C++ 工程实践经验谈

陈硕 (giantchen@gmail.com)

最后更新 2012-4-1

版权声明

内容一览

说明

这是我的博客上关于 C++ 的文章的合集。最新版可从陈硕博客的置顶文章中下载，地址见本页右下角。本系列文章适用于 Linux 操作系统，x86/amd64 硬件平台，g++ 4.x 编译器，服务端开发。

http://blog.csdn.net/Solstice/archive/2011/02/24/6206154.aspx

1 慎用匿名 namespace

匿名 namespace (anonymous namespace 或称 unnamed namespace) 是 C++ 语言的一项非常有用的功能，其主要目的是让该 namespace 中的成员（变量或函数）具有独一无二的全局名称，避免名字碰撞 (name collisions)。一般在编写 .cpp 文件时，如果需要写一些小的 helper 函数，我们常常会放到匿名 namespace 里。muduo 0.1.7 中的 `muduo/base/Date.cc` 和 `muduo/base/Thread.cc` 等处就用到了匿名 namespace。

我最近在工作中遇到并重新思考了这一问题，发现匿名 namespace 并不是多多益善。

1.1 C 语言的 static 关键字的两种用法

C 语言的 static 关键字有两种用途：

1. 用于函数内部修饰变量，即函数内的静态变量。这种变量的生存期长于该函数，使得函数具有一定的“状态”。使用静态变量的函数一般是不可重入的，也不是线程安全的，比如 `strtok(3)`。
2. 用在文件级别（函数体之外），修饰变量或函数，表示该变量或函数只在本文件可见，其他文件看不到也访问不到该变量或函数。专业的说法叫“具有 internal linkage”（简言之：不暴露给别的 translation unit）。

C 语言的这两种用法很明确，一般也不容易混淆。

1.2 C++ 语言的 static 关键字的四种用法

由于 C++ 引入了 class，在保持与 C 语言兼容的同时，static 关键字又有了两种新用法：

3. 用于修饰 class 的数据成员，即所谓“静态成员”。这种数据成员的生存期大于 class 的对象（实例/instance）。静态数据成员是每个 class 有一份，普通数据成员是每个 instance 有一份，因此也分别叫做 class variable 和 instance variable。

4. 用于修饰 class 的成员函数，即所谓“静态成员函数”。这种成员函数只能访问 class variable 和其他静态程序函数，不能访问 instance variable 或 instance method。

当然，这几种用法可以相互组合，比如 C++ 的成员函数（无论 static 还是 instance）都可以有其局部的静态变量（上面的用法 1）。对于 class template 和 function template，其中的 static 对象的真正个数跟 template instantiation （模板具现化）有关，相信学过 C++ 模板的人不会陌生。

可见在 C++ 里 static 被 overload 了多次。匿名 namespace 的引入是为了减轻 static 的负担，它替换了 static 的第 2 种用途。也就是说，在 C++ 里不必使用文件级的 static 关键字，我们可以用匿名 namespace 达到相同的效果。（其实严格地说，linkage 或许稍有不同，这里不展开讨论了。）

1.3 匿名 namespace 的不利之处

在工程实践中，匿名 namespace 有两大不利之处：

1. 匿名 namespace 中的函数是“匿名”的，那么在确实需要引用它的时候就比较麻烦。

   比如在调试的时候不便给其中的函数设断点，如果你像我一样使用的是 gdb 这样的文本模式 debugger；又比如 profiler 的输出结果也不容易判别到底是哪个文件中的 `calculate()` 函数需要优化。

2. 使用某些版本的 g++ 时，同一个文件每次编译出来的二进制文件会变化。

   比如说拿到一个会发生 core dump 的二进制可执行文件，无法确定它是由哪个 revision 的代码编译出来的。毕竟编译结果不可复现，具有一定的随机性。（当然，在正式场合，这应该由软件配置管理 (SCM) 流程来解决。）

   另外这也可能让某些 build tool 失灵，如果该工具用到了编译出来的二进制文件的 MD5 的话。

考虑下面这段简短的代码 (`anon.cc`)：

anon.cc
```
namespace
{
  void foo()
  {
  }
}

int main()
{
  foo();
}
```
anon.cc

对于问题 1： gdb 的 <tab> 键自动补全功能能帮我们设定断点，不是什么大问题。前提是你知道那个“(anonymous namespace)::foo()”正是你想要的函数。

```
$ gdb ./a.out
GNU gdb (GDB) 7.0.1-debian

(gdb) b '<tab>
(anonymous namespace)         __data_start                  _end
(anonymous namespace)::foo()  __do_global_ctors_aux         _fini
_DYNAMIC                      __do_global_dtors_aux         _init
_GLOBAL_OFFSET_TABLE_         __dso_handle                  _start
_IO_stdin_used                __gxx_personality_v0          anon.cc
__CTOR_END__                  __gxx_personality_v0@plt      call_gmon_start
__CTOR_LIST__                 __init_array_end              completed.6341
__DTOR_END__                  __init_array_start            data_start
__DTOR_LIST__                 __libc_csu_fini               dtor_idx.6343
__FRAME_END__                 __libc_csu_init               foo
__JCR_END__                   __libc_start_main             frame_dummy
__JCR_LIST__                  __libc_start_main@plt         int
__bss_start                   _edata                        main

(gdb) b '(<tab>
anonymous namespace)         anonymous namespace)::foo()

(gdb) b '(anonymous namespace)::foo()'
Breakpoint 1 at 0x400588: file anon.cc, line 4.
```

麻烦的是，如果两个文件 anon.cc 和 anonlib.cc 都定义了匿名空间中的 foo() 函数（这不会冲突），那么 gdb 无法区分这两个函数，你只能给其中一个设断点。或者你使用 **文件名: 行号** 的方式来分别设断点。（从技术上，匿名 namespace 中的函数是 weak text，链接的时候如果发生符号重名，linker 不会报错。）

从根本上解决的办法是使用普通具名 namespace，如果怕重名，可以把源文件名（必要时加上路径）作为 namespace 名字的一部分。

对于问题 2： 把 anon.cc 编译两次，分别生成 a.out 和 b.out：

```
$ g++ -g -o a.out anon.cc

$ g++ -g -o b.out anon.cc

$ md5sum a.out b.out
0f7a9cc15af7ab1e57af17ba16afcd70  a.out
8f22fc2bbfc27beb922aefa97d174e3b  b.out

$ g++ --version
g++ (GCC) 4.2.4 (Ubuntu 4.2.4-1ubuntu4)

$ diff -u <(nm a.out) <(nm b.out)
--- /dev/fd/63  2011-02-15 22:27:58.960754999 +0800
+++ /dev/fd/62  2011-02-15 22:27:58.960754999 +0800
@@ -2,7 +2,7 @@
 0000000000600940 d _GLOBAL_OFFSET_TABLE_
 0000000000400634 R _IO_stdin_used
                  w _Jv_RegisterClasses
-0000000000400538 t _ZN36_GLOBAL__N_anon.cc_00000000_E2CEEB513fooEv
+0000000000400538 t _ZN36_GLOBAL__N_anon.cc_00000000_CB51498D3fooEv
 0000000000600748 d __CTOR_END__
 0000000000600740 d __CTOR_LIST__
 0000000000600758 d __DTOR_END__
```

由上可见，g++ 4.2.4 会随机地给匿名 namespace 生成一个惟一的名字（foo() 函数的 mangled name 中的 E2CEEB51 和 CB51498D 是随机的），以保证名字不冲突。也就是说，同样的源文件，两次编译得到的二进制文件内容不相同，这有时候会造成问题或困惑。

这可以用 gcc 的 -frandom-seed 参数解决，具体见文档。

这个现象在 gcc 4.2.4 中存在（之前的版本估计类似），在 gcc 4.4.5 中不存在。

1.4 替代办法

如果前面的“不利之处”给你带来困扰，解决办法也很简单，就是使用普通具名 namespace。当然，要起一个好的名字，比如 boost 里就常常用 boost::detail 来放那些“不应该暴露给客户，但又不得不放到头文件里”的函数或 class。

总而言之，匿名 namespace 没什么大问题，使用它也不是什么过错。万一它碍事了，可以用普通具名 namespace 替代之。

2 不要重载全局 ::operator new()

本文只考虑 Linux x86 平台，服务端开发（不考虑 Windows 的跨 DLL 内存分配释放问题）。本文假定读者知道 ::operator new() 和 ::operator delete() 是干什么的，与通常用的 new/delete 表达式有和区别和联系，这方面的知识可参考侯捷先生的文章《池内春秋》[1]，或者这篇文章[1]。

C++ 的内存管理是个老生常谈的话题，我在《当析构函数遇到多线程》[2] 第 7 节“插曲：系统地避免各种指针错误”中简单回顾了一些常见的问题以及在现代 C++ 中的解决办法。基本上，按现代 C++ 的手法（RAII）来管理内存，你很难遇到什么内存方面的错误。“没有错误”是基本要求，不代表“足够好”。我们常常会设法优化性能，如果 profiling 表明 hot spot 在内存分配和释放上，重载全局的 ::operator new() 和 ::operator delete() 似乎是一个一劳永逸好办法（以下简写为“重载 ::operator new()”），本文试图说明这个办法往往行不通。

2.1 内存管理的基本要求

如果只考虑分配和释放，内存管理基本要求是“不重不漏”：**既不重复 delete，也不漏掉 delete**。也就说我们常说的 new/delete 要配对，“配对”不仅是个数相等，还隐含了 new 和 delete 的调用本身要匹配，不要“东家借的东西西家还”。例如：

- 用系统默认的 malloc() 分配的内存要交给系统默认的 free() 去释放；
- 用系统默认的 new 表达式创建的对象要交给系统默认的 delete 表达式去析构并释放；
- 用系统默认的 new[] 表达式创建的对象要交给系统默认的 delete[] 表达式去析构并释放；
- 用系统默认的 ::operator new() 分配的的内存要交给系统默认的 ::operator delete() 去释放；
- 用 placement new 创建的对象要用 placement delete （为了表述方便，姑且这么说吧）去析构（其实就是直接调用析构函数）；
- 从某个内存池 A 分配的内存要还给这个内存池。

[1] http://www.relisoft.com/book/tech/9new.html
[2] http://blog.csdn.net/Solstice/archive/2010/01/22/5238671.aspx

- 如果定制 new/delete，那么要按规矩来。见 *Effective C++* [2] 第 8 章“定制 new 和 delete”。

做到以上这些不难，是每个 C++ 开发人员的基本功。不过，如果你想重载全局的 `::operator new()`，事情就麻烦了。

2.2 重载::operator new() 的理由

《Effective C++ 第三版》[2] 第 50 条列举了定制 new/delete 的几点理由：

- 检测代码中的内存错误
- 优化性能
- 获得内存使用的统计数据

这些都是正当的需求，文末我们将会看到，不重载 `::operator new()` 也能达到同样的目的。

2.3 ::operator new() 的两种重载方式

1. 不改变其签名，无缝直接替换系统原有的版本，例如：

```
#include <new>

void* operator new(size_t size);
void operator delete(void* p);
```

用这种方式的重载，使用方不需要包含任何特殊的头文件，也就是说不需要看见这两个函数声明。“性能优化”通常用这种方式。

2. 增加新的参数，调用时也提供这些额外的参数，例如：

```
// 此函数返回的指针必须能被普通的 ::operator delete(void*) 释放
void* operator new(size_t size, const char* file, int line);

// 此函数只在析构函数抛异常的情况下才会被调用
void operator delete(void* p, const char* file, int line);
```

