ/с, 4x throughput vs A100.
FP8 – качественный скачок: обучение и inference в пониженной точности без деградации.

Chain-of-Thought Prompting – Wei et al.
«Let's think step by step.» Промежуточные шаги рассуждения кратко улучшают точность.
Простая идея с непропорциональным эффектом. Фундамент reasoning.

InstructGPT – RLHF at Scale
1,3B InstructGPT побеждает 175B GPT-3. Post-training: pre-train → SFT → RLHF.
Маленькая модель с RLHF побеждает огромную без.

• DEPLOYED

Copilot GA + ChatGPT
Copilot выходит в GA (июнь). ChatGPT запускается (ноябрь).
Рынок кодогенерации взрывается.

«Спроси AI» вместо Stack Overflow
ChatGPT (июнь 2022): мгновенный ответ без осуждения. Вопросы на SO: -11% за 2 месяца.
SO → ChatGPT. PNAS Nexus: -25% снижение активности SO.

2023

• DEPLOYED



Transformer – "Attention Is All You Need"

НАУЧНАЯ СУТЬ

Self-attention заменяет рекуррентность. **Параллельная обработка** всей последовательности. $O(1)$ между любыми позициями.

ЦЕННОСТЬ ДЛЯ ИНЖЕНЕРА

Фундамент всего. Каждая модель и каждый продукт стоят на этой архитектуре.

ССЫЛКИ

[Attention Is All You Need ↗](#)

Оригинальная статья Vaswani et al. (NeurIPS 2017). Архитектура, изменившая всё машинное обучение.

[The Illustrated Transformer ↗](#)

Jay Alammar's визуальное объяснение – лучшее введение в механизм self-attention.

[The Annotated Transformer ↗](#)

Harvard NLP: построчная реализация Transformer на PyTorch с объяснениями. Для тех, кто хочет понять код.

— ОСНОВАН НА

- Позволил [NVIDIA V100](#) ↗

— РАЗВИТИЕ

- Эволюция [GPT-3 & Scaling Laws – Kaplan et al.](#) ↗

- Позволил [GitHub Copilot \(Preview\)](#) ↗

Developer-first платформа с AI,
доступная в облаке

GETVERSE

Спасибо. Вопросы?

GitVerse с ИИ внутри: <https://gitverse.ru>

Эти слайды:

<https://oleg.guru/talks/100-percent-generation>

Новое лето искусственного интеллекта:

<https://oleg.guru/ru/timeline>

80 лет борьбы чата с файлами:

<https://oleg.guru/ru/chat-vs-file>

Промт для исследователей:

<https://gist.github.com/olegchir/c1104526b000be33763b6369d20f0ebc>

Остальные ссылки (Telegram, Twitter...):

<https://oleg.guru>