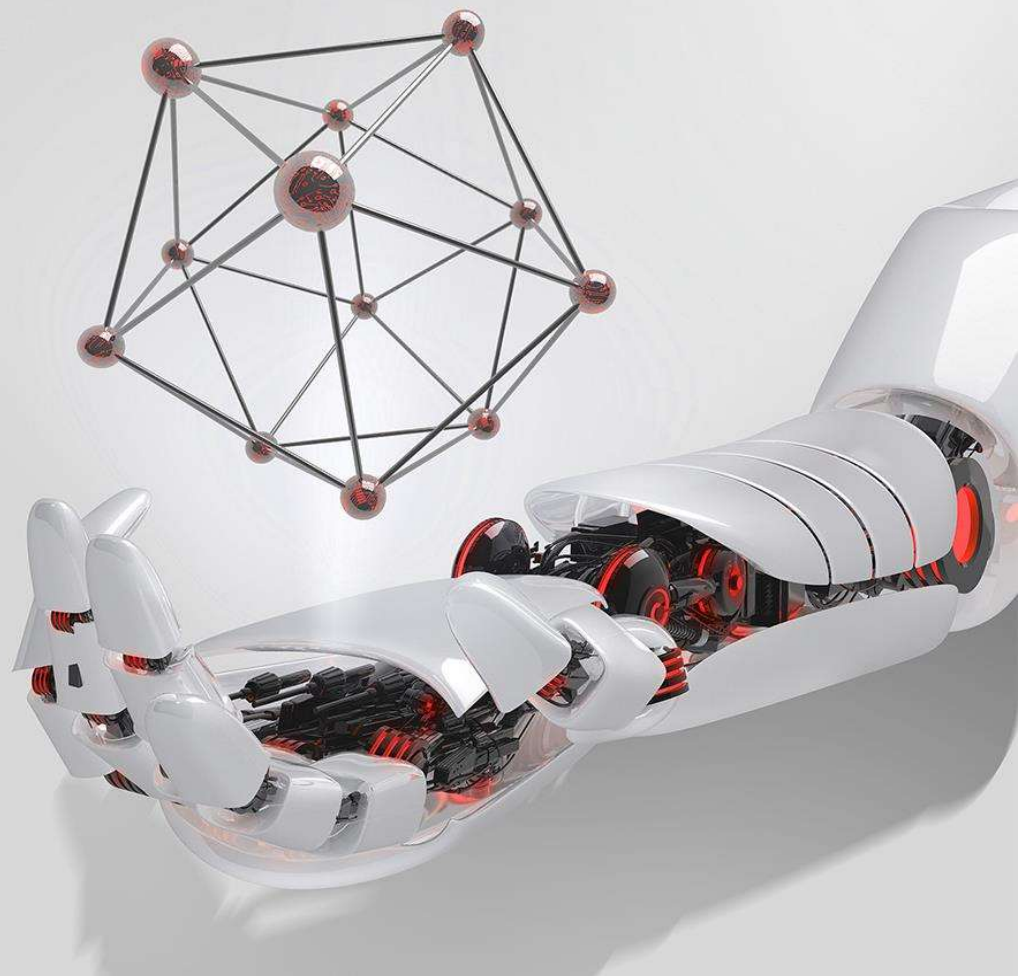


AIOT时代的 编程语言、编译器与指令集架构： 机遇、挑战与技术分享

华为技术有限公司 编译器与编程语言实验室
- 曾建江



Security Level:



