

飞腾处理器上向量三角函数的设计实现与优化

沈洁 龙标 姜浩 黄春

(国防科技大学计算机学院 长沙 410073)

(j.shen@nudt.edu.cn)

Implementation and Optimization of Vector Trigonometric Functions on Phytium Processors

Shen Jie, Long Biao, Jiang Hao, and Huang Chun

(College of Computer, National University of Defense Technology, Changsha 410073)

Abstract Benefiting from SIMD (single instruction multiple data) vectorization, processors' floating-point compute capability has been increased largely. However, the current SIMD units and SIMD instruction sets only support basic operations like arithmetic operations (addition, subtraction, multiplication, and division) and logical operations, and do not provide direct support for floating-point transcendental functions. Since transcendental functions are the most time-consuming functions in floating-point computing, improving these functions' performance has become a key point in math library optimization. In this paper, we design and propose a new method that utilizes SIMD units to vectorize and optimize trigonometric functions (which are one class of transcendental functions). While most vector implementations use a unified algorithm to process all floating-point numbers, we select and import several optimizable branches from the scalar implementations to process different ranges of floating-point numbers. We further utilize a series of optimization techniques to accelerate the vectorized scalar code. By combining the piecewise computing of the scalar implementations and the vectorization advantage of the vector implementations, our method optimizes branch processing in vector trigonometric functions, reduces redundant computation, and increases the utilization of SIMD units. Experimental results show that our method meets accuracy requirement, and effectively improves trigonometric functions' performance. Compared with original vector trigonometric functions, the average performance speedup of optimized functions is 2.04x.

Key words vector trigonometric functions; segmented computing; SIMD vectorization; performance optimization; Phytium processors

摘要得益于单指令多数据(single instruction multiple data, SIMD)向量化技术,处理器浮点计算能力获得了成倍的提升,然而当前 SIMD 向量部件和指令集仅支持加、减、乘、除、逻辑运算等基本操作,对浮点超越函数没有提供直接的支持。作为浮点计算中最耗时的一类函数,如何提高其性能成为底层数学库优化工作的一个重点。面向超越函数中的三角函数,提出一种利用 SIMD 向量部件设计、实现与优化向量三角函数的方法。该方法结合标量数学库分段计算与向量数学库向量化实现的优势,增加和优化了向量三角函数中的分支处理,既减少了函数实现中的冗余计算,又提高了分支情况下向量部件的利用

收稿日期:2019-10-11;修回日期:2020-04-03

基金项目:“核高基”国家科技重大专项基金项目(2018ZX01029-103);国家自然科学基金项目(61902407);湖南省自然科学基金资助项目(2018JJ3616)

This work was supported by the National Science and Technology Major Projects of Hegaoji (2018ZX01029-103), the National Natural Science Foundation of China (61902407), and Hunan Provincial Natural Science Foundation of China (2018JJ3616).

通信作者:黄春(chunhuang@nudt.edu.cn)

率。在飞腾处理器上的实验表明:所提优化方法既保证了向量三角函数的精度,同时有效提高了函数性能,与原始向量三角函数相比平均性能加速比为2.04倍。

关键词 向量三角函数;分段计算;SIMD向量化;性能优化;飞腾处理器

中图法分类号 TP311

三角函数在导航、测绘、工程、物理学等科学计算类应用中使用广泛,由于三角函数算法实现的复杂性,这些函数往往是应用中最耗时的浮点计算函数,因此如何提高三角函数性能成为科研人员设计和优化浮点计算函数的一个重点。

与此同时,单指令多数据(single instruction multiple data, SIMD)向量化对发挥当今处理器浮点计算性能至关重要^[1-2]。从x86处理器上的SSE(streaming SIMD extensions),AVX(advanced vector extensions)到最新的AVX512F(AVX-512 foundation)向量指令集,从ARM处理器的ADVSIMD(advanced SIMD)到SVE(scalable vector extension)向量指令集^[3],可以看出随着体系结构的发展,处理器向量宽度正在逐步加宽、并变得更加灵活可用。然而,目前主流处理器平台上的SIMD向量指令集仅包括对基础的加、减、乘、除等算术运算以及逻辑运算、访存操作、位运算等基本操作的支持,对于复杂的浮点三角函数(以及其他超越函数)没有提供直接的支持。

科研人员通常采用软件方式设计数学库以实现三角函数等超越函数。当前,应用广泛的数学库有GNU libm库(GNU math library)^[4]、Intel libimf库(Intel math library)^[5]、Intel SVML库(Intel short vector math library)^[6]等。其中GNU libm库和Intel libimf库是标量数学库,未能利用SIMD向量部件提高函数性能,而Intel SVML库虽然是向量数学库,但属于Intel设计和开发的商用数学库,仅面向x86处理器平台实现向量化。近来,科研人员提出了Sleep开源向量数学库^[7-8],该数学库具有良好的模块化和跨平台特性,可支持多种SIMD向量指令集,在多种处理器平台上实现超越函数向量化。然而,Sleep为了实现向量化,以增加冗余计算为代价,换取函数中分支语句的减少。这样,虽然增加了SIMD向量部件的利用率,但冗余计算在一定程度上还是导致了性能损失。

因此,本文基于Sleep开源向量数学库,面向飞腾处理器平台,进一步优化向量三角函数的性能。首先,我们通过完备深入的测试,发现Sleep向量三角

函数实现中的性能瓶颈。然后,我们借鉴GNU libm库实现方法中的部分分支算法,针对性地提出了一种支持分支处理的向量三角函数优化方法。基于此,我们还使用了分支预测、精度削减、查表优化、条件传递优化、精度修正、性能修复等优化技术以尽可能减少引入分支后带来的向量化开销。本文所提优化方法结合Sleep向量数学库和GNU libm标量数学库各自的优势,有效提高了向量三角函数的性能。最后,我们将所提优化方法实现为Sleep的一个模块,移植入Sleep数学库中。我们在飞腾处理器上进行实验验证,结果表明我们提出的优化方法在保证向量三角函数精度的前提下,有效提高了向量三角函数性能,与原始Sleep向量三角函数相比,加速比可达1.12~3.97倍。