然后用的时候是

```
Foo* p = new (__FILE, __LINE__) Foo;  // 这样能跟踪是哪个文件哪一行代码分配的内存
```

我们也可以用宏替换 new 来节省打字。用这第二种方式重载，使用方需要看到这两个函数声明，也就是说要主动包含你提供的头文件。“检测内存错误”和“统计内存使用情况”通常会用这种方式重载。当然，这不是绝对的。

在学习 C++ 的阶段，每个人都可以写个一两百行的程序来验证教科书上的说法，重载 `::operator new()` 在这样的玩具程序里边不会造成什么麻烦。

不过，我认为在现实的产品开发中，重载 `::operator new()` 乃是下策，我们有更简单安全的办法来到达以上目标。

2.4 现实的开发环境

作为 C++ 应用程序的开发人员，在编写稍具规模的程序时，我们通常会用到一些 library。我们可以根据 library 的提供方把它们大致分为这么几大类：

1. C 语言的标准库，也包括 Linux 编程环境提供的 glibc 系列函数。
2. 第三方的 C 语言库，例如 OpenSSL。
3. C++ 语言的标准库，主要是 STL。（我想没有人在产品中使用 iostream 吧？）
4. 第三方的通用 C++ 库，例如 Boost.Regex，或者某款 XML 库。
5. 公司其他团队的人开发的内部基础 C++ 库，比如网络通信和日志等基础设施。
6. 本项目组的同事自己开发的针对本应用的基础库，比如某三维模型的仿射变换模块。

在使用这些 library 的时候，不可避免地要在各个 library 之间交换数据。比方说 library A 的输出作为 library B 的输入，而 library A 的输出本身常常会用到动态分配的内存（比如 `std::vector<double>`）。

如果所有的 C++ library 都用同一套内存分配器（就是系统默认的 new/delete），那么内存的释放就很方便，直接交给 delete 去释放就行。如果不是这样，那就得时时刻刻记住“这一块内存是属于哪个分配器，是系统默认的还是我们定制的，释放的时候不要还错了地方”。

（由于 C 语言不像 C++ 一样提过了那么多的定制性，C library 通常都会默认直接用 `malloc/free` 来分配和释放内存，不存在上面提到的“内存还错地方”问题。或

者有的考虑更全面的 C library 会让你注册两个函数，用于它内部分配和释放内存，这就就能完全掌控该 library 的内存使用。这种依赖注入的方式在 C++ 里变得花哨而无用，见陈硕写的《C++ 标准库中的 allocator 是多余的》[3]。）

但是，如果重载了 `::operator new()`，事情恐怕就没有这么简单了。

2.5 重载 `::operator new()` 的困境

首先，重载 `::operator new()` 不会给 C 语言的库带来任何麻烦。当然，重载它得到的三点好处也无法让 C 语言的库享受到。

以下仅考虑 C++ library 和 C++ 主程序。

规则 1：绝对不能在 library 里重载 `::operator new()`

如果你是某个 library 的作者，你的 library 要提供给别人使用，那么你无权重载全局 `::operator new(size_t)`（注意这是前面提到的第一种重载方式），因为这非常具有侵略性：任何用到你的 library 的程序都被迫使用了你重载的 `::operator new()`，而别人很可能不愿意这么做。另外，如果有两个 library 都试图重载 `::operator new(size_t)`，那么它们会打架，我估计会发生 duplicated symbol link error。（这还算是好的，如果某个实现偷偷盖住了另一个实现，会在运行时发生诡异的现象。）干脆，作为 library 的编写者，大家都不要重载 `::operator new(size_t)` 好了。

那么第二种重载方式呢？

首先，`::operator new(size_t size, const char* file, int line)` 这种方式得到的 `void*` 指针必须同时能被 `::operator delete(void*)` 和 `::operator delete(void* p, const char* file, int line)` 这两个函数释放。这时候你需要决定，你的 `::operator new(size_t size, const char* file, int line)` 返回的指针是不是兼容系统默认的 `::operator delete(void*)`。

如果不兼容（也就是说不能用系统默认的 `::operator delete(void*)` 来释放内存），那么你得重载 `::operator delete(void*)`，让它的行为与你的 `::operator new(size_t size, const char* file, int line)` 匹配。一旦你决定重载 `::operator delete(void*)`，那么你必须重载 `::operator new(size_t)`，这就回到了规则 1：你无权重载全局 `::operator new(size_t)`。

[3] http://blog.csdn.net/Solstice/archive/2009/08/02/4401382.aspx

如果选择兼容系统默认的 `::operator delete(void*)`，那么你在 `::operator new(size_t size, const char* file, int line)` 里能做的事情非常有限，比方说你不能额外动态分配内存来做 house keeping 或保存统计数据（无论显示还是隐式），因为系统默认的 `::operator delete(void*)` 不会释放你额外分配的内存。（这里隐式分配内存指的是往 `std::map<>` 这样的容器里添加元素。）看到这里估计很多人已经晕了，但这还没完。

其次，在 library 里重载 `::operator new(size_t size, const char* file, int line)` 还涉及到你的重载要不要暴露给 library 的使用者（其他 library 或主程序）。这里“暴露”有两层意思：

1. 包含你的头文件的代码会不会用你重载的 `::operator new()`，
2. 重载之后的 `::operator new()` 分配的内存能不能在你的 library 之外被安全地释放。如果不行，那么你是不是要暴露某个接口函数来让使用者安全地释放内存？或者返回 `shared_ptr`，利用其“捕获”deleter 的特性？

听上去好像挺复杂？这里就不一一展开讨论了，总之，作为 library 的作者，我建议你绝对不要动“重载 `::operator new()`”的念头。

事实 2：在主程序里重载 `::operator new()` 作用不大

这不是一条规则，而是我试图说明这么做没有多大意义。

如果用第一种方式重载全局 `::operator new(size_t)`，会影响本程序用到的所有 C++ library，这么做或许不会有什么问题，不过我建议你使用下一节介绍的更简单的“替代办法”。

如果用第二种方式重载 `::operator new(size_t size, const char* file, int line)`，那么你的行为是否惠及本程序用到的其他 C++ library 呢？比方说你要不要统计 C++ library 中的内存使用情况？如果某个 library 会返回它自己用 new 分配的内存和对象，让你用完之后自己释放，那么是否打算对错误释放内存做检查？

C++ library 从代码组织上有两种形式：

1. 以头文件方式提供（如以 STL 和 Boost 为代表的模板库）；
2. 以头文件 + 二进制库文件方式提供（大多数非模板库以此方式发布）。

对于纯以头文件方式实现的 library，那么你可以在你的程序的每个.cpp 文件的第一行包含重载 `::operator new()` 的头文件，这样程序里用到的其他 C++ library 也会转而使用你的 `::operator new()` 来分配内存。当然这是一种相当有侵略性的做法，如果运气好，编译和运行都没问题；如果运气差一点，可能会遇到编译错误，这其实还不算坏事；运气更差一点，编译没有错误，运行的时候时不时出现非法访问，导致 segment fault；或者在某些情况下你定制的分配策略与 library 有冲突，内存数据损坏，出现莫名其妙的行为。

对于以库文件方式实现的 library，这么做并不能让其受惠，因为 library 的源文件已经编译成了二进制代码，它不会调用你新重载的 `::operator new` （想想看，已经编译的二进制代码怎么可能提供额外的 `new (__FILE__, __LINE__)` 参数呢？）更麻烦的是，如果某些头文件有 inline function，还会引起诡异的“串扰”。即 library 有的部分用了你的分配器，有的部分用了系统默认的分配器，然后在释放内存的时候没有给对地方，造成分配器的数据结构被破坏。

总之，第二种重载方式看似功能更丰富，但其实与程序里使用的其他 C++ library 很难无缝配合。

综上，对于现实生活中的 C++ 项目，重载 `::operator new()` 几乎没有用武之地，因为很难处理好与程序所用的 C++ library 的关系，毕竟大多数 library 在设计的时候没有考虑到你会重载 `::operator new()` 并强塞给它。

如果确实需要定制内存分配，该如何办？

2.6 替代办法

很简单，替换 `malloc()`。如果需要，直接从 `malloc` 层面入手，通过 `LD_PRELOAD` 来加载一个 .so，其中有 `malloc/free` 的替代实现 (drop-in replacement)，这样能同时为 C 和 C++ 代码服务，而且避免 C++ 重载 `::operator new()` 的阴暗角落。

对于“检测内存错误”这一用法，我们可以用 valgrind 或者 dmalloc 或者 efence 来达到相同的目的，专业的除错工具比自己山寨一个内存检查器要靠谱。

对于“统计内存使用数据”，替换 `malloc` 同样能得到足够的信息，因为我们可以用 `backtrace()` 函数来获得调用栈，这比 `new (__FILE__, __LINE__)` 的信息更丰富。比方说你通过分析 `(__FILE__, __LINE__)` 发现 `std::string` 大量分配释放内存，有超出预期的开销，但是你却不知道代码里哪一部分在反复创建和销毁 `std::string` 对

象，因为 (__FILE__, __LINE__) 只能告诉你最内层的调用函数。用 backtrace() 能找到真正的发起调用者。

对于“性能优化”这一用法，我认为这目前的多线程开发中，自己实现一个能打败系统默认的 malloc 的内存分配器是不现实的。一个通用的内存分配器本来就有相当的难度，为多线程程序实现一个安全和高效的通用（全局）内存分配器超出了一般开发人员的能力。不如使用现有的针对多核多线程优化的 malloc，例如 Google tcmalloc 和 Intel TBB 2.2 里的内存分配器。好在这些 allocator 都不是侵入式的，也无须重载 ::operator new()。

2.7 为单独的 class 重载 ::operator new() 有问题吗?

与全局 ::operator new() 不同，per-class operator new() 和 operator delete () 的影响面要小得多，它只影响本 class 及其派生类。似乎重载 member ::operator new() 是可行的。**我对此持反对态度**。

如果一个 class Node 需要重载 member ::operator new()，说明它用到了特殊的内存分配策略，常见的情况是使用了内存池或对象池。我宁愿把这一事实明显地摆出来，而不是改变 new Node 语句的默认行为。具体地说，是用 factory 来创建对象，比如 static Node* Node::createNode() 或者 static shared_ptr<Node> Node::createNode()。

这可以归结为最小惊讶原则：如果我在代码里读到 Node* p = new Node，我会认为它在 heap 上分配了内存，如果 Node class 重载了 member ::operator new()，那么我要事先仔细阅读 node.h 才能发现其实这行代码使用了私有的内存池。为什么不写得明确一点呢？写成 Node* p = NodeFactory::createNode()，那么我能猜到 NodeFactory::createNode() 肯定做了什么与 new Node 不一样的事情，免得将来大吃一惊。

The Zen of Python[4] 说 explicit is better than implicit，我深信不疑。

总结： 重载 ::operator new() 或许在某些临时的场合能应个急，但是不应该作为一种策略来使用。如果需要，我们可以从 malloc 层面入手，彻底而全面地替换内存分配器。

[4] http://www.python.org/dev/peps/pep-0020/

3 采用有利于版本管理的代码格式

版本管理 (version controlling) 是每个程序员的基本技能，C++ 程序员也不例外。版本管理的基本功能之一是追踪代码变化，让你能清楚地知道代码是如何一步步变成现在的这个样子，以及每次 check-in 都具体改动了哪些内部。无论是传统的集中式版本管理工具，如 Subversion，还是新型的分布式管理工具，如 Git/Hg，比较两个版本 (revision) 的差异都是其基本功能，即俗称“做一下 diff”。

diff 的输出是个窥孔 (peephole)，它的上下文有限（`diff -u` 默认显示前后 3 行）。在做 code review 的时候，如果能凭这“一孔之见”就能发现代码改动有问题，那就再好也不过了。