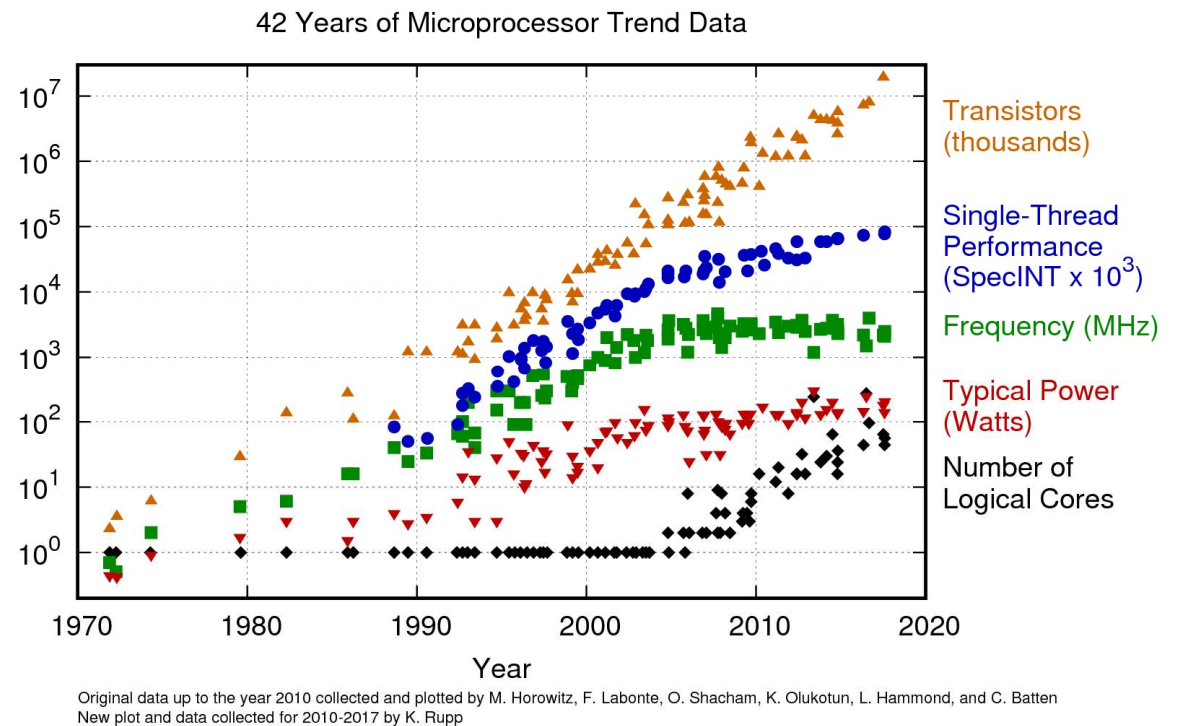
➤ **趋势与挑战**

➤ **产业案例**



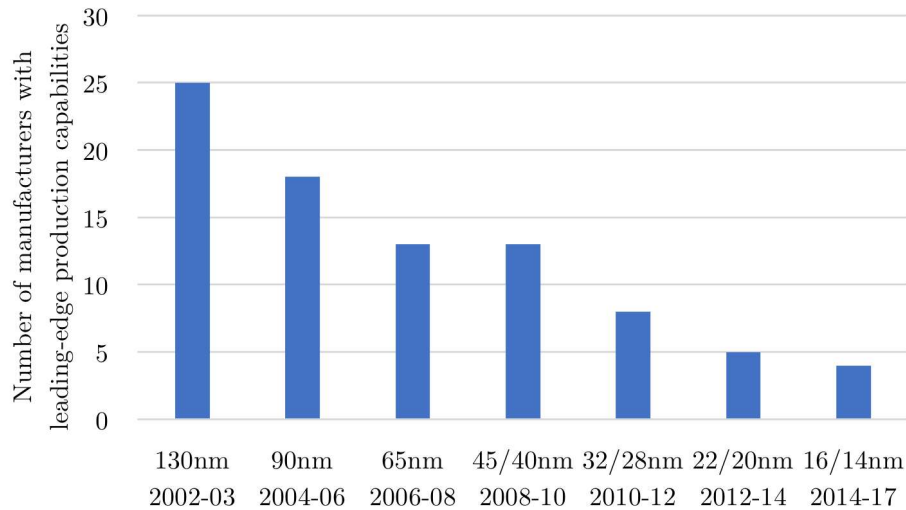
处理器的发展趋势

- Operating frequencies has saturated for the last 10 years. Dennard scaling is no more possible.
- Single-Thread performance is plateauing. No more complex, power hungry optimizations is added to processor design.
- But transistor count per chip is still doubling.
- This enabled more logical cores to be integrated on the same chip.
- This has maintained constant levels for power dissipations.
- Can we do better?