1 相关背景

1.1 三角函数及其软件实现

三角函数一般通过规约、近似和重建3个步骤获得近似值^[9-10]。1)规约。根据三角函数的对称性和周期性,将任意区间映射到[0,π/4]区间。2)近似。通过泰勒级数展开计算[0,π/4]区间的三角函数近似值。例如,sinx可以计算为

$$\sin x = \sum_{n=0}^{\infty} \frac{(-1)^n}{(2n+1)!} x^{2n+1} = x - \frac{x^3}{3!} + \frac{x^5}{5!} - \dots,$$

由于sinx在该区间内是收敛的,因此通过展开若干次可以获得sinx的近似值。3)重建。任意区间三角函数值可以通过[0,π/4]区间三角函数值表示。此外,对于一些特殊值的三角函数,可以绕过上述常规过程进行特殊处理(例如0、无穷大等,可以不经过计算直接返回结果)。

在通用处理器上,三角函数等超越函数通常以软件方式集成在数学库中实现。程序员调用数学库中的三角函数接口,由数学库中的相关代码实现相应的函数运算。目前,常用的数学库有Linux操作系统上的GNU libm库、面向Intel处理器的Intel libimf库、ARM发布的libmathlib库(ARM optimized routines)^[11]等,其中GNU libm和ARM libmathlib是开源数学库,Intel libimf是Intel特别为其处理

器设计和优化的商用数学库。这些数学库都属于标量数学库,一次调用计算一个浮点操作数。因此,为了充分利用处理器上的向量部件和向量指令集以优化程序中的三角函数计算,科研人员设计和开发了向量三角函数。

1.2 向量三角函数及其软件实现

相比标量三角函数,向量三角函数内部使用 SIMD 指令实现向量化,根据处理器向量部件的宽度,一次调用同时计算多个浮点操作数,因而其理论性能是标量三角函数的数倍。在实现时,向量三角函数仍保留规约、近似和重建 3 个核心步骤,并使用 SIMD 指令对应的内部函数(intrinsics)或直接使用汇编指令进行向量化。

目前比较成熟的实现是 Intel SVML 数学库,这是 Intel 开发的一套商用向量数学库,虽然已经部分开源并纳入 GNU 的标准 C 库(GNU glibc)中^[12],但其应用依然局限于 x86 平台。近来,科研人员相继实现并发布了一些开源向量数学库。其中,奈良先端科学技术大学院大学开发的 Sleef 开源向量数学库,为多种硬件平台上的向量超越函数实现提供了支持。Lauter^[13]设计的向量 libm 库(vector libm)实现了双精度三角函数,但其计算精度较低。欧洲核子研究组织发布了 VDT 向量数学库(vectorised math),其实现依赖于第三方库进行多项式近似,因而其可向量化的程度受限^[14]。本文是基于 Sleef 向量数学库设计和优化向量三角函数的,主要针对 12 个三角函数进行设计实现与优化,这 12 个函数具体如表 1 所示:

Table 1 Vector Trigonometric Functions to be Optimized

表 1 待优化向量三角函数

Function	Description
sin	sin function in double precision
cos	cos function in double precision
tan	tan function in double precision
asin	arcsin function in double precision
acos	arccos function in double precision
atan	arctan function in double precision
sinf	sin function in single precision
cosf	cos function in single precision
tanf	tan function in single precision
asinf	arcsin function in single precision
acosf	arccos function in single precision
atanf	arctan function in single precision

此外,硬件实现超越函数虽然能很快返回计算结果,但仅有少量非通用体系结构提供超越函数的硬件实现^[15],因而应用受限,不属于本文的研究范畴。

1.3 Sleef 向量数学库

Sleef 是一款基于 C 语言编写的多平台向量数学库,提供了单精度和双精度 2 个版本,并实现了 C99 标准下所有实浮点数学函数的向量化。Sleef 支持多种处理器架构和 SIMD 指令集,目前 Sleef 支持 x86(SSE2, SSE4.1, AVX, FMA4, AVX2+FMA3, AVX512F 指令集),AArch64(ADVSIMD, SVE 指令集)和 PowerPC64(VSX 指令集)。

由于各 SIMD 向量指令集的向量类型和 intrinsics 函数存在较多差异,为了支持多种处理器平台,Sleef 采用模块化封装和抽象,面向不同指令集抽象出一套通用的 Sleef 向量类型(包括 vdouble, vfloat, vint, vint2, vopmask, vmask 共 6 种向量类型)和 Sleef intrinsics 函数(包括向量浮点和整型算术运算、逻辑运算、位运算、类型转换、条件传送等函数)。Sleef 代码结构如图 1 所示,底层在头文件中实现 Sleef 向量类型和 Sleef intrinsics 函数到各指令集向量类型和 intrinsics 函数的映射(一个指令集对应一个头文件),上层使用 Sleef 向量类型和 Sleef intrinsics 函数实现各超越函数算法,编译器在编译时会根据所在处理器平台自动将 Sleef 向量类型和 Sleef intrinsics 函数替换为指定指令集的向量类型和 intrinsics 函数,从而达到编写一份 Sleef 超越函数算法、在不同处理器平台上编译运行的目的。正是这种封装和模块化设计使得 Sleef 具有良好的可扩展性和可移植性,只要符合 Sleef 代码规则,就可以