C 和 C++ 都是自由格式的语言，代码中的换行符被当做 white space 来对待。（当然，我们说的是预处理 (preprocess) 之后的情况）。对编译器来说一模一样的代码可以有多种写法，比如

```
foo(1, 2, 3, 4);
```

和

```
foo(1,
    2,
    3,
    4);
```

词法分析的结果是一样的，语意也完全一样。

对人来说，这两种写法读起来不一样，对与版本管理工具来说，同样功能的修改造成的差异 (diff) 也往往不一样。所谓“有利于版本管理”，就是指在代码中合理使用换行符，对 diff 工具友好，让 diff 的结果清晰明了地表达代码的改动。（diff 一般以行为单位，也可以以单词为单位，本文只考虑最常见的 diff by lines。）

这里举一些例子。

3.1 对 diff 友好的代码格式

3.1.1 多行注释也用 `//`，不用 `/* */`

Scott Meyers 写的《Effective C++》第二版第 4 条建议使用 C++ 风格，我这里为他补充一条理由：对 diff 友好。比如，我要注释一大段代码（其实这不是个好的做法，但是在实践中有时会遇到），如果用 `/* */`，那么得到的 diff 是：

```
--- a/examples/asio/tutorial/timer5/timer.cc
+++ b/examples/asio/tutorial/timer5/timer.cc
@@ -18,6 +18,7 @@ class Printer : boost::noncopyable
     loop2_->runAfter(1, boost::bind(&Printer::print2, this));
   }

+  /*
   ~Printer()
   {
     std::cout << "Final count is " << count_ << "\n";
@@ -38,6 +39,7 @@ class Printer : boost::noncopyable
       loop1_->quit();
     }
   }
+  */

   void print2()
   {
```

从这样的 diff output 能看出注释了哪些代码吗？

如果用 `//`，结果会清晰很多：

```
--- a/examples/asio/tutorial/timer5/timer.cc
+++ b/examples/asio/tutorial/timer5/timer.cc
@@ -18,26 +18,26 @@ class Printer : boost::noncopyable
     loop2_->runAfter(1, boost::bind(&Printer::print2, this));
   }

-  ~Printer()
-  {
-    std::cout << "Final count is " << count_ << "\n";
-  }
+  // ~Printer()
+  // {
+  //   std::cout << "Final count is " << count_ << "\n";
+  // }

-  void print1()
-  {
-    muduo::MutexLockGuard lock(mutex_);
-    if (count_ < 10)
-    {
-      std::cout << "Timer 1: " << count_ << "\n";
-      ++count_;
-
-      loop1_->runAfter(1, boost::bind(&Printer::print1, this));
-    }
-    else
-    {
-      loop1_->quit();
-    }
```

```
-  }
+  // void print1()
+  // {
+  //   muduo::MutexLockGuard lock(mutex_);
+  //   if (count_ < 10)
+  //   {
+  //     std::cout << "Timer 1: " << count_ << "\n";
+  //     ++count_;
+  //
+  //     loop1_->runAfter(1, boost::bind(&Printer::print1, this));
+  //   }
+  //   else
+  //   {
+  //     loop1_->quit();
+  //   }
+  // }

   void print2()
   {
```

同样的道理，取消注释的时候 `//` 也比 `/* */` 更清晰。

另外，如果用 `/* */` 来做多行注释，从 diff 不一定能看出来你是在修改代码还是修改注释。比如以下 diff 似乎修改了 `muduo::EventLoop::runAfter()` 的调用参数：

```
--- a/examples/asio/tutorial/timer5/timer.cc
+++ b/examples/asio/tutorial/timer5/timer.cc
@@ -32,7 +32,7 @@ class Printer : boost::noncopyable
       std::cout << "Timer 1: " << count_ << std::endl;
       ++count_;

-      loop1_->runAfter(1, boost::bind(&Printer::print1, this));
+      loop1_->runAfter(2, boost::bind(&Printer::print1, this));
     }
     else
     {
```

其实这个修改发生在注释里边（要增加上下文才能看到，`diff -U 20`，多一道手续，降低了工作效率），对代码行为没有影响：

```
--- a/examples/asio/tutorial/timer5/timer.cc
+++ b/examples/asio/tutorial/timer5/timer.cc
@@ -20,31 +20,31 @@ class Printer : boost::noncopyable

   /*
   ~Printer()
   {
     std::cout << "Final count is " << count_ << std::endl;
   }
```

```
    void print1()
    {
      muduo::MutexLockGuard lock(mutex_);
      if (count_ < 10)
      {
        std::cout << "Timer 1: " << count_ << std::endl;
        ++count_;

-       loop1_->runAfter(1, boost::bind(&Printer::print1, this));
+       loop1_->runAfter(2, boost::bind(&Printer::print1, this));
      }
      else
      {
        loop1_->quit();
      }
    }
    */

    void print2()
    {
      muduo::MutexLockGuard lock(mutex_);
      if (count_ < 10)
      {
        std::cout << "Timer 2: " << count_ << std::endl;
        ++count_;
```

总之，不要用 `/* */` 来注释多行代码。

或许是时过境迁，大家都在用 `//` 注释了，《Effective C++》第三版去掉了这一条建议。

3.1.2 局部变量与成员变量的定义

基本原则是，一行代码只定义一个变量，比如

```
double x;
double y;
```

将来代码增加一个 `double z` 的时候，diff 输出一眼就能看出改了什么：

```
@@ -63,6 +63,7 @@ private:
   int count_;
   double x;
   double y;
+  double z;
 };

 int main()
```

如果把 x 和 y 写在一行，diff 的输出就得多看几眼才知道。

```
@@ -61,7 +61,7 @@ private:
   muduo::net::EventLoop* loop1_;
   muduo::net::EventLoop* loop2_;
   int count_;
-  double x, y;
+  double x, y, z;
 };

 int main()
```

所以，一行只定义一个变量更利于版本管理。同样的道理适用于 enum 成员的定义，数组的初始化列表等等。

3.1.3 函数声明中的参数

如果函数的参数大于 3 个，那么在逗号后面换行，这样每个参数占一行，便于 diff。以 muduo::net::TcpClient 为例：

muduo/net/TcpClient.h

```
class TcpClient : boost::noncopyable
{
 public:
  TcpClient(EventLoop* loop,
            const InetAddress& serverAddr,
            const string& name);
```

muduo/net/TcpClient.h

如果将来 TcpClient 的构造函数增加或修改一个参数，那么很容易从 diff 看出来。这恐怕比在一行长代码里数逗号要高效一些。

3.1.4 函数调用时的参数

在函数调用的时候，如果参数大于 3 个，那么把实参分行写。

以 muduo::net::EPollPoller 为例：

muduo/net/poller/EPollPoller.cc

```
Timestamp EPollPoller::poll(int timeoutMs, ChannelList* activeChannels)
{
  int numEvents = ::epoll_wait(epollfd_,
                               &*events_.begin(),
```

```
                                static_cast<int>(events_.size()),
                                timeoutMs);
    Timestamp now(Timestamp::now());
```

muduo/net/poller/EPollPoller.cc

这样一来，如果将来重构引入了一个新参数（好吧，epoll_wait 不会有这个问题），那么函数定义和函数调用的地方的 diff 具有相同的形式（比方说都是在倒数第二行加了一行内容），很容易肉眼验证有没有错位。如果参数写在一行里边，就得睁大眼睛数逗号了。

3.1.5 class 初始化列表的写法

同样的道理，class 初始化列表 (initializer list) 也遵循一行一个的原则，这样将来如果加入新的成员变量，那么两处（class 定义和 ctor 定义）的 diff 具有相同的形式，让错误无所遁形。以 muduo::net::Buffer 为例：

muduo/net/Buffer.h

```
class Buffer : public muduo::copyable
{
 public:
  static const size_t kCheapPrepend = 8;
  static const size_t kInitialSize = 1024;

  Buffer()
    : buffer_(kCheapPrepend + kInitialSize),
      readerIndex_(kCheapPrepend),
      writerIndex_(kCheapPrepend)
  {
  }
  // 省略
 private:
   std::vector<char> buffer_;
   size_t            readerIndex_;
   size_t            writerIndex_;
};
```

muduo/net/Buffer.h

注意，初始化列表的顺序必须和数据成员声明的顺序相同。

3.1.6 与 namespace 有关的缩进

Google 的 C++ 编程规范明确指出，namespace 不增加缩进 [5]。这么做非常有道理，方便 diff -p 把函数名显示在每个 diff chunk 的头上。

[5] http://google-styleguide.googlecode.com/svn/trunk/cppguide.xml#Namespace_Formatting

如果对函数实现做 diff，chunk name 是函数名，让人一眼就能看出改的是哪个函数。如下图，阴影部分。

```
diff --git a/muduo/net/SocketsOps.cc b/muduo/net/SocketsOps.cc
--- a/muduo/net/SocketsOps.cc
+++ b/muduo/net/SocketsOps.cc
@@ -125,7 +125,7 @@ int sockets::accept(int sockfd, struct sockaddr_in* addr)
       case ENOTSOCK:
       case EOPNOTSUPP:
         // unexpected errors
-        LOG_FATAL << "unexpected error of ::accept";
+        LOG_FATAL << "unexpected error of ::accept " << savedErrno;
         break;
       default:
         LOG_FATAL << "unknown error of ::accept " << savedErrno;
```

如果对 class 做 diff，那么 chunk name 就是 class name。

```
diff --git a/muduo/net/Buffer.h b/muduo/net/Buffer.h
--- a/muduo/net/Buffer.h
+++ b/muduo/net/Buffer.h
@@ -60,13 +60,13 @@ class Buffer : public muduo::copyable
     std::swap(writerIndex_, rhs.writerIndex_);
   }

-  size_t readableBytes();
+  size_t readableBytes() const;

-  size_t writableBytes();
+  size_t writableBytes() const;

-  size_t prependableBytes();
+  size_t prependableBytes() const;

   const char* peek() const;
```

diff 原本是为 C 语言设计的，C 语言没有 namespace 缩进一说，所以它默认会找到“顶格写”的函数作为一个 diff chunk 的名字，如果函数名前面有空格，它就不认得了。muduo 的代码都遵循这一规则，例如：

muduo/base/Timestamp.h

```
namespace muduo
{

// class 从第一列开始写，不缩进
class Timestamp : public muduo::copyable
{
  // ...
};
```

muduo/base/Timestamp.h

muduo/base/Timestamp.cc

```
// 函数的实现也从第一列开始写，不缩进。
Timestamp Timestamp::now()
{
  struct timeval tv;
  gettimeofday(&tv, NULL);
  int64_t seconds = tv.tv_sec;
  return Timestamp(seconds * kMicroSecondsPerSecond + tv.tv_usec);
}
```

muduo/base/Timestamp.cc

相反，boost 中的某些库的代码是按 namespace 来缩进的，这样的话看 diff 往往不知道改动的是哪个 class 的哪个成员函数。

这个或许可以通过设置 diff 取函数名的正则表达式来解决，但是如果我们写代码的时候就注意把函数“顶格写”，那么就不用去动 diff 的默认设置了。另外，正则表达式不能完全匹配函数名，因为函数名是上下文无关语法 (context-free syntax)，你没办法写一个正则语法去匹配上下文无关语法。我总能写出某种函数声明，让你的正则表达式失效（想想函数的返回类型，它可能是一个非常复杂的东西，更别说参数了）。更何况 C++ 的语法是上下文相关的，比如你猜 `Foo<Bar> qux;` 是个表达式还是变量定义？