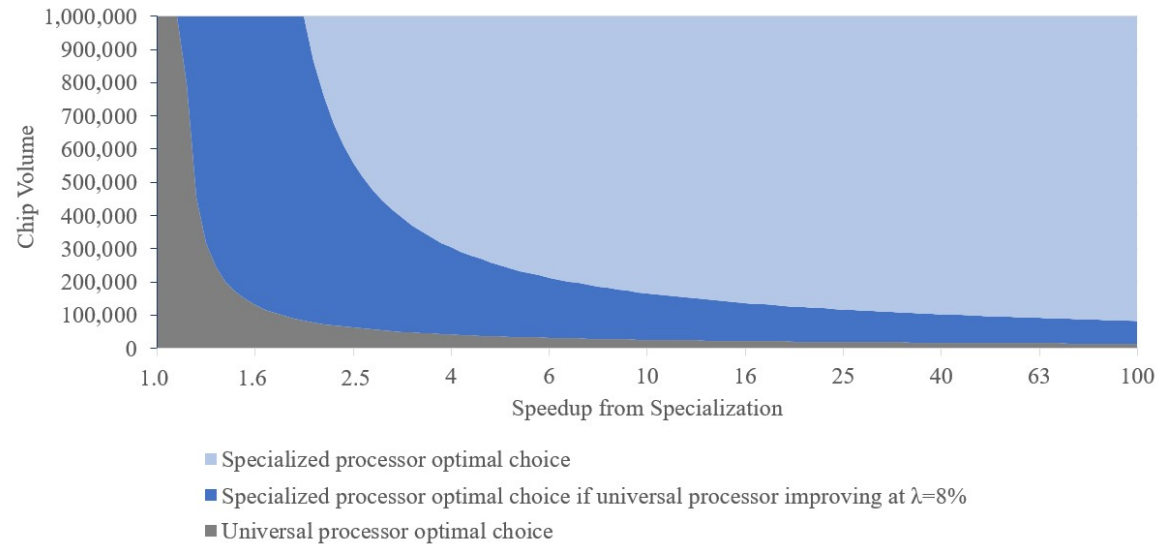
source: <https://www.karlrupp.net/2018/02/42-years-of-microprocessor-trend-data/>