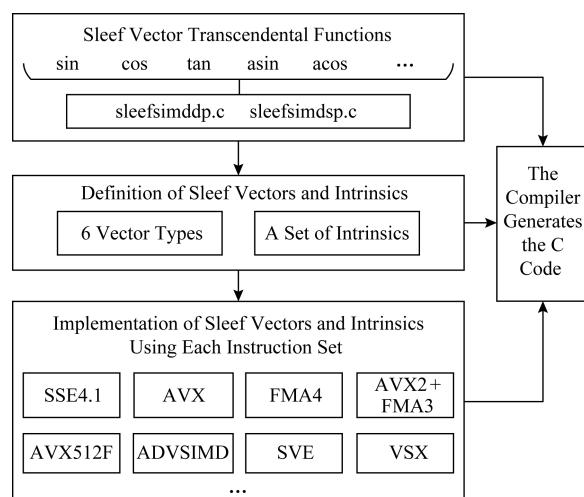


Fig. 1 The code structure of Sleef vector math library

图 1 Sleef 向量数学库代码结构

方便地增加和修改向量数学函数或增加对新的处理器平台和指令集的支持。本文基于 Sleef 向量数学库在飞腾处理器平台上优化向量三角函数。

1.4 数值结果精度和误差

为了更加精确地分析向量三角函数实现的精度,本文采用 ulp (unit in the last place)衡量计算结果误差。根据 Goldberg 定义^[16-17], ulp 是最接近实数真实值的 2 个浮点数之间的距离。假设函数真值为实数 x ,其对应的浮点数计算结果 X 可表示为 $d_0.d_1d_2d_3\dots d_{p-1}\beta^e, x \in [\beta^e, \beta^{e+1})$,则

$$ulp(x) = \beta^{\max(e, e_{\min}) - p + 1},$$

其中, β 是基, e 是阶数, $d_0.d_1d_2d_3\dots d_{p-1}$ 是尾数, p 是精度即浮点数尾数的有效位数(在 IEEE754 标准下单精度 $p=24$, 双精度 $p=53$)。

本文实验中, X 由待测三角函数计算得出, x 由任意精度算法库 MPRF 库^[18]中对应的三角函数计算同样的操作数得出,通过计算 x 与 X 的绝对误差 $|x-X|$ 的单位 ulp 数,从而评价待测三角函数的精度。一般情况下,三角函数等超越函数的精度需控制在 $0.5ulp \sim 1.0ulp$ 以内。

由于科学计算类应用中存在大量可并行的三角函数数值计算,这些计算十分耗时,因此本文将面向飞腾处理器,基于 Sleef 向量数学库,在保证一定精度的前提下优化向量三角函数性能。

2 向量三角函数设计与优化

2.1 优化方法

我们调研了向量数学库中三角函数的实现方

法,发现虽然在算法上向量三角函数仍然采用规约、近似和重建 3 个步骤,但会尽量避免使用标量三角函数实现中广泛采用的分支处理,这是因为如果同一向量中的不同元素进入不同分支,那么向量化将受到影响,不同分支中的元素不能同时进行运算。Sleef 向量数学库正是如此,为了充分利用 SIMD 指令的并行处理能力,减少分支操作,Sleef 向量数学库在实现向量三角函数算法时不区分操作数的特征,采用统一算法处理所有操作数。该实现方法虽然尽可能避免了算法中的分支语句,提升了处理器 SIMD 向量单元的利用率,但也导致了向量三角函数在处理一些操作数时的冗余计算(例如 cos 函数在计算绝对值小于 2^{-27} 的操作数时,可以不需要经过计算而直接将 1.0 作为计算结果返回)。相反,libm 数学库作为标量数学库,为了尽可能减少函数串行计算的计算量,对三角函数的操作数进行了分段,利用三角函数的性质,对不同的操作数范围采用不同的算法(分支)实现运算,从而提高函数运算的速度。

本文将结合 Sleef 向量化和 libm 分段计算的优势,以 libm 的分段计算为指导,将分段计算引入 Sleef 向量数学库中,从而进一步提高向量三角函数的性能。换言之,我们提出一种在向量数学库中使用分支以优化函数性能的方法。本文的基本优化方法如图 2 所示。

针对每个三角函数,首先我们对 libm 三角函数中的操作数范围分支进行筛选,当某个或某些操作数范围分支的计算量较小、执行速度较快时(也就是说该分支值得被向量化用以替换原始 Sleef 函数),则将其提取出来并使用 Sleef intrinsics 函数进行

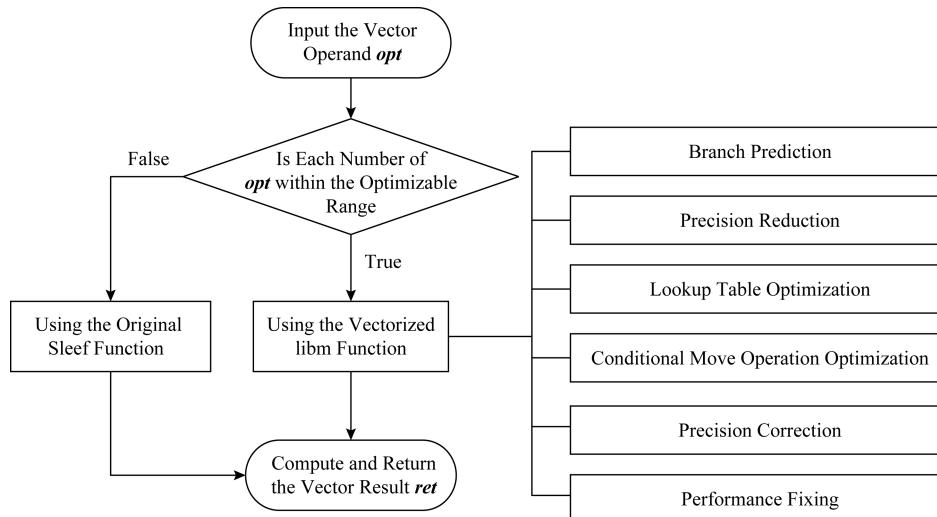


Fig. 2 Vector trigonometric function optimization

图 2 向量三角函数优化方法

向量化.在实际应用中,优化后的三角函数在运行时会判断向量操作数 opt 中各元素是否均在可优化操作数范围内,如果是则进入向量化的 libm 分支,否则进入原始 Sleef 分支,最后计算出向量结果 ret 返回.对 libm 函数分支进行筛选时,既要保证函数运算的时间优于原始 Sleef 函数运算时间,又要保证函数运算的结果满足精度要求(最大误差控制在 $1.0ulp$ 以内).在实现时,我们通过大量实验确定每个三角函数可移植的操作数范围分支,同时在向量化 libm 函数分支的过程中,我们还使用了分支预测、精度削减、查表优化、条件传送优化、精度修正和性能修复一系列优化技术以进一步加快函数运算速度.