3.1.7 public 与 private

我认为这是 C++ 语法的一个缺陷，如果我把一个成员函数从 public 区移到 private 区，那么从 diff 上看不出来我干了什么，例如：

```
diff --git a/muduo/net/TcpClient.h b/muduo/net/TcpClient.h
--- a/muduo/net/TcpClient.h
+++ b/muduo/net/TcpClient.h
@@ -37,7 +37,6 @@ class TcpClient : boost::noncopyable
   void connect();
   void disconnect();

-  bool retry() const;
   void enableRetry() { retry_ = true; }

   /// Set connection callback.
@@ -60,6 +59,7 @@ class TcpClient : boost::noncopyable
   void newConnection(int sockfd);
   /// Not thread safe, but in loop
   void removeConnection(const TcpConnectionPtr& conn);
+  bool retry() const;

   EventLoop* loop_;
   boost::scoped_ptr<Connector> connector_; // avoid revealing Connector
```

从上面的 diff 能看出我把 `retry()` 变成 private 了吗？对此我也没有好的解决办法，总不能每个函数前面都写上 `public:` 或 `private:` 吧？

对此 Java 和 C# 都做得比较好，它们把 public/private 等修饰符放到每个成员函数的定义中。这么做增加了信息的冗余度，让 diff 的结果更直观。

3.1.8 避免使用版本控制软件的 keyword substitution 功能

这么做是为了避免 diff 噪音。

比方说，如果我想比较 0.1.1 和 0.1.2 两个代码分支有哪些改动，我通常会在 branches 目录执行 `diff 0.1.1 0.1.2 -ru`。两个 branch 中的 `muduo/net/EventLoop.h` 其实是一样的（先后从同一个 revision 分支出来）。但是如果这个文件使用了 SVN 的 keyword substitution 功能（比如 `$Id$`），diff 会报告这两个 branches 中的文件不一样，如下。

```
diff -rup 0.1.1/muduo/net/EventLoop.h 0.1.2/muduo/net/EventLoop.h
--- 0.1.1/muduo/net/EventLoop.h 2011-05-02 23:11:02.000000000 +0800
+++ 0.1.2/muduo/net/EventLoop.h 2011-05-02 23:12:22.000000000 +0800
@@ -8,7 +8,7 @@
 //
 // This is a public header file, it must only include public header files.

-// $Id: EventLoop.h 4 2011-05-01 10:11:02Z schen $
+// $Id: EventLoop.h 5 2011-05-02 15:12:22Z schen $

 #ifndef MUDUO_NET_EVENTLOOP_H
 #define MUDUO_NET_EVENTLOOP_H
```

这样纯粹增加了噪音，这是 RCS/CVS 时代过时的做法。文件的 Id 不应该在文件内容中出现，这些 metadata 跟源文件的内容无关，应该由版本管理软件额外提供。

3.2 对 grep 友好的代码风格

3.2.1 操作符重载

C++ 工具匮乏，在一个项目里，要找到一个函数的定义或许不算太难（最多就是分析一下重载和模板特化），但是要找到一个函数的使用就难多了。不比 Java，在 Eclipse 里 Ctrl+Shift+G 就能找到所有的引用点。

假如我要做一个重构，想先找到代码里所有用到 `muduo::timeDifference()` 的地方，判断一下工作是否可行，基本上惟一的办法是 `grep`。用 `grep` 还不能排除同名的

函数和注释里的内容。这也说明为什么要用 `//` 来引导注释，因为在 `grep` 的时候，一眼就能看出这行代码是在注释里的。

在我看来，operator overloading 应仅限于和 STL algorithm/container 配合时使用，比如 `std::transform()` 和 `map<Key,Value>`，其他情况都用具名函数为宜。原因之一是，我根本用 grep 找不到在哪儿用到了减号 `operator-()`。这也是 `muduo::Timestamp` class 只提供 `operator<()` 而不提供 `operator+()` `operator-()` 的原因，我提供了两个函数 `timeDifference()` 和 `addTime()` 来实现所需的功能。

又比如，Google Protocol Buffers 的回调是 `class Closure`，它的接口用的是 virtual function `Run()` 而不是 virtual `operator()()`。

3.2.2 static_cast 与 C-style cast

为什么 C++ 要引入 static_cast 之类的转型操作符，原因之一就是像 `(int*) pBuffer` 这样的表达式基本上没办法用 `grep` 判断出它是个强制类型转换，写不出一个刚好只匹配类型转换的正则表达式。(again，语法是上下文无关的，无法用正则搞定。)

如果类型转换都用 `*_cast`，那只要 `grep` 一下我就能知道代码里哪儿用了 reinterpret_cast 转换，便于迅速地检查有没有用错。为了强调这一点，muduo 开启了编译选项 `-Wold-style-cast` 来帮助查找 C-style casting，这样在编译时就能帮我们找到问题。

3.3 一切为了效率

如果用图形化的文件比较工具，似乎能避免上面列举的问题。但无论是 web 还是客户端，无论是 diff by words 还是 diff by lines 都不能解决全部问题，效率也不一定更高。

对于 (3.1.2)，如果想知道是谁在什么时候增加的 `double z`，在分行写的情况下，用 `git blame` 或 `svn blame` 立刻就能找到始作俑者。如果写成一行，那就得把文件的 revisions 拿来一个个人工比较，因为这一行 `double x = 0.0, y = 1.0, z = -1.0;` 可能修改过多次，你得一个个看才知道什么时候加入了变量 z。这个 blame 的 case 也适用于 3、4、5。

比如 (3.1.6) 改动了一行代码，你还是要 scroll up 去找改的是哪个 function，人眼看的话还有“看走眼”的可能，又得再定睛观瞧。这一切都是浪费人的时间，使用更好的图形化工具并不能减少浪费，相反，我认为增加了浪费。

另外一个常见的工作场景，早上来到办公室，update 一下代码，然后扫一眼 diff output 看看别人昨天动了哪些文件，改了哪些代码。这就是一两条命令的事，几秒钟就能解决战斗。如果用图形化的工具，得一个个点开文件 diff 的链接或点开新 tab 来看文件的 side-by-side 比较（不这么做的话看不到足够多的上下文，跟看 diff output 无异），然后点击鼠标滚动页面去看别人到底改了什么。说实话我觉得这么做效率不比 diff 高。

4 二进制兼容性

本文主要讨论 Linux x86/x86-64 平台，偶尔会举 Windows 作为反面教材。

C++ 程序员有不同的角色，比如有主要编写应用程序的 (application)，也有主要编写程序库的 (library)，有的程序员或许还身兼多职。如果公司的规模比较大，会出现更细致和明确的分工。比如有的团队专门负责一两个公用的 library，有的团队负责某个 application，并使用了前一个团队的 library。

举一个具体的例子。假设你负责一个图形库，这个图形库功能强大，且经过了充分测试，于是在公司内慢慢推广开来。目前已经有二三十个内部项目用到了你的图形库，大家日子过得挺好。前几天，公司新买了一批大屏幕显示器 (2560×1600 分辨率)，不巧你的图形库不能支持这么高的分辨率。（这其实不怪你，因为在你编写这个库的时候，市面上显示器的最高分辨率是 1920×1200。）

结果用到了你的图形库的应用程序在 2560×1600 分辨率下不能正常工作，你该怎么办？你可以发布一个新版的图形库，并要求那二三十个项目组用你的新库重新编译他们的程序，然后让他们重新发布应用程序。或者，你提供一个新的库文件，直接替换现有的库文件，应用程序可执行文件保持不变。

这两种做法各有优劣。第一种声势浩大，凡是用到你的库的团队都要经历一个 release cycle。后一种办法似乎节省人力，但是有风险：如果新的库文件和原有的应用程序可执行文件不兼容怎么办？

所以，作为 C++ 程序员（无论是写应用的还是写基础库的），需要了解二进制兼容性方面的知识。

C/C++ 的二进制兼容性 (binary compatibility) 有多重含义，本文主要在“库文件单独升级，现有可执行文件是否受影响”这个意义下讨论，我称之为 library （主要是 shared library，即动态链接库）的 ABI (application binary interface)。至于编译器与操作系统的 ABI 留给下一篇谈 C++ 标准与实践的文章。

4.1 什么是二进制兼容性

在解释这个定义之前，先看看 Unix/C 语言的一个历史问题：`open()` 的 `flags` 参数的取值。`open(2)` 函数的原型是

```
int open(const char *pathname, int flags);
```

其中 `flags` 的取值有三个：`O_RDONLY`, `O_WRONLY`, `O_RDWR`。

与一般人的直觉相反，这几个值不是**按位或** (bitwise-OR) 的关系，即 `O_RDONLY | O_WRONLY != O_RDWR`。如果你想以读写方式打开文件，必须用 `O_RDWR`，而不能用 `(O_RDONLY | O_WRONLY)`。为什么？因为 `O_RDONLY`, `O_WRONLY`, `O_RDWR` 的值分别是 0, 1, 2。它们不满足按位或。

那么为什么 C 语言从诞生到现在一直没有纠正这个小小的缺陷？比方说把 `O_RDONLY`, `O_WRONLY`, `O_RDWR` 分别定义为 1, 2, 3，这样 `O_RDONLY | O_WRONLY == O_RDWR`，符合直觉。而且这三个值都是宏定义，也不需要修改现有的源代码，只需要改改系统的头文件就行了。

因为这么做会破坏二进制兼容性。对于已经编译好的可执行文件，它调用 `open(2)` 的参数是写死的，更改头文件并不能影响已经编译好的可执行文件。比方说这个可执行文件会调用 `open(path, 1)` 来写文件，而在新规定中，这表示读文件，程序就错乱了。

以上这个例子说明，如果以 shared library 方式提供函数库，那么头文件和库文件不能轻易修改，否则容易破坏已有的二进制可执行文件，或者其他用到这个 shared library 的 library。

操作系统的 system call 可以看成 Kernel 与 User space 的 interface，kernel 在这个意义下也可以当成 shared library，你可以把内核从 2.6.30 升级到 2.6.35，而不需要重新编译所有用户态的程序。

所谓“二进制兼容性”指的就是在升级（也可能是 bug fix）库文件的时候，不必重新编译使用了这个库的可执行文件或其他库文件，程序的功能不被破坏。

见 QT FAQ 的有关条款：http://developer.qt.nokia.com/faq/answer/you_frequently_say_that_you_cannot_add_this_or_that_feature_because_it_woul

在 Windows 下有恶名叫 DLL Hell，比如 MFC 有一堆 DLL，mfc40.dll, mfc42.dll, mfc71.dll, mfc80.dll, mfc90.dll，这是动态链接库的本质问题，怪不到 MFC 头上。

4.2 有哪些情况会破坏库的 ABI

到底如何判断一个改动是不是二进制兼容呢？这跟 C++ 的实现方式直接相关，虽然 C++ 标准没有规定 C++ 的 ABI，但是几乎所有主流平台都有明文或事实上的 ABI 标准。比方说 ARM 有 EABI，Intel Itanium 有 Itanium ABI [6]，x86-64 有仿 Itanium 的 ABI，SPARC 和 MIPS 也都有明文规定的 ABI，等等。x86 是个例外，它只有事实上的 ABI，比如 Windows 就是 Visual C++，Linux 是 G++（G++ 的 ABI 还有多个版本，目前最新的是 G++ 3.4 的版本），Intel 的 C++ 编译器也得按照 Visual C++ 或 G++ 的 ABI 来生成代码，否则就不能与系统其它部件兼容。

C++ ABI 的主要内容：

- 函数参数传递的方式，比如 x86-64 用寄存器来传函数的前 4 个整数参数
- 虚函数的调用方式，通常是 vptr/vtbl 然后用 vtbl[offset] 来调用
- struct 和 class 的内存布局，通过偏移量来访问数据成员
- name mangling
- RTTI 和异常处理的实现（以下本文不考虑异常处理）