通用算力持续发展的时代已经结束



Shrinking transistors has become much more expensive

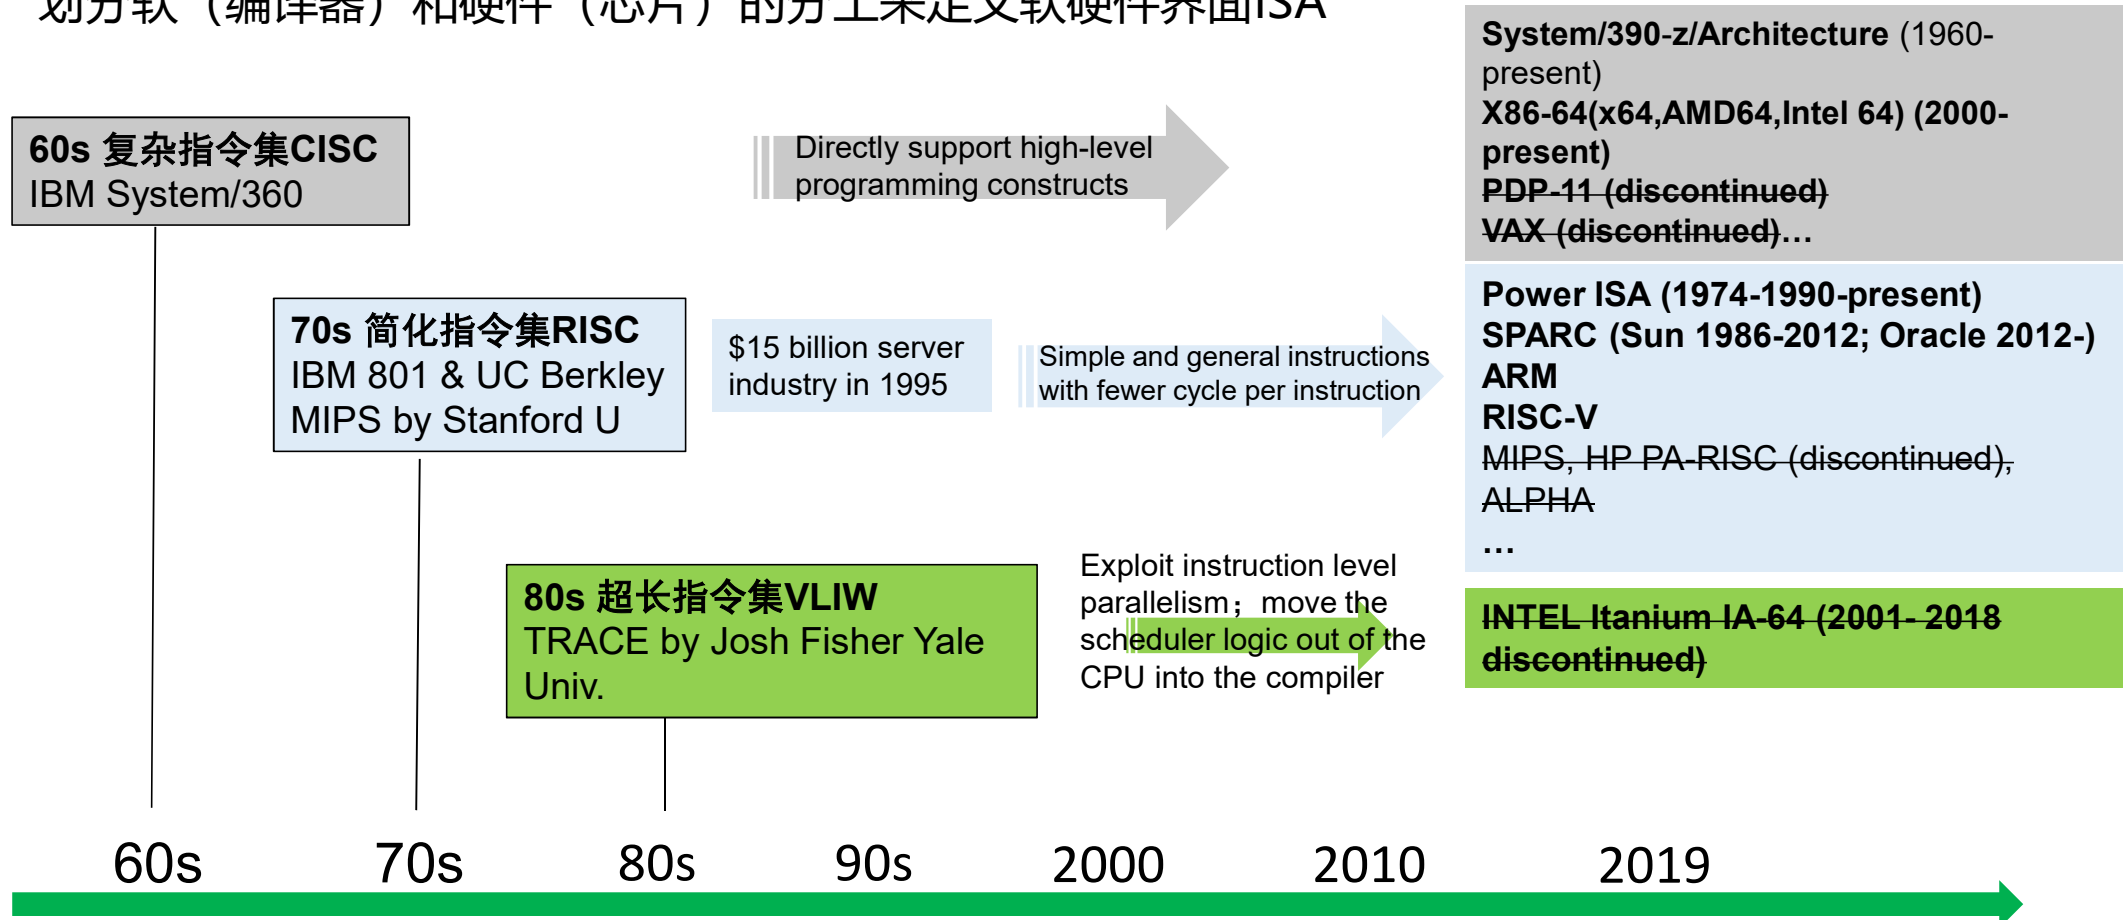
- \$7 billion to construct a new fab
- semiconductor manufacturers from 25, in 2002, to just four today
- Performance improvements have dropped from 48% annually in 2000-2004, to 29% in 2004-2008, to 8% in 2008-2013.