1) 分支预测.如图 2 所示,我们的优化方法是以分支的形式添加至原始 Sleef 代码中的,这就在代码中引入了执行分支语句、进行分支预测所带来的开销.为了尽可能减少分支语句对函数性能的影响,降低分支预测失败的开销,我们使用各个编译器支持的分支预测函数(如 gcc 编译器的 `_builtin_expect` 函数)对 2 个分支执行的概率进行调整,以大概率执行原始 Sleef 分支,小概率执行向量化的 libm 分支,这是因为我们通过实验确定的每个函数的可优化操作数范围相对于整个实数域仍是一个小范围,因此我们认为设定以大概率执行原始 Sleef 分支是合理的.只有一个例外是 atanf 函数,因为经过实验我们发现其可优化操作数范围是整个实数域(详见 2.2 节),因此实现时是将原始 Sleef 分支整个替换为向量化的 libm 分支,因此不会受到分支预测优化的影响.Sleef 库中已经将各个编译器的分支预测函数进行了打包,函数接口分别是 `LIKELY()` 和 `UNLIKELY()`.

2) 精度削减.libm 的部分三角函数在一些操作数范围内的计算精度很高(最大误差在 $0.5ulp$ 以内),代码中将对计算结果的精度进行判断,如果精度不够则进入下一层分支进行细化计算,从而达到更高的精度要求.由于 Sleef 的精度控制相比 libm 宽松一些,因此在移植 libm 分支时我们可以删除一些高精度分支,以降低计算开销.

3) 查表优化.标量三角函数实现时通常将函数计算所用到的常系数写在表中,并使用查表操作以减少函数计算量.原始 Sleef 向量数学库在实现时尽量规避了查表操作,这是因为进行向量查表会涉及到使用聚合(gather)访存指令,将内存中不同位置的常系数值加载到一个向量寄存器中,供向量中的不同元素使用,这种聚合访存因访存不连续往往需

要多次访存操作才能完成,从而影响三角函数向量化的性能.我们发现当函数中需要进行查表操作,而查表所需表的大小小于向量宽度时,仍然可以使用查表操作加速函数计算.首先,使用向量 load 指令先将表中的数据从内存一次加载至向量寄存器中,然后使用特定的 permute, blend, shuffle 向量操作指令将这些数据存放至向量中的指定位置,从而代替向量 gather 操作,这样既保留了查表操作并减少了函数计算量,同时又降低了向量查表可能引入的多次内存读写的开销.目前支持特定 permute, blend, shuffle 向量操作的指令集有 AVX2, AVX512F, SVE.

4) 条件传送优化.向量代码中可以使用类似三目运算符 $x = a ? b : c$ 功能的简单条件运算,编译器编译时会将其翻译成向量条件传送指令.例如 ADVSIMD 指令集中的 BSL, BIT, BIF 指令.本质上这些指令可以等价为若干按位逻辑操作的组合,如图 3 所示:

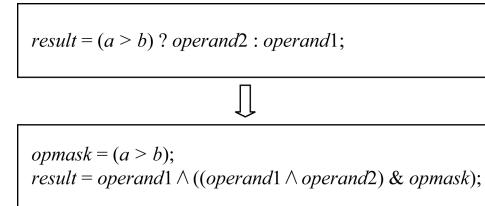


Fig. 3 Conditional move operation is implemented by bit operation

图 3 条件传送操作实现为按位逻辑操作

当优化代码中使用这种条件传送运算的操作数是一些特殊值时(比如 1 个源操作数为 0 或者 2 个源操作数互为相反数),我们可以使用更加简单的按位逻辑操作组合而不是直接使用向量条件传送语句,从而达到提升性能的目的.向量条件传送优化如图 4 所示.

5) 精度修正.当计算某几个特定操作数结果有误时(如 atanf 函数在计算 $|x| \geq 2^{34}$ 的操作数时),如图 5 我们将在代码最后使用向量条件传送语句来修正结果向量中的错误元素.

6) 性能修复.我们发现优化代码在处理可优化操作数范围内的一些特殊操作数时,在运行时可能会进入非规格化数处理的情况下而变得十分缓慢.为了解决这个问题,我们使用了类似于精度修正的方法来规避这种潜在的性能问题.如图 6 所示,我们的优化代码在开始计算之前会先判断操作数是否落入特殊操作数范围内,并使用条件传送语句将操作

```
float func (float x)
{
    float y;
    y = x > 0.0 ? x : 0.0;
    return y;
}
```



```
float func (float x)
{
    /* reinterpret the scalar floating-point number to binary bits */
    int32_t mask1 = floatToRawIntBits (x);
    int32_t mask2 = mask1;
    mask1 = mask1 >> 31;
    mask2 = (~mask1) & mask2;
    /* reinterpret binary bits to the scalar floating-point number */
    float y = intBitsToFloat (mask2);
    return y;
}
```

(a) Optimization for the scalar operand

```
float func (vfloat x)
{
    vfloat y;
    vfloat vzero = vcast_vf_f(0.0);
    vopmask vo = vgt_vo_vf_vf(x, vzero);
    y = vsel_vf_vo_vf_vf(vo, x, vzero);
    return y;
}
```



```
float func (vfloat x)
{
    /* reinterpret the vector of floating-point numbers to binary bits */
    vint2 mask1 = vreinterpret_vi2_vf(x);
    vint2 mask2 = mask1;
    mask1 = vsra_v2_v2_i(mask1, 31);
    mask2 = vandnot_v2_v2_v2(mask1, mask2);
    /* reinterpret binary bits to the vector of floating-point numbers */
    vfloat y = vreinterpret_vf_v2(mask2);
    return y;
}
```

(b) Optimization for the vector operand

Fig. 4 Conditional move operation optimization

图4 条件传送优化

数中可能导致性能问题的元素替换为普通操作数。计算结束后再使用同样的条件传送语句将计算结果(即错误的结果)替换为正确值。由于导致被优化函数陷入非规格化数的缓慢分支对应的特殊操作数范围可以确定出来,其计算结果往往可以被近似为一个常量,因此可以提前计算得出正确的计算结果,并在代码中直接使用。