C/C++ 通过头文件暴露出动态库的使用方法，这个“使用方法”主要是给编译器看的，编译器会据此生成二进制代码，然后在运行的时候通过装载器 (loader) 把可执行文件和动态库绑到一起。如何判断一个改动是不是二进制兼容，主要就是看头文件暴露的这份“使用说明”能否与新版本的动态库的实际使用方法兼容。因为新的库必然有新的头文件，但是现有的二进制可执行文件还是按旧的头文件来调用动态库。

这里举一些源代码兼容但是二进制代码不兼容例子

[6] http://www.codesourcery.com/public/cxx-abi/abi.html

- 给函数增加默认参数，现有的可执行文件无法传这个额外的参数。
- 增加虚函数，会造成 vtbl 里的排列变化。(不要考虑“只在末尾增加”这种取巧行为，因为你的 class 可能已被继承。)
- 增加默认模板类型参数，比方说 `Foo<T>` 改为 `Foo<T, Alloc=alloc<T> >`，这会改变 name mangling
- 改变 enum 的值，把 `enum Color { Red = 3 };` 改为 `Red = 4`。这会造成错位。当然，由于 enum 自动排列取值，添加 enum 项也是不安全的，在末尾添加除外。

给 `class Bar` 增加数据成员，造成 `sizeof(Bar)` 变大，以及内部数据成员的 offset 变化，这是不是安全的？通常不是安全的，但也有例外。

- 如果客户代码里有 `new Bar`，那么肯定不安全，因为 new 的字节数不够装下新 Bar 对象。相反，如果 library 通过 factory 返回 `Bar*` （并通过 factory 来销毁对象）或者直接返回 `shared_ptr<Bar>`，客户端不需要用到 `sizeof(Bar)`，那么可能是安全的。
- 如果客户代码里有 `Bar* pBar; pBar->memberA = xx;`，那么肯定不安全，因为 memberA 的新 Bar 的偏移可能会变。相反，如果只通过成员函数来访问对象的数据成员，客户端不需要用到 data member 的 offsets，那么可能是安全的。
- 如果客户调用 `pBar->setMemberA(xx);` 而 `Bar::setMemberA()` 是个 inline function，那么肯定不安全，因为偏移量已经被 inline 到客户的二进制代码里了。如果 `setMemberA()` 是 outline function，其实现位于 shared library 中，会随着 Bar 的更新而更新，那么可能是安全的。

那么只使用 header-only 的库文件是不是安全呢？不一定。如果你的程序用了 boost 1.36.0，而你依赖的某个 library 在编译的时候用的是 1.33.1，那么你的程序和这个 library 就不能正常工作。因为 1.36.0 和 1.33.1 的 boost::function 的模板参数类型的个数不一样，后者一个多了 allocator。

这里有一份黑名单，列在这里的肯定是二级制不兼容，没有列出的也可能二进制不兼容，见 KDE 的文档：http://techbase.kde.org/Policies/Binary_Compatibility_Issues_With_C%2B%2B

4.3 哪些做法多半是安全的

前面我说“不能轻易修改”，暗示有些改动多半是安全的，这里有一份白名单，欢迎添加更多内容。

只要库改动不影响现有的可执行文件的二进制代码的正确性，那么就是安全的，我们可以先部署新的库，让现有的二进制程序受益。

- 增加新的 class
- 增加 non-virtual 成员函数或 static 成员函数
- 修改数据成员的名称，因为生产的二进制代码是按偏移量来访问的，当然，这会造成源码级的不兼容。
- 还有很多，不一一列举了。

欢迎补充

4.4 反面教材：COM

在 C++ 中以虚函数作为接口基本上就跟二进制兼容性说拜拜了。具体地说，以只包含虚函数的 class （称为 interface class）作为程序库的接口，这样的接口是僵硬的，一旦发布，无法修改。

此处的内容挪到“避免使用虚函数作为库的接口”一节中详细论述。

另外，Windows 下，Visual C++ 编译的时候要选择 Release 或 Debug 模式，而且 Debug 模式编译出来的 library 通常不能在 Release binary 中使用（反之亦然），这也是因为两种模式下的 CRT 二进制不兼容（主要是内存分配方面，Debug 有自己的簿记）。Linux 就没有这个麻烦，可以混用。

4.5 解决办法

采用静态链接

这个是王道。在分布式系统这，采用静态链接也带来部署上的好处，只要把可执行文件放到机器上就行运行，不用考虑它依赖的 libraries。目前 muduo 就是采用静态链接。

通过动态库的版本管理来控制兼容性

这需要非常小心检查每次改动的二进制兼容性并做好发布计划，比如 1.0.x 系列做到二进制兼容，1.1.x 系列做到二进制兼容，而 1.0.x 和 1.1.x 二进制不兼容。《程序员的自我修养》[3] 里边讲过 .so 文件的命名与二进制兼容性相关的话题，值得一读。

用 pimpl 技法，编译器防火墙

在头文件中只暴露 non-virtual 接口，并且 class 的大小固定为 `sizeof(Impl*)`，这样可以随意更新库文件而不影响可执行文件。具体做法见第 6 节。当然，这么做有多了一道间接性，可能有一定的性能损失。另见 *Exceptional C++* 有关条款和 *C++ Coding Standards 101* [4].

5 避免使用虚函数作为库的接口

摘要 作为 C++ 动态库的作者，应当避免使用虚函数作为库的接口。这么做会给保持二进制兼容性带来很大麻烦，不得不增加很多不必要的 interfaces，最终重蹈 COM 的覆辙。

本文主要讨论 Linux x86 平台，会继续举 Windows/COM 作为反面教材。

本文是上一篇《二进制兼容性》的延续，在写这篇文章的时候，我原本以外大家都对“以 C++ 虚函数作为接口”的害处达成共识，我就写得比较简略，看来情况不是这样，我还得展开谈一谈。

“接口”有广义和狭义之分，本文用中文“接口”表示广义的接口，即一个库的代码界面；用英文 interface 表示狭义的接口，即只包含 virtual function 的 class，这种 class 通常没有 data member，在 Java 里有一个专门的关键字 interface 来表示它。

5.1 C++ 程序库的作者的生存环境

假设你是一个 shared library 的维护者，你的 library 被公司另外两三个团队使用了。你发现了一个安全漏洞，或者某个会导致 crash 的 bug 需要紧急修复，那么你修复之后，能不能直接部署 library 的二进制文件？有没有破坏二进制兼容性？会不会破坏别人团队已经编译好的投入生成环境的可执行文件？是不是要强迫别的团队重

新编译链接，把可执行文件也发布新版本？会不会打乱别人的 release cycle？这些都是工程开发中经常要遇到的问题。

如果你打算新写一个 C++ library，那么通常要做以下几个决策：

- 以什么方式发布？动态库还是静态库？（本文不考虑源代码发布这种情况，这其实和静态库类似。）
- 以什么方式暴露库的接口？可选的做法有：以全局（含 namespace 级别）函数为接口、以 class 的 non-virtual 成员函数为接口、以 virtual 函数为接口（interface）。

（Java 程序员没有这么多需要考虑的，直接写 class 成员函数就行，最多考虑一下要不要给 method 或 class 标上 final。也不必考虑动态库静态库，都是 .jar 文件。）

在作出上面两个决策之前，我们考虑两个基本假设：

- 代码会有 bug，库也不例外。将来可能会发布 bug fixes。
- 会有新的功能需求。写代码不是一锤子买卖，总是会有新的需求冒出来，需要程序员往库里增加东西。这是好事情，让程序员不丢饭碗。

（如果你的代码第一次发布的时候就已经做到完美，将来不需要任何修改，那么怎么做都行，也就不必继续阅读本文。）

也就是说，在设计库的时候必须要考虑将来如何升级。

基于以上两个基本假设来做决定。第一个决定很好做，如果需要 hot fix，那么只能用动态库；否则，在分布式系统中使用静态库更容易部署，这在前文中已经谈过。（“动态库比静态库节约内存”这种优势在今天看来已不太重要。）

以下本文假定你或者你的老板选择以动态库方式发布，即发布 .so 或 .dll 文件，来看看第二个决定怎么做。（再说一句，如果你能够以静态库方式发布，后面的麻烦都不会遇到。）

第二个决定不是那么容易做，关键问题是，要选择一种可扩展的 (extensible) 接口风格，让库的升级变得更轻松。“升级”有两层意思：

- 对于 bug fix only 的升级，二进制库文件的替换应该兼容现有的二进制可执行文件，二进制兼容性方面的问题已经在前文谈过，这里从略。

- 对于新增功能的升级，应该对客户代码的友好。升级库之后，客户端使用新功能的代价应该比较小。只需要包含新的头文件（这一步都可以省略，如果新功能已经加入原有的头文件中），然后编写新代码即可。而且，不要在客户代码中留下垃圾，后文我们会谈到什么是垃圾。

在讨论虚函数接口的弊端之前，我们先看看虚函数做接口的常见用法。

5.2 虚函数作为库的接口的两大用途

虚函数为接口大致有这么两种用法：

- **调用**，也就是库提供一个什么功能（比如绘图 Graphics），以虚函数为接口方式暴露给客户端代码。客户端代码一般不需要继承这个 interface，而是直接调用其 member function。这么做据说是有利于接口和实现分离，我认为纯属脱了裤子放屁。
- **回调**，也就是事件通知，比如网络库的“连接建立”、“数据到达”、“连接断开”等等。客户端代码一般会继承这个 interface，然后把对象实例注册到库里边，等库来回调自己。一般来说客户端不会自己去调用这些 member function，除非是为了写单元测试模拟库的行为。
- **混合**，一个 class 既可以被客户端代码继承用作回调，又可以被客户端直接调用。说实话我没看出这么做的好处，但实际中某些面向对象的 C++ 库就是这么设计的。

对于“回调”方式，现代 C++ 有更好的做法，即 boost::function + boost::bind，见第 7 节，muduo 的回调全部采用这种新方法，见《Muduo 网络编程示例之零：前言》[7]。本文以下不考虑以虚函数为回调的过时做法。

对于“调用”方式，这里举一个虚构的图形库，这个库的功能是画线、画矩形、画圆弧：

```
struct Point
{
  int x;
  int y;
};
```

[7] http://blog.csdn.net/Solstice/archive/2011/02/02/6171831.aspx

```
class Graphics
{
  virtual void drawLine(int x0, int y0, int x1, int y1);
  virtual void drawLine(Point p0, Point p1);

  virtual void drawRectangle(int x0, int y0, int x1, int y1);
  virtual void drawRectangle(Point p0, Point p1);

  virtual void drawArc(int x, int y, int r);
  virtual void drawArc(Point p, int r);
};
```

这里略去了很多与本文主题无关细节，比如 Graphics 的构造与析构、`draw*()` 函数应该是 public、Graphics 应该不允许复制，还比如 Graphics 可能会用 pure virtual functions 等等，这些都不影响本文的讨论。

这个 Graphics 库的使用很简单，客户端看起来是这个样子。

```
Graphics* g = getGraphics();
g->drawLine(0, 0, 100, 200);
releaseGraphics(g);
g = NULL;
```