Many applications will be economically viable to run on specialized processors (computation parallelism, pattern regularity, memory access locality, lower precision)

指令集架构的演进 - CISC/RISC/VLIW

划分软（编译器）和硬件（芯片）的分工来定义软硬件界面ISA



处理器架构与编译技术的演进

单核优化

SSA-based optimization
Pointer analysis
Profile-guided optimization
Memory hierarchy optimization
Loop optimizations
Data reorganization
Link-time cross-module optimization
Automatic vectorization
just-in-time compilation for Dynamic Languages

多核优化

Continuous Program Optimization
Multicore and Parallel Programming

- Explicit parallelization
- Auto and semi-auto parallelization

Safety, Security and reliability incorporate more sophisticated auto-tuning strategies
Transactional memory
speculative optimizations

异构优化、超异构优化

Heterogeneous computing
Programming models and languages for productivity and performance
Dynamic and static compilation for multiple scenarios/applications
Compiler optimization for multi-ISA heterogeneous architectures (CPU/GPU/DSP/AI cores/FPGA)
Data movement communication optimization
Data and Thread placement
Multi-type memory optimization
Multi-ISA optimization ...
Analysis tools for correctness, security, performance
Auto performance tuning
AI/Machine Learning and Deep Learning with Compiler Technologies

CISC/RISC/
VLIW

通用单核芯片

2000 48% 2004

29%

性价比
瓶颈

同构通用多核芯片

2008

8%

2013

异构通用和专用芯片

2019

3%

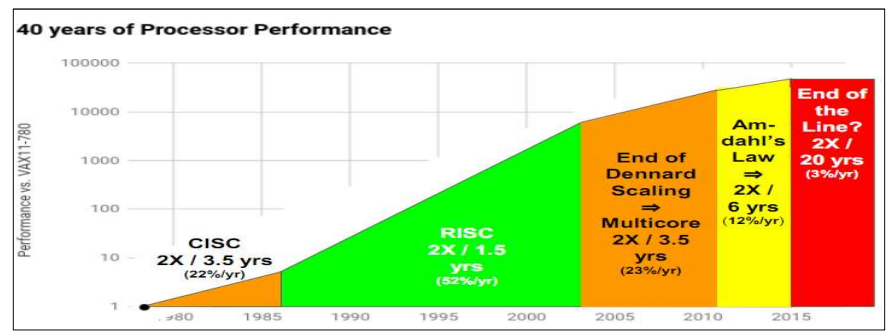


Single-core/Scalar/Superscalar → SIMD/Vector/SMT → multi-core/many-core → Heterogeneous Computing

后摩尔时代，芯片架构走向异构，快速演进的芯片和高复杂度的应用，对软件生产效率 和兼容性提出了前所未有的挑战 “software disaster”

David Patterson与John Hennessy指出 “The easy ride of software is over”：在异构计算时代，想要完全释放出异构芯片的计算能力，程序员必须既懂上层应用算法，又懂底层硬件模型，才能写出高效高质量代码，未来的编程工作会比现在更复杂