需要指出的是,原则上我们尽可能对每个向量三角函数使用上述所有优化方法,但由于各个函数内在算法的差异性,上述优化方法不一定适用于每一个函数。其中,分支预测优化应用于所有函数中,精度削减应用于所有双精度函数中,条件传送优化和精度修正只使用在 `asinf`, `acosf`, `atanf` 函数中,性能修复只使用在 `atanf` 函数中,而查表优化则因为

```
double func (double x){
{
    /* compute code */
    ...
    /* y is the result */
    double y = result;
}
double errorOpt = CONST1;
double exactVaule = CONST2;
/* precision correction */
y = (x == errorOpt ? exactVaule : y);
return y;
```

(a) Optimization for the scalar operand

```
vdouble func (vdouble x){
{
    /* compute code */
    ...
    /* y is the result */
    vdouble y = result;
}
double errorOpt = CONST1;
double exactVaule = CONST2;
/* precision correction */
vopmask vo = veq_vo_vd_vd(x, vcast_vd_d(errorOpt));
y = vsel_vd_vo_vd_vd(vo, y, vcast_vd_d(exactVaule));
return y;
```

(b) Optimization for the vector operand

Fig. 5 Precision correction

图5 精度修正

```
double func (double x){
    int vo = (x <= badOpt);
    x = (vo ? normalVal : x);
{
    /* compute code */
    ...
    /* y is the result */
    double y = result;
}
double exactVaule = CONST1;
y = (vo ? exactVaule : y);
return y;
```

(a) Optimization for the scalar operand

```
vdouble func (vdouble x){
    vopmask vo = vle_vo_vd_vd(x, vcast_vd_d(badOpt));
    x = vsel_vd_vo_vd_vd(vo, vcast_vd_d(normalVal), x);
{
    /* compute code */
    ...
    /* y is the result */
    vdouble y = result;
}
double exactVaule = CONST1;
y = vsel_vd_vo_vd_vd(vo, vcast_vd_d(exactVaule), y);
return y;
```

(b) Optimization for the vector operand

Fig. 6 Performancefixing

图6 性能修复

ADVSIMD 指令集不支持 permute 操作而只使用在了 SVE 指令集的 atanf 函数中。

2.2 具体实现

结合 Sleef 向量数学库和 libm 标量数学库, 我们一共对 12 个三角函数(包括单精度和双精度)的向量版本进行了优化。我们通过大量实验确定了各个函数可优化的操作数范围, 具体如表 2 所示。我们发现如果 libm 某个函数的某个分支代码中包含大量的分支跳转语句, 该分支将不值得移植和向量化, 除非这些条件跳转比较简单可以转换为条件传送。另外, atanf 函数的可优化操作数范围是整个实数域, 因为我们发现向量化后的 libm 函数在整个范围内的性能均优于原始 Sleef 函数。

在代码移植和向量化的过程中, 我们在原 Sleef 向量数学库的基础上增加了 7 个新的 Sleef intrinsics

函数, 如表 3 所示。其中, vint2, vdouble, vfloat 分别代表整型向量类型、双精度浮点数向量类型和单精度浮点数向量类型, $vgather_{vi2_p_vi2}()$ 与 $vgather_{vf_p_vi2}()$ 为前文所提的为查表优化打包的函数。

Table 2 The Optimization Range of Vector Trigonometric Functions

表 2 各向量三角函数可优化操作数范围

Double Precision	The Optimizable Range	Single Precision	The Optimizable Range
sin	(-0.25, 0.25)	sinf	(-0.785, 0.785)
cos	(-0.785, 0.785)	cosf	(-0.3, 0.3)
tan	(-0.0608, 0.0608)	tanf	(-0.67, 0.67)
asin	(-0.125, 0.125)	asinf	[-1.0, -0.5] & [0.5, 1.0]
acos	(-0.125, 0.125)	acosf	[-1.0, -0.5] & [0.5, 1.0]
atan	(-0.0625, 0.0625)	atanf	Real numbers

Table 3 New Sleef Intrinsics

表 3 优化过程中新增加的 Sleef Intrinsics 函数

New Sleef Intrinsics	Description
vint $vcastou_{vi_vi2}(vint2 \mathbf{x})$;	Extract odd vector elements of the vint2 vector
vint $vcasteu_{vi_vi2}(vint2 \mathbf{x})$;	Extract even vector elements of the vint2 vector
vdouble $vmlanp_{vd_vd_vd_vd}(vdouble \mathbf{x}, vdouble \mathbf{y}, vdouble \mathbf{z})$;	Negate multiply-subtract for the vdouble vector
vfloat $vmlapn_{vf_vf_vf_vf}(vfloat \mathbf{x}, vfloat \mathbf{y}, vfloat \mathbf{z})$;	Multiply-subtract for the vfloat vector
vint2 $vgather_{vi2_p_vi2}(int *ptr, vint2 \mathbf{x})$;	Gather operation for the vint2 vector (without lookup table optimization)
vint2 $vgather_{vi2_p_vi2}(int *ptr, vint2 \mathbf{x})$;	Gather operation for the vint2 vector (with lookup table optimization)
vfloat $vgather_{vf_p_vi2}(const float *ptr, vint2 \mathbf{x})$;	Gather operation for the vfloat vector (with lookup table optimization)

优化的代码是以模块化方式移植入 Sleef 向量数学库中, 从而保证这部分优化代码的独立性, 也方便后续 Sleef 更新后, 能将优化代码快速合并到新的 Sleef 中。具体实现时, 我们将每个函数的优化代码放置于一个单独 xxxx_opt.c 文件中, 例如单精度函数放置于 opt_include/single/yyyy_opt.c 文件中, 而双精度函数放置于 opt_include/double/yyyy_opt.c 文件中, 所有优化函数共同需要的常量和函数则统一放置于头文件 opt_include/opt_vecf_helper.h 中, 为函数优化新增的 intrinsics 函数则放置于 opt_include/sleef_arch_patch.h 中, 通过宏定义和 include 语句将这些文件导入 Sleef 源码中, 在编译时通过控制编译选项-DCMAKE_C_FLAGS = “-DOPT_LB”来选择是否开启优化, 图 7 显示了模块化优化方式的伪代码。