似乎一切都很好，阳光明媚，符合“面向对象的原则”，但是一旦考虑升级，前景立刻变得昏暗。

5.3 虚函数作为接口的弊端

以虚函数作为接口在二进制兼容性方面有本质困难：“一旦发布，不能修改”。

假如我需要给 Graphics 增加几个绘图函数，同时保持二进制兼容性。这几个新函数的坐标以浮点数表示，我理想中的新接口是：

```
--- old/graphics.h  2011-03-12 13:12:44.000000000 +0800
+++ new/graphics.h  2011-03-12 13:13:30.000000000 +0800
@@ -7,11 +7,14 @@
 class Graphics
 {
   virtual void drawLine(int x0, int y0, int x1, int y1);
+  virtual void drawLine(double x0, double y0, double x1, double y1);
   virtual void drawLine(Point p0, Point p1);

   virtual void drawRectangle(int x0, int y0, int x1, int y1);
+  virtual void drawRectangle(double x0, double y0, double x1, double y1);
   virtual void drawRectangle(Point p0, Point p1);
```

```
    virtual void drawArc(int x, int y, int r);
+   virtual void drawArc(double x, double y, double r);
    virtual void drawArc(Point p, int r);
  };
```

受 C++ 二进制兼容性方面的限制，我们不能这么做。其本质问题在于 C++ 以 vtable[offset] 方式实现虚函数调用，而 offset 又是根据虚函数声明的位置隐式确定的，这造成了脆弱性。我增加了 `drawLine(double x0, double y0, double x1, double y1)`，造成 vtable 的排列发生了变化，现有的二进制可执行文件无法再用旧的 offset 调用到正确的函数。

怎么办呢？有一种危险且丑陋的做法：把新的虚函数放到 interface 的末尾，例如：

```
--- old/graphics.h  2011-03-12 13:12:44.000000000 +0800
+++ new/graphics.h  2011-03-12 13:58:22.000000000 +0800
@@ -7,11 +7,15 @@
 class Graphics
 {
   virtual void drawLine(int x0, int y0, int x1, int y1);
   virtual void drawLine(Point p0, Point p1);

   virtual void drawRectangle(int x0, int y0, int x1, int y1);
   virtual void drawRectangle(Point p0, Point p1);

   virtual void drawArc(int x, int y, int r);
   virtual void drawArc(Point p, int r);
+
+  virtual void drawLine(double x0, double y0, double x1, double y1);
+  virtual void drawRectangle(double x0, double y0, double x1, double y1);
+  virtual void drawArc(double x, double y, double r);
 };
```

这么做很丑陋，因为新的 `drawLine(double x0, double y0, double x1, double y1)` 函数没有和原来的 `drawLine()` 函数呆在一起，造成阅读上的不便。这么做同时很危险，因为 Graphics 如果被继承，那么新增虚函数会改变派生类中的 vtable offset 变化，同样不是二进制兼容的。

另外有两种似乎安全的做法，这也是 COM 采用的办法：

1. 通过链式继承来扩展现有 interface，例如从 Graphics 派生出 Graphics2。

```
--- graphics.h  2011-03-12 13:12:44.000000000 +0800
+++ graphics2.h 2011-03-12 13:58:35.000000000 +0800
@@ -7,11 +7,19 @@
```

```
 class Graphics
 {
   virtual void drawLine(int x0, int y0, int x1, int y1);
   virtual void drawLine(Point p0, Point p1);

   virtual void drawRectangle(int x0, int y0, int x1, int y1);
   virtual void drawRectangle(Point p0, Point p1);

   virtual void drawArc(int x, int y, int r);
   virtual void drawArc(Point p, int r);
 };
+
+class Graphics2 : public Graphics
+{
+  using Graphics::drawLine;
+  using Graphics::drawRectangle;
+  using Graphics::drawArc;
+
+  // added in version 2
+  virtual void drawLine(double x0, double y0, double x1, double y1);
+  virtual void drawRectangle(double x0, double y0, double x1, double y1);
+  virtual void drawArc(double x, double y, double r);
+};
```

将来如果继续增加功能，那么还会有 `class Graphics3 : public Graphics2`；以及 `class Graphics4 : public Graphics3`; 等等。这么做和前面的做法一样丑陋，因为新的 `drawLine(double x0, double y0, double x1, double y1)` 函数位于派生 Graphics2 interace 中，没有和原来的 `drawLine()` 函数呆在一起，造成割裂。

2. 通过多重继承来扩展现有 interface，例如定义一个与 Graphics class 有同样成员的 Graphics2，再让实现同时继承这两个 interfaces。

```
--- graphics.h  2011-03-12 13:12:44.000000000 +0800
+++ graphics2.h 2011-03-12 13:16:45.000000000 +0800
@@ -7,11 +7,32 @@
 class Graphics
 {
   virtual void drawLine(int x0, int y0, int x1, int y1);
   virtual void drawLine(Point p0, Point p1);

   virtual void drawRectangle(int x0, int y0, int x1, int y1);
   virtual void drawRectangle(Point p0, Point p1);

   virtual void drawArc(int x, int y, int r);
   virtual void drawArc(Point p, int r);
 };
+
+class Graphics2
+{
+  virtual void drawLine(int x0, int y0, int x1, int y1);
```

```
+  virtual void drawLine(double x0, double y0, double x1, double y1);
+  virtual void drawLine(Point p0, Point p1);
+
+  virtual void drawRectangle(int x0, int y0, int x1, int y1);
+  virtual void drawRectangle(double x0, double y0, double x1, double y1);
+  virtual void drawRectangle(Point p0, Point p1);
+
+  virtual void drawArc(int x, int y, int r);
+  virtual void drawArc(double x, double y, double r);
+  virtual void drawArc(Point p, int r);
+};
+
+// 在实现中采用多重接口继承
+class GraphicsImpl : public Graphics,  // version 1
+                     public Graphics2, // version 2
+{
+  // ...
+};
```

这种带版本的 interface 的做法在 COM 使用者的眼中看起来是很正常的（比如 IXMLDOMDocument、IXMLDOMDocument2、IXMLDOMDocument3，又比如 ITaskbarList、ITaskbarList2、ITaskbarList3、ITaskbarList4 等等），解决了二进制兼容性的问题，客户端源代码也不受影响。

在我看来带版本的 interface 实在是很丑陋，因为每次改动都引入了新的 interface class，会造成日后客户端代码难以管理。比如，如果新版应用程序的代码使用了 Graphics3 的功能，要不要把现有代码中出现的 Graphics2 都替换掉？

- 如果不替换，一个程序同时依赖多个版本的 Graphics，一直背着历史包袱。依赖的 Graphics 版本越积越多，将来如何管理得过来？
- 如果要替换，为什么不相干的代码（现有的运行得好好的使用 Graphics2 的代码）也会因为别处用到了 Graphics3 而被修改？

这种二难境地纯粹是“以虚函数为库的接口”造成的。如果我们能直接原地扩充 class Graphics，就不会有这些屁事，见下一节“动态库接口的推荐做法”。

5.4 假如 Linux 系统调用以 COM 接口方式实现

或许上面这个 Graphics 的例子太简单，没有让“以虚函数为接口”的缺点充分暴露出来，让我们看一个真实的案例：Linux Kernel。

Linux kernel 从 0.10 的 67 个[8] 系统调用发展到 2.6.37 的 340 个[9]，kernel interface 一直在扩充，而且保持良好的兼容性，它保持兼容性的办法很土，就是给每个 system call 赋予一个终身不变的数字代号，等于把虚函数表的排列固定下来。点开本段开头的两个链接，你就能看到 fork() 在 Linux 0.10 和 Linux 2.6.37 里的代号都是 2。（系统调用的编号跟硬件平台有关，这里我们看的是 x86 32-bit 平台。）

试想假如 Linus 当初选择用 COM 接口的链式继承风格来描述，将会是怎样一种壮观的景象？为了避免扰乱视线，请移步观看近百层继承的代码[10]。（先后关系与版本号不一定 100% 准确，我是用 git blame 去查的，现在列出的代码只从 0.01 到 2.5.31，相信已经足以展现 COM 接口方式的弊端。）

不要误认为“接口一旦发布就不能更改”是天经地义的，那不过是“以 C++ 虚函数为接口”的固有弊端，如果跳出这个框框去思考，其实 C++ 库的接口很容易做得更好。

为什么不能改？还不是因为用了 C++ 虚函数作为接口。Java 的 interface 可以添加新函数，C 语言的库也可以添加新的全局函数，C++ class 也可以添加新 non-virtual 成员函数和 namespace 级别的 non-member 函数，这些都不需要继承出新 interface 就能扩充原有接口。偏偏 COM 的 interface 不能原地扩充，只能通过继承来 workaround，产生一堆带版本的 interfaces。有人说 COM 是二进制兼容性的正面例子，某深不以为然。COM 确实以一种最丑陋的方式做到了“二进制兼容”。脆弱与僵硬就是以 C++ 虚函数为接口的宿命。

相反，Linux 系统调用以编译期常数方式固定下来，万年不变，轻而易举地解决了这个问题。在其他面向对象语言（Java/C#）中，我也没有见过每改动一次就给 interface 递增版本号的诡异做法。

还是应了《The Zen of Python》中的那句话，Explicit is better than implicit, Flat is better than nested.

5.5 Java 是如何应对的

Java 实际上把 C/C++ 的 linking 这一步骤推迟到 class loading 的时候来做。就不存在“不能增加虚函数”，“不能修改 data member”等问题。在 Java 里边用面向 interface 编程远比 C++ 更通用和自然，也没有上面提到的“僵硬的接口”问题。

[8] http://lxr.linux.no/linux-old+v0.01/include/unistd.h#L60
[9] http://lxr.linux.no/linux+v2.6.37.3/arch/x86/include/asm/unistd_32.h
[10] https://gist.github.com/867174

6 动态库的接口的推荐做法

取决于动态库的使用范围，有两类做法。

其一，如果动态库的使用范围比较窄，比如本团队内部的两三个程序在用，用户都是受控的，要发布新版本也比较容易协调，那么不用太费事，只要做好发布的版本管理就行了。再在可执行文件中使用 rpath 把库的完整路径确定下来。

比如现在 Graphics 库发布了 1.1.0 和 1.2.0 两个版本，这两个版本可以不必是二进制兼容。用户的代码从 1.1.0 升级到 1.2.0 的时候要重新编译一下，反正他们要用新功能都是要重新编译代码的。如果要原地打补丁，那么 1.1.1 应该和 1.1.0 二进制兼容，而 1.2.1 应该和 1.2.0 兼容。如果要加入新的功能，而新的功能与 1.2.0 不兼容，那么应该发布到 1.3.0 版本。

为了便于检查二进制兼容性，可考虑把库的代码的暴露情况分辨清楚。muduo 的头文件和 class 就有意识地分为用户可见和用户不可见两部分，见 http://blog.csdn.net/Solstice/archive/2010/08/29/5848547.aspx。对于用户可见的部分，升级时要注意二进制兼容性，选用合理的版本号；对于用户不可见的部分，在升级库的时候就不必在意。另外 muduo 本身设计来是以原文件方式发布，在二进制兼容性方面没有做太多的考虑。

其二，如果库的使用范围很广，用户很多，各家的 release cycle 不尽相同，那么推荐 pimpl [11] 技法 [4, item 43]，并考虑多采用 non-member non-friend function in namespace [2, item 23] [4, item 44 and 57] 作为接口。这里以前面的 Graphics 为例，说明 pimpl 的基本手法。

1. 暴露的接口里边不要有虚函数，而且 `sizeof(Graphics) == sizeof(Graphics::Impl*)`。

graphics.h

```
class Graphics
{
 public:
  Graphics(); // outline ctor
  ~Graphics(); // outline dtor

  void drawLine(int x0, int y0, int x1, int y1);
  void drawLine(Point p0, Point p1);

  void drawRectangle(int x0, int y0, int x1, int y1);
  void drawRectangle(Point p0, Point p1);
```