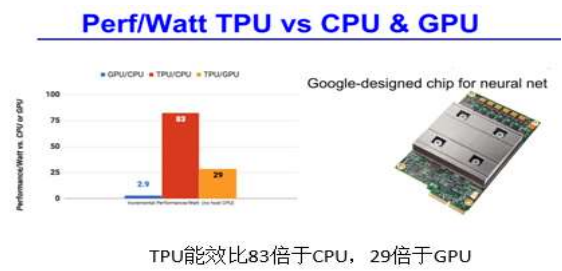
业界趋势



摩尔定律减速、
每年只有几个百分点的提升

- 不同领域的计算需要越来越多的异构资源
- 出现面向特定领域定制的体系结构 (DSA)

- 天河-2: 16,000个计算节点，每个节点 2*Xeon (IveBridge)+3*Phi。Total 3,120,000 cores。
Linpack: 33.86 petaFLOPS, Power 17.6 megawatts.
- Mac Pro: Intel Xeon E5 (6/8/2 cores) + Dual AMD FirePro D500 GPU (1526 stream processors, 2.2 teraflops, 3-way 4k video).
- Amazon Linux GPU Instances g2.xlarge: 4 GPU, 32 vCPU。
- Qualcomm Snapdragon 820: octa-core CPU+ Adreno 530 GPU+ Hexagon 680 DSP



开发者痛点

- 软件开发效率 “低”：
 - 普通开发者在上层应用算法和底层硬件模型无法做到两者皆懂，无法利用芯片能力实现程序性能的提升
 - 目前缺乏有效的轻量化实时编译方案，无法做到运行时代码生成。
- 兼容性 “差”，代码移植成本 “高”：
 - 芯片快速演进，开发者针对多芯片需要多次开发，代码移植成本很高
 - 体系结构层出不穷，开发者无法通过DSL语言，快速适配多形态芯片进行迭代式开发

如何解决3P问题 (Productivity, Performance, Portability)
支撑快速演进的芯片可编程性和解决软件兼容性问题，助力开发者实现高质量快速编程，降低代码迁移成本

➤ 趋势与挑战

➤ 产业案例



昇腾：高性能、高产能的AI编译器，助力Atlas发布最快AI训练集群

2019年9月18日HC2019，副董事长胡厚崑宣布，AI基础软件助力59.8s完成ResNet-50@imageNet模型训练，**超越原世界纪录10s**，并现场展示基于MindSpore实现10.02s内20万天体识别，成功发布**全球最快**的AI训练集群Atlas 900。



关键技术：

➤ Super Kernel优化技术

在二进制层面实现算子**Kernel融合调度**，最大化减少TS调度Kernel开销，Resnet50训练E2E性能**提升2~3s**，助力整体性能突破60s

➤ 并行编译、ccache优化

库上CCE算子构建时间从**15min+降到4min**，提升构建速度**3倍**

➤ 算子编译优化和代码生成技术

突破循环优化、同步算法、内存复用、多核多batch等优化技术，**数量级**提升TBE算子性能，**TBE成为D算子开发的统一框架**

方舟编译器作为P30关键特性发布

关键技术：

➤ Java全静态化编译技术

基于统一IR将Java直接编译为机器码，通过高强度编译优化提升运行效率。

➤ Java RC内存管理

配合编程约束后，可实现Java无GC停顿、RC低开销，对标Apple

➤ JNI自动拆墙优化

可将Java \leftrightarrow C/C++互操作开销降低10倍，调用开销像“一种语言”

安卓性能革命 华为方舟编译器

解决安卓程序“边解释边执行”的低效
架构级优化 显著提升性能

24%↑ 系统操作流畅度

44%↑ 系统响应

60%↑ 三方应用操作流畅度

本幻灯片中所列以下数据均为实验室测试数据，仅供参考。实际性能提升效果可能因设备、系统版本、应用版本、测试环境等因素而有所差异。华为方舟编译器目前仅在华为P30手机上进行商用部署，其他设备上的性能提升效果可能有所不同。请用户在实际使用中留意设备性能表现。

编程语言、编译器和指令集的设计与实现所关注的问题



编程语言：
表达、抽象

表达力强：
容易描述计算、业务逻辑
容易使用：好学、好写、好读
不易出错、代码安全

谢谢!