最后需要说明的是, 虽然我们面向飞腾处理器进行实验, 但本文所述优化方法和基于 Sleef 的模块化实现也可以扩展至其他处理器平台和向量指令集。

```
/* src/libm/sleefsimdsp.c */
#ifndef OPT_LB
#include "opt_include/off_on.h"
#include "opt_include/sleef_arch_patch.h"
#include "opt_include/opt_vecf_helper.h"
#endif

{
    /* Sleef original code */
    ...
}

/* opt code for the Sleef asinf function */
#ifndef OPT_LB
#include "opt_include/single/asinf_opt.c"
#else
{
    /* Sleef original asinf code */
    ...
}
#endif

{
    /* Sleef original code */
    ...
}
```

Fig. 7 Porting optimized code into Sleef

图 7 以模块化方式植入优化代码

3 实验结果与分析

3.1 实验设计与环境

本文结合 Sleef 和 libm 对向量三角函数进行优化,并在飞腾处理器上对优化后的向量三角函数进行功能验证、精度实验和性能实验。其中,功能验证是验证优化后的向量三角函数功能是否正确,精度实验是具体分析优化后向量三角函数计算精度的变化,性能实验是对比我们提出的优化方法是否能进一步提升向量三角函数的性能。

本文实验主要在飞腾处理器上进行(FT-1500A/16,兼容 ADVSIMD 指令集,向量宽度为 128 b)。此外,为了进行全面的功能验证,我们还使用了 x86 处理器平台以验证 SSE2,AVX,AVX2 指令集,以及 ARM Instruction Emulator 模拟器以验证 SVE 指令集。我们使用的 Sleef 版本为 3.3.1 版本,libm 版本为 GNU Glibc Linaro-2.20 版本。

3.2 功能验证

我们对所有优化后的向量三角函数进行严格的功能性验证,具体包括 6 项验证内容。

1) 优化后函数在可优化操作数范围内的计算精度是否满足设计时要求。该项验证要求待测试向量操作数中的各个元素不一致,且最终每个元素对应的计算结果的最大误差控制在 $1.0ulp$ 以内。

2) 优化后函数在可优化操作数范围边界及其附近的计算精度是否满足设计时要求。同样要求待测试向量操作数中的各个元素不一致以及最终结果的最大误差控制在 $1.0ulp$ 以内。这是用以检验被优化函数在算法边界处的处理是否正确。

3) 优化后函数在可优化操作数范围外的计算精度是否仍然满足设计时要求,这是用以检验本文提出的优化方法不会对可优化操作数范围外的计算产生精度方面的负面影响。

4) 优化后函数对浮点数域内的特殊浮点常量的计算结果是否正确。包括验证对浮点数 $\pm 0, \pm \infty$, NaN 的计算结果是否等于对应的 C99 标准下规定的浮点值,验证 ± 1.0 、正负最大最小非规格化数、正负最大最小规格化数的计算结果是否正确,以及验证被优化函数对大浮点数的处理是否正确(所有双精度函数检验操作数为 $\pm 1E+10$ 的计算结果,所有单精函数检验操作数为 $\pm 1E+7$ 的计算结果)。

5) 优化后函数在计算与算法相关的特殊浮点常量时的计算结果是否正确。其中,双精度 \sin, \cos ,

\tan 函数和单精度 \sinf, \cosf, \tanf 函数需要检查操作数为 $\pi/4$ 的倍数时的计算结果,双精度 \sin, \cos 函数和单精度 \sinf, \cosf 函数需要检验操作数趋于 ± 1.0 时的计算结果,这些计算结果的误差要控制在 $1.0ulp$ 以内。

6) 多种情况组合下的功能验证,将前 5 项中列出的各种情况下的浮点操作数组合到同一向量中,测试每个向量元素的计算结果是否达到精度要求(同样要满足最大误差在 $1.0ulp$ 以内),这是用以检验优化函数中的分支处理与特殊值处理等是否正确。

我们在飞腾处理器平台、x86 处理器平台和 ARM Instruction Emulator 模拟器上对不同 SIMD 向量指令集进行功能验证。实验证明对于飞腾处理器平台的 ADVSIMD 指令集、x86 平台的 SSE2, AVX, AVX2 指令集、以及 ARM Instruction Emulator 模拟器上的 SVE 指令集,优化后的向量三角函数均通过了功能验证,这表明我们对向量三角函数的优化达到了 Sleef 库的标准,可以移植入 Sleef 库中使用。

3.3 精度实验

对每个优化后的向量三角函数,精度实验以指定步阶从小到大测试可优化操作数范围内的浮点数,我们使用任意精度 MPFR 库作为参考标准,计算优化后三角函数的计算结果与 MPFR 库中相同函数的计算结果的具体误差(以 ulp 形式表示)。实验将循环迭代次数控制在 10^7 次,并统计出最大误差和平均误差的 ulp 值。我们在飞腾处理器上进行精度实验,结果如表 4 所示:

Table 4 Precision Experiment Results

表 4 精度实验结果

Function	The Optimizable Range	max(ulp)		Average(ulp)	
		BO	AO	BO	AO
sin	(-0.25, 0.25)	0.53	0.52	0.25	0.25
sinf	(-0.785, 0.785)	0.60	0.68	0.25	0.25
cos	(-0.785, 0.785)	0.79	0.50	0.25	0.25
cosf	(-0.3, 0.3)	0.93	0.56	0.26	0.25
tan	(-0.0608, 0.0608)	0.53	0.50	0.25	0.25
tanf	(-0.67, 0.67)	0.74	0.82	0.25	0.25
asin	(-0.125, 0.125)	0.72	0.50	0.26	0.25
asinf	[-1.0, -0.5] & [0.5, 1.0]	0.66	0.65	0.25	0.25
acos	(-0.125, 0.125)	0.51	0.50	0.25	0.25
acosf	[-1.0, -0.5] & [0.5, 1.0]	0.57	0.71	0.25	0.27
atan	(-0.0625, 0.0625)	0.82	0.51	0.27	0.25
atanf	Real numbers	0.93	0.85	0.25	0.26

Note: BO(before optimization), AO(after optimization)