[11] pimpl 是 pointer to implementation 的缩写。

```
    void drawArc(int x, int y, int r);
    void drawArc(Point p, int r);

  private:
    class Impl;
    boost::scoped_ptr<Impl> impl;
};
```

graphics.h

2. 在库的实现中把调用转发 (forward) 给实现 Graphics::Impl，这部分代码位于 .so/.dll 中，随库的升级一起变化。

graphics.cc

```
#include <graphics.h>

class Graphics::Impl
{
 public:
  void drawLine(int x0, int y0, int x1, int y1);
  void drawLine(Point p0, Point p1);

  void drawRectangle(int x0, int y0, int x1, int y1);
  void drawRectangle(Point p0, Point p1);

  void drawArc(int x, int y, int r);
  void drawArc(Point p, int r);
};

Graphics::Graphics()
  : impl(new Impl)
{
}

Graphics::~Graphics()
{
}

void Graphics::drawLine(int x0, int y0, int x1, int y1)
{
  impl->drawLine(x0, y0, x1, y1);
}

void Graphics::drawLine(Point p0, Point p1)
{
  impl->drawLine(p0, p1);
}

// ...
```

graphics.cc

3. 如果要加入新的功能，不必通过继承来扩展，可以原地修改，且很容易保持二进制兼容性。先动头文件：

```
--- old/graphics.h    2011-03-12 15:34:06.000000000 +0800
+++ new/graphics.h    2011-03-12 15:14:12.000000000 +0800
@@ -7,19 +7,22 @@
 class Graphics
 {
  public:
   Graphics(); // outline ctor
   ~Graphics(); // outline dtor

   void drawLine(int x0, int y0, int x1, int y1);
+  void drawLine(double x0, double y0, double x1, double y1);
   void drawLine(Point p0, Point p1);

   void drawRectangle(int x0, int y0, int x1, int y1);
+  void drawRectangle(double x0, double y0, double x1, double y1);
   void drawRectangle(Point p0, Point p1);

   void drawArc(int x, int y, int r);
+  void drawArc(double x, double y, double r);
   void drawArc(Point p, int r);

  private:
   class Impl;
   boost::scoped_ptr<Impl> impl;
 };
```

然后在实现文件里增加 forward，这么做不会破坏二进制兼容性，因为增加 non-virtual 函数不影响现有的可执行文件。

```
--- old/graphics.cc   2011-03-12 15:15:20.000000000 +0800
+++ new/graphics.cc   2011-03-12 15:15:26.000000000 +0800
@@ -1,35 +1,43 @@
 #include <graphics.h>

 class Graphics::Impl
 {
  public:
   void drawLine(int x0, int y0, int x1, int y1);
+  void drawLine(double x0, double y0, double x1, double y1);
   void drawLine(Point p0, Point p1);

   void drawRectangle(int x0, int y0, int x1, int y1);
+  void drawRectangle(double x0, double y0, double x1, double y1);
   void drawRectangle(Point p0, Point p1);

   void drawArc(int x, int y, int r);
+  void drawArc(double x, double y, double r);
   void drawArc(Point p, int r);
```

```
};

Graphics::Graphics()
  : impl(new Impl)
{
}

Graphics::~Graphics()
{
}

void Graphics::drawLine(int x0, int y0, int x1, int y1)
{
  impl->drawLine(x0, y0, x1, y1);
}

+void Graphics::drawLine(double x0, double y0, double x1, double y1)
+{
+  impl->drawLine(x0, y0, x1, y1);
+}
+
 void Graphics::drawLine(Point p0, Point p1)
 {
   impl->drawLine(p0, p1);
 }
```

采用 pimpl 多了一道 explicit forward 的手续，带来的好处是可扩展性与二进制兼容性，通常是划算的。pimpl 扮演了编译器防火墙的作用。

pimpl 不仅 C++ 语言可以用，C 语言的库同样可以用，一样带来二进制兼容性的好处，比如 libevent2 里边的 struct event_base 是个 opaque pointer，客户端看不到其成员，都是通过 libevent 的函数和它打交道，这样库的版本升级比较容易做到二进制兼容。

为什么 non-virtual 函数比 virtual 函数更健壮？因为 virtual function 是 bind-by-vtable-offset，而 non-virtual function 是 bind-by-name。加载器 (loader) 会在程序启动时做决议 (resolution)，通过 mangled name 把可执行文件和动态库链接到一起。就像使用 Internet 域名比使用 IP 地址更能适应变化一样。

万一要跨语言怎么办？很简单，暴露 C 语言的接口。Java 有 JNI 可以调用 C 语言的代码；Python/Perl/Ruby 等等的解释器都是 C 语言编写的，使用 C 函数也不在话下。C 函数是 Linux 下的万能接口。

本文只谈了使用 class 为接口，其实用 free function 有时候更好（比如 `muduo/base/Timestamp.h` 除了定义 class Timestamp，还定义了 `muduo::timeDifference()` 等 free function），这也是 C++ 比 Java 等纯面向对象语言优越的地方。留给

将来再细谈吧。

7 以 boost::function 和 boost:bind 取代虚函数

这篇文章的中心思想是“面向对象的继承就像一条贼船，上去就下不来了”，而借助 boost::function 和 boost::bind，大多数情况下，你都不用上贼船。

boost::function 和 boost::bind 已经纳入了 std::tr1，这或许是 C++0x 最值得期待的功能，它将彻底改变 C++ 库的设计方式，以及应用程序的编写方式。

Scott Meyers 的 Effective C++ 3rd ed [2] 第 35 条款提到了以 boost::function 和 boost:bind 取代虚函数的做法，这里谈谈我自己使用的感受。

（这篇文章写得比较早，那会儿我还没有开始写 muduo，所以文章的例子与现在的代码有些脱节。另见孟岩《function/bind 的救赎（上）》[12]，《回复几个问题》[13]中的“四个半抽象”）

7.1 基本用途

boost::function 就像 C# 里的 delegate，可以指向任何函数，包括成员函数。当用 bind 把某个成员函数绑到某个对象上时，我们得到了一个 closure（闭包）。例如：

```
class Foo
{
 public:
  void methodA();
  void methodInt(int a);
};

class Bar
{
 public:
  void methodB();
};

boost::function<void()> f1; // 无参数，无返回值

Foo foo;
```

[12]http://blog.csdn.net/myan/archive/2010/10/09/5928531.aspx
[13]http://blog.csdn.net/myan/archive/2010/09/14/5884695.aspx

```
f1 = boost::bind(&Foo::methodA, &foo);
f1(); // 调用 foo.methodA();
Bar bar;
f1 = boost::bind(&Bar::methodB, &bar);
f1(); // 调用 bar.methodB();

f1 = boost::bind(&Foo::methodInt, &foo, 42);
f1(); // 调用 foo.methodInt(42);

boost::function<void(int)> f2; // int 参数，无返回值
f2 = boost::bind(&Foo::methodInt, &foo, _1);
f2(53); // 调用 foo.methodInt(53);
```

如果没有 boost::bind，那么 boost::function 就什么都不是，而有了 bind，“同一个类的不同对象可以 delegate 给不同的实现，从而实现不同的行为”（myan 语），简直就无敌了。

7.2 对程序库的影响

程序库的设计不应该给使用者带来不必要的限制（耦合），而继承是第二强的一种耦合（最强耦合的是友元）。如果一个程序库限制其使用者必须从某个 class 派生，那么我觉得这是一个糟糕的设计。不巧的是，目前不少 C++ 程序库就是这么做的。

例 1：线程库

常规 OO 设计 ：

写一个 Thread base class，含有（纯）虚函数 Thread::run()，然后应用程序派生一个 derived class，覆写 run()。程序里的每一种线程对应一个 Thread 的派生类。例如 Java 的 Thread class 可以这么用。

缺点：如果一个 class 的三个 method 需要在三个不同的线程中执行，就得写 helper class(es) 并玩一些 OO 把戏。

基于 boost::function 的设计 ：

令 Thread 是一个具体类，其构造函数接受 Callable 对象。应用程序只需提供一个 Callable 对象，创建一份 Thread 实体，调用 Thread::start() 即可。Java 的 Thread也可以这么用，传入一个 Runnable对象。C# 的 Thread 只支持这一种用法，构造函数的参数是 delegate ThreadStart。boost::thread 也只支持这种用法。

```
// 一个基于 boost::function 的 Thread class 基本结构
class Thread
{
 public:
  typedef boost::function<void()> ThreadCallback;

  Thread(ThreadCallback cb) : cb_(cb)
  { }

  void start()
  {
    /* some magic to call run() in new created thread */
  }

 private:
  void run()
  {
    cb_();
  }

  ThreadCallback cb_;
  // ...
};
```

使用：

```
class Foo // 不需要继承
{
 public:
  void runInThread();
  void runInAnotherThread(int)
};

Foo foo;
Thread thread1(boost::bind(&Foo::runInThread, &foo));
Thread thread2(boost::bind(&Foo::runInAnotherThread, &foo, 43));
thread1.start();
thread2.start();
```

例 2：网络库

以 boost::function 作为桥梁，NetServer class 对其使用者没有任何类型上的限制，只对成员函数的参数和返回类型有限制。使用者 EchoService 也完全不知道 NetServer 的存在，只要在 main() 里把两者装配到一起，程序就跑起来了。

network library

```
class Connection;
class NetServer : boost::noncopyable
```

```
{
 public:
  typedef boost::function<void (Connection*)> ConnectionCallback;
  typedef boost::function<void (Connection*,
                                const void*,
                                int len)> MessageCallback;

  NetServer(uint16_t port);
  ~NetServer();
  void registerConnectionCallback(const ConnectionCallback&);
  void registerMessageCallback(const MessageCallback&);
  void sendMessage(Connection*, const void* buf, int len);

 private:
  // ...
};
```

network library

user code

```
class EchoService
{
 public:
  // 符合 NetServer::sendMessage 的原型
  typedef boost::function<void(Connection*,
                               const void*,
                               int)> SendMessageCallback;

  EchoService(const SendMessageCallback& sendMsgCb)
    : sendMessageCb_(sendMsgCb) // 保存 boost::function
  { }

  // 符合 NetServer::MessageCallback 的原型
  void onMessage(Connection* conn, const void* buf, int size)
  {
    printf("Received Msg from Connection %d: %.*s\n",
           conn->id(), size, (const char*)buf);
    sendMessageCb_(conn, buf, size); // echo back
  }

  // 符合 NetServer::ConnectionCallback 的原型
  void onConnection(Connection* conn)
  {
    printf("Connection from %s:%d is %s\n",
           conn->ipAddr(),
           conn->port(),
           conn->connected() ? "UP" : "DOWN");
  }

 private:
  SendMessageCallback sendMessageCb_;
};

// 扮演上帝的角色，把各部件拼起来
```

```
int main()
{
  NetServer server(7);
  EchoService echo(bind(&NetServer::sendMessage, &server, _1, _2, _3));
  server.registerMessageCallback(
        bind(&EchoService::onMessage, &echo, _1, _2, _3));
  server.registerConnectionCallback(
        bind(&EchoService::onConnection, &echo, _1));
  server.run();
}
```

user code

7.3 对面向对象程序设计的影响

一直以来，我对面向对象有一种厌恶感，叠床架屋，绕来绕去的，一拳拳打在棉花上，不解决实际问题。面向对象三要素是封装、继承和多态。我认为封装是根本的，继承和多态则是可有可无。用 class 来表示 concept，这是根本的；至于继承和多态，其耦合性太强，往往不划算。

继承和多态不仅规定了函数的名称、参数、返回类型，还规定了类的继承关系。在现代的 OO 编程语言里，借助反射和 attribute/annotation，已经大大放宽了限制。举例来说，JUnit 3.x 是用反射，找出派生类里的名字符合 `void test*()` 的函数来执行，这里就没继承什么事，只是对函数的名称有部分限制（继承是全面限制，一字不差）。至于 JUnit 4.x 和 NUnit 2.x 则更进一步，以 annoatation/attribute 来标明 test case，更没继承什么事了。