可以看出,相比优化前、优化后的向量三角函数在可优化操作数范围内的精度变化很小,最大误差的变化在 $0.37ulp$ 以内,平均误差的变化在 $0.17ulp$ 以内,此外,除 \sinf , \tanf , \acosf 函数外,其余函数在优化后的最大误差还有所降低(最大降低了 $0.37ulp$)。这说明本文所提出的优化技术对函数精度的影响较小,函数精度变化是符合要求的。

3.4 性能实验

我们从 2 个方面分析评估本文所提出的向量三角函数优化方法:1)通过与 libm 标量三角函数以及原始 Sleef 向量三角函数进行对比,以分析优化方法对向量三角函数的性能提升;2)分析所提优化方法所引入的开销。所有性能实验在飞腾处理器上进行。

3.4.1 优化方法带来的性能提升

对于每个向量三角函数,我们在可优化操作数范围内产生单精度或双精度浮点随机数以测试函数性能。实验中,我们一共产生 10^8 个浮点随机数(存放在数组中),依次使用数组中的随机数(以向量宽度为单位,双精度为 2 个随机数,单精度为 4 个随机数)做三角函数计算,并取函数计算的平均耗时作为衡量函数性能的指标。

首先,我们对比分析 Sleef 向量三角函数优化前与 libm 标量三角函数在可优化操作数范围内的性能差异,结果如图 8 所示。可以看出,尽管使用 ADVSIMD 向量指令,除异常的 \asinf 和 \acosf 函数外,只有一部分 Sleef 向量三角函数(\sin , \cos , \cosf , \tan)比 libm 标量三角函数快(最高只有 1.64 倍加速比),另外一部分 Sleef 向量三角函数与 libm 性能相当(\sin 和 \atanf),其余函数的性能比 libm 差(\tan , \asin , \acos , \atan),这是因为原始 Sleef 向量三角函数在计算可优化操作数范围时的算法冗余而

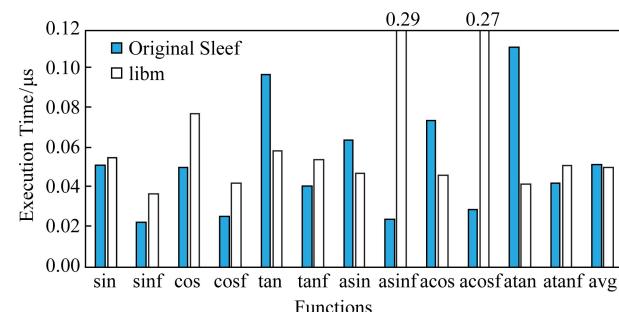


Fig. 8 Performance comparison of original Sleef functions and libm functions

图 8 Sleef 函数优化前与 libm 函数性能对比

libm 采用分段计算在可优化操作数范围内降低了函数计算量。对于 \asinf 和 \acosf 函数,libm 性能低下的原因是我们在使用的 libm 版本内部实现时使用了软件开方(sqrt),导致函数异常耗时。

其次,我们对比分析 Sleef 向量三角函数优化后与 libm 标量三角函数的性能差异,结果如图 9 所示。我们发现向量三角函数优化后与 libm 标量三角函数相比,双精度下平均加速比为 1.74 倍,单精度下平均加速比为 3.06 倍。这一性能表现一定程度上符合飞腾处理器 128 b 向量宽度下向量函数与标量函数的理想加速比(双精度下 2 倍加速比,单精度下 4 倍加速比)。

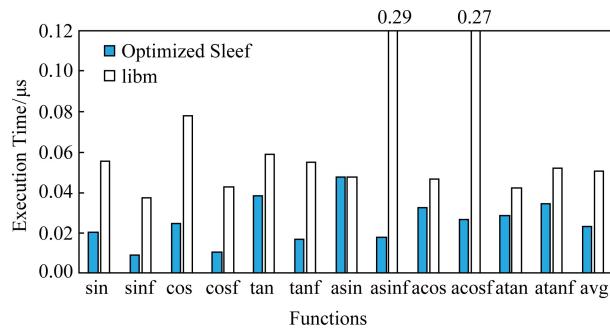


Fig. 9 Performance comparison of optimized Sleef functions and libm functions

图 9 Sleef 函数优化后与 libm 函数性能对比

最后,我们对比分析 Sleef 向量三角函数优化前与优化后的性能差异,结果如图 10 所示。可以看出使用本文所提出的优化技术,在可优化操作数范围内,所有向量三角函数的性能均得到了提升,平均加速比为 2.04 倍(最低加速比为 1.12 倍,最高可达 3.97 倍)。

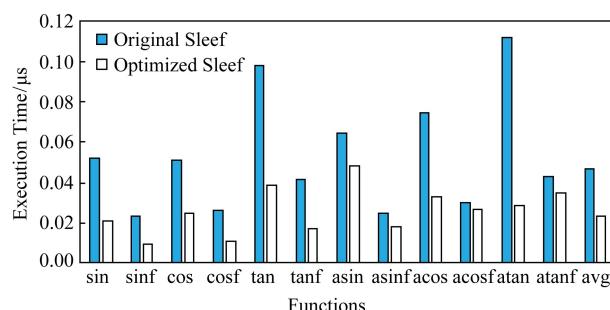


Fig. 10 Performance comparison of Sleef functions before and after optimization

图 10 Sleef 函数优化前与优化后性能对比

3.4.2 优化方法引入的开销

为了评估所提优化方法引入的开销,我们进行

如下实验,对比分析 Sleaf 向量三角函数优化前与优化后在可优化操作数范围之外的性能,以检查我们的优化方法在非可优化操作数范围内对原始 Sleaf 向量三角函数的影响,实验结果如图 11 所示。可以看出使用本文所提优化方法后,在非可优化操作数范围内,所有三角函数的性能变化均很小,其中双精度三角函数的性能波动维持在 4.3% 以内,单精度三角函数的性能波动维持在 3.8% 以内(由于 atanf 函数的可优化操作数范围为整个实数域,因此不存在对比)。换言之,我们实验确定的可优化操作数范围是正确的,并且我们的优化方法开销很低,在可优化操作数范围之外对原始 Sleaf 向量三角函数的性能影响很小。

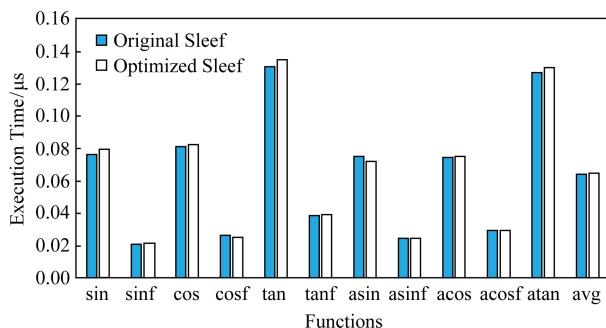


Fig. 11 Performance comparison of Sleaf functions before and after optimization with operands outside the optimization range

图 11 在可优化操作数范围外,Sleaf 函数优化前与优化后性能对比

综上所述,功能验证、精度实验和性能实验证明,本文提出的向量三角函数优化方法,在功能上满足设计要求,能够在保证计算精度和较小开销的前提下有效提高向量三角函数的性能。

4 结束语

三角函数等超越函数是科学计算类应用中最耗时的浮点计算函数,利用 SIMD 向量化技术提高函数性能是设计和优化数学库的一个重要研究方向。本文基于 Sleaf 开源向量数学库,以 libm 分段计算为指导,设计和提出了一种支持分支处理的向量三角函数优化方法,该方法降低了原始 Sleaf 向量三角函数中冗余计算的开销,同时保证了函数计算精度。在飞腾处理器平台上的实验表明,本文所提方法有效提高了向量三角函数性能。未来我们将进一步研究向量指数函数、对数函数、幂函数的性能优化以

及代码的自动向量化工作,使得更多的科学计算应用可以得益于超越函数向量化而提升性能。

参 考 文 献

- [1] Huang Libo, Ma Sheng, Shen Li, et al. Low-cost binary128 floating-point FMA unit design with SIMD support [J]. IEEE Transactions on Computers, 2012, 61(5): 745-751
- [2] Wang Yongxian, Zhang Lilun, Che Yonggang, et al. Heterogeneous computing and optimization on Tianhe-2 supercomputer system for high-order accurate CFD applications [J]. Journal of Computer Research and Development, 2015, 52(4): 833-842 (in Chinese)
(王勇献, 张理论, 车永刚, 等. 高阶精度 CFD 应用在天河 2 系统上的异构并行模拟与性能优化[J]. 计算机研究与发展, 2015, 52(4): 833-842)
- [3] Stephens N, Biles S, Boettcher M, et al. The ARM scalable vector extension [J]. IEEE Micro, 2017, 37(2): 26-39
- [4] GNU. GNU C library version 2.20 [OL]. [2019-10-09]. <http://www.gnu.org/software/libc/>
- [5] Intel. Intel libimf library [OL]. [2019-10-09]. <http://software.intel.com/de-de/tags/21702>
- [6] Intel. Intel short vector mathematical library [OL]. [2019-10-09]. <http://software.intel.com/sites/products/documentation/hpc/composerxe/en-us/cpp/win/index.htm>
- [7] Shibata N. Efficient evaluation methods of elementary functions suitable for SIMD computation [J]. Computer Science-Research and Development, 2010, 25: 25-32
- [8] Shibata N, Petrogalli F. SLEEF: A portable vectorized library of C standard mathematical functions [J]. IEEE Transactions on Parallel and Distributed Systems, 2020, 31(6): 1316-1327
- [9] Liu Chungen. Programming Principle, Implementation and Application of Floating-point Computing [M]. Beijing: China Machine Press, 2008 (in Chinese)
(刘纯根. 浮点计算编程原理、实现与应用[M]. 北京: 机械工业出版社, 2008)
- [10] Muller J M. Elementary Functions: Algorithms and Implementation [M]. Boston: Birkhäuser, 2006
- [11] AMR. ARM optimized routines [OL]. [2019-10-09]. <https://github.com/ARM-software/optimized-routines>
- [12] GNU. GNU C library [OL]. [2019-10-09]. https://sourceware.org/git/?p=glibc.git;a=tree;f=sysdeps/x86_64/fpu/multiarch
- [13] Lauter C. A new open-source SIMD vector libm fully implemented with high-level scalar C [C] //Proc of 50th Asilomar Conf on Signals, Systems and Computers. Piscataway, NJ: IEEE, 2016: 407-411
- [14] Piparo D, Innocente V, Hauth T. Speeding up HEP experiment software with a library of fast and auto-vectorisable mathematical functions [J]. Journal of Physics: Conf Series, 2014, 513(5): No.052027

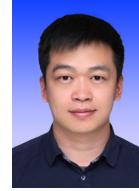
- [15] Lei Yuanwu, Dou Yong, Zhou Jie. FPGA-specific custom VLIW architecture for arbitrary precision floating-point arithmetic [J]. IEICE Transactions on Information and Systems, 2011, 94(11): 2173-2183
- [16] Goldberg D. What every computer scientist should know about floating-point arithmetic [J]. ACM Computing Surveys, 1991, 23(1): 5-47
- [17] Cornea M, Golliver R A, Markstein P. Correctness proofs outline for Newton-Raphson-based floating-point divide and square root algorithms [C] //Proc of the 14th IEEE Symp on Computer Arithmetic. Piscataway, NJ: IEEE, 1999: 96-105
- [18] MPFR. The MPFR Library [OL]. [2019-10-09]. <http://www.mpfr.org>



Shen Jie, born in 1987. PhD, assistant professor. Her main research interests include high performance computing, parallel programming, performance optimization, and high performance math library on multi-core and many-core platforms.



Long Biao, born in 1994. BSc. His main research interests include floating-point arithmetic and high performance computing. (longbiao7498@qq.com)



Jiang Hao, born in 1983. PhD, assistant professor. His main research interests include high performance computing, rounding error analysis, and numerical computation. (haojiang@nudt.edu.cn)



Huang Chun, born in 1973. PhD, professor. Her main research interests include compiler technology, parallel programming model and language.