我的猜测是，当初提出面向对象的时候，closure 还没有一个通用的实现，所以它没能算作基本的抽象工具之一。现在既然 closure 已经这么方便了，或许我们应该重新审视面向对象设计，至少不要那么滥用继承。

自从找到了 `boost::function+boost::bind` 这对神兵利器，不用再考虑类直接的继承关系，只需要基于对象的设计 (object-based)，拳拳到肉，程序写起来顿时顺手了很多。

7.4 对面向对象设计模式的影响

既然虚函数能用 closure 代替，那么很多 OO 设计模式，尤其是行为模式，失去了存在的必要。另外，既然没有继承体系，那么创建型模式似乎也没啥用了。

最明显的是 Strategy，不用累赘的 Strategy 基类和 ConcreteStrategyA、ConcreteStrategyB 等派生类，一个 `boost::function<>` 成员就解决问题。另外一个例

子是 Command 模式，有了 `boost::function`，函数调用可以直接变成对象，似乎就没 Command 什么事了。同样的道理，Template Method 可以不必使用基类与继承，只要传入几个 `boost::function` 对象，在原来调用虚函数的地方换成调用 `boost::function` 对象就能解决问题。

在《设计模式》这本书提到了 23 个模式，我认为 iterator 有用（或许再加个 State），其他都在摆谱，拉虚架子，没啥用。或许它们解决了面向对象中的常见问题，不过要是我的程序里连面向对象（指继承和多态）都不用，那似乎也不用叨扰面向对象设计模式了。

或许 closure-based programming 将作为一种新的 programming paradiam 而流行起来。

7.5 依赖注入与单元测试

前面的 EchoService 可算是依赖注入的例子，EchoService 需要一个什么东西来发送消息，它对这个“东西”的要求只是函数原型满足 SendMessageCallback，而并不关系数据到底发到网络上还是发到控制台。在正常使用的时候，数据应该发给网络，而在做单元测试的时候，数据应该发给某个 DataSink。

安照面向对象的思路，先写一个 AbstractDataSink interface，包含 sendMessage() 这个虚函数，然后派生出两个 classes：NetDataSink 和 MockDataSink，前面那个干活用，后面那个单元测试用。EchoService 的构造函数应该以 AbstractDataSink* 为参数，这样就实现了所谓的接口与实现分离。

我认为这么做纯粹是脱了裤子放屁，直接传入一个 SendMessageCallback 对象就能解决问题。在单元测试的时候，可以 `boost::bind()` 到 MockServer 上，或某个全局函数上，完全不用继承和虚函数，也不会影响现有的设计。

7.6 什么时候使用继承？

如果是指 OO 中的 public 继承，即为了接口与实现分离，那么我只会在派生类的数目和功能完全确定的情况下使用。换句话说，不为将来的扩展考虑，这时候面向对象或许是一种不错的描述方法。一旦要考虑扩展，什么办法都没用，还不如把程序写简单点，将来好大改或重写。

如果是功能继承，那么我会考虑继承 boost::noncopyable 或 boost::enable_shared_from_this，下一篇 blog 会讲到 enable_shared_from_this 在实现多线程安全的对象回调时的妙用。

例如，IO-Multiplex 在不同的操作系统下有不同的推荐实现，最通用的 select()，POSIX 的 poll()，Linux 的 epoll()，FreeBSD 的 kqueue 等等，数目固定，功能也完全确定，不用考虑扩展。那么设计一个 NetLoop base class 加若干具体 classes 就是不错的解决办法。换句话说，用多态来代替 switch-case 以达到简化代码的目的。

7.7 基于接口的设计

这个问题来自那个经典的讨论：不会飞的企鹅（Penguin）究竟应不应该继承自鸟（Bird），如果 Bird 定义了 virtual function fly() 的话。讨论的结果是，把具体的行为提出来，作为 interface，比如 Flyable（能飞的），Runnable（能跑的），然后让企鹅实现 Runnable，麻雀实现 Flyable 和 Runnable。（其实麻雀只能双脚跳，不能跑，这里不作深究。）

进一步的讨论表明，interface 的粒度应足够小，或许包含一个 method 就够了，那么 interface 实际上退化成了给类型打的标签 (tag)。在这种情况下，完全可以使用 boost::function 来代替，比如：

```
// 企鹅能游泳，也能跑
class Penguin
{
 public:
  void run();
  void swim();
};


// 麻雀能飞，也能跑
class Sparrow
{
 public:
  void fly();
  void run();
};


// 以 boost::function 作为接口
typedef boost::function<void()> FlyCallback;
typedef boost::function<void()> RunCallback;
typedef boost::function<void()> SwimCallback;
```

```
// 一个既用到 run, 也用到 fly 的客户 class
class Foo
{
 public:
  Foo(FlyCallback flyCb, RunCallback runCb)
   : flyCb_(flyCb), runCb_(runCb)
  { }

 private:
  FlyCallback flyCb_;
  RunCallback runCb_;
};


// 一个既用到 run, 也用到 swim 的客户 class
class Bar
{
 public:
  Bar(SwimCallback swimCb, RunCallback runCb)
   : swimCb_(swimCb), runCb_(runCb)
  { }

 private:
  SwimCallback swimCb_;
  RunCallback runCb_;
};


int main()
{
  Sparrow s;
  Penguin p;
  // 装配起来, Foo 要麻雀, Bar 要企鹅。
  Foo foo(bind(&Sparrow::fly, &s), bind(&Sparrow::run, &s));
  Bar bar(bind(&Penguin::swim, &p), bind(&Penguin::run, &p));
}
```

最后，向伟大的 C 语言致敬！

8 带符号整数的除法与余数

最近研究整数到字符串的转换，读到了 Matthew Wilson 的《Efficient Integer to String Conversions》系列文章。[14] 他的巧妙之处在于，用一个对称的 digits 数组搞定了负数转换的边界条件（二进制补码的正负整数表示范围不对称）。代码大致如下，经过改写：

[14] http://synesis.com.au/publications.html 搜 conversions

```
const char* convert(char buf[], int value)
{
  static char digits[19] =
    { '9', '8', '7', '6', '5', '4', '3', '2', '1',
      '0', '1', '2', '3', '4', '5', '6', '7', '8', '9' };
  static const char* zero = digits + 9;  // zero 指向 '0'
  // works for -2147483648 .. 2147483647
  int i = value;
  char* p = buf;
  do {
    // lsd - least significant digit
    int lsd = i % 10;  // lsd 可能小于 0
    i /= 10;           // 是向下取整还是向零取整？
    *p++ = zero[lsd];  // 下标可能为负
  } while (i != 0);
  if (value < 0) {
    *p++ = '-';
  }
  *p = '\0';
  std::reverse(buf, p);
  return p; // p - buf 即为整数长度
}
```

这段简短的代码对 32-bit int 的全部取值都是正确的（从 -2 147 483 648 到 2 147 483 647）。可以视为 itoa() 的参考实现，面试的标准答案。

读到这份代码，我心中顿时升起一个疑虑：《C Traps and Pitfalls》第 7.7 节 [15]

讲到，C 语言中的整数除法 (/) 和取模 (%) 运算在操作数为负的时候，结果是 implementation-defined。

也就是说，如果 m、d 都是整数，

```
int q = m / d;
int r = m % d;
```

那么 C 语言只保证 $m = q \times d + r$。如果 m、d 当中有负数，那么 q 和 r 的正负号是由实现决定的。比如 $(-13)/4 = (-3)$ 或 $(-13)/4 = (-4)$ 都是合法的。如果采用后一种实现，那么这段转换代码就错了（因为将有 $(-1)\%10 = 9$ ）。只有商向 0 取整，代码才能正常工作。

为了弄清这个问题，我研究了一番。

[15]网上能下载到的一份简略版也有相同的内容，http://www.literateprogramming.com/ctraps.pdf 第 7.5 节。

8.1 语言标准怎么说

C89 我手头没有 ANSI C89 的文稿，只好求助于 K&R88，此书第 41 页第 2.5 节讲到 *The direction of truncation for / and the sign of the result for % are machine-dependent for negative operands, ...*。确实是实现相关的。为此，C89 专门提供了 `div()` 函数，这个函数算出的商是向 0 取整的，便于编写可移植的程序。我得再去查 C++ 标准。

C++98 第 5.6.4 节写到 *If the second operand of / or % is zero the behavior is undefined; otherwise `(a/b)*b + a%b` is equal to `a`. If both operands are nonnegative then the remainder is nonnegative; if not, the sign of the remainder is implementation-defined.* C++ 也没有规定余数的正负号（C++03 的叙述一模一样）。

不过这里有一个注脚，提到 *According to work underway toward the revision of ISO C, the preferred algorithm for integer division follows the rules defined in the ISO Fortran standard, ISO/IEC 1539:1991, in which the quotient is always rounded toward zero.* 即 C 语言的修订标准会采用和 Fortran 一样的取整算法。我又去查了 C99。

C99 第 6.5.5.6 节说 *When integers are divided, the result of the / operator is the algebraic quotient with any fractional part discarded.*（脚注：*This is often called "truncation toward zero".*）

C99 明确规定了商是向 0 取整，也就意味着余数的符号与被除数相同，前面的转换算法能正常工作。C99 Rationale [16] 提到了这个规定的原因，*In Fortran, however, the result will always truncate toward zero, and the overhead seems to be acceptable to the numeric programming community. Therefore, C99 now requires similar behavior, which should facilitate porting of code from Fortran to C.* 既然 Fortran 在数值计算领域都做了如此规定，说明开销（如果有的话）是可以接受的。

C++0x （x 已经确定无疑是个十六进制数了）

最近的 n2800 草案第 5.6.4 节采用了与 C99 类似的表述：*For integeral operands the / operator yields the algebraic quotient with any fractional part discarded; (This is often called truncation towards zero.)* 可见 C++ 还是尽力保持与 C 的兼容性。

小结：C89 和 C++98 都留给实现去决定，而 C99 和 C++0x 都规定商向 0 取整，这算是语言的进步吧。

[16] `http://www.open-std.org/jtc1/sc22/wg14/www/C99RationaleV5.10.pdf`

8.2 C/C++ 编译器的表现

我主要关心 G++ 和 VC++ 这两个编译器。需要说明的是，用代码案例来探查编译器的行为是靠不住的，尽管前面的代码在两个编译器下都能正常工作。除非在文档里有明确表述，否则编译器可能会随时更改实现 –毕竟我们关心的就是 *implementation-defined* 行为。

G++ 4.4 [17] GCC always follows the C99 requirement that the result of division is truncated towards zero. G++ 一直遵循 C99 规范，商向 0 取整，算法能正常工作。

Visual C++ 2008 [18] The sign of the remainder is the same as the sign of the dividend. 这个说法与商向 0 取整是等价的，算法也能正常工作。

8.3 其他语言的规定

既然 C89/C++98/C99/C++0x 已经很有多样性了，索性弄清楚其他语言是怎么定义整数除法的。这里只列出我（陈硕）接触过的几种常用语言。

Java Java 语言规范[19] 明确说 Integer division rounds toward 0. 另外对于 int 整数除法溢出，特别规定不抛异常，且 -2147483648 / -1 = -2147483648 （以及相应的 long 版本）。

C# [20] C# 3.0 语言规定 The division rounds the result towards zero. 对于溢出的情况，规定在 checked 上下文中抛 ArithmeticException 异常；在 unchecked 上下文里没有明确规定，可抛可不抛。(据了解，C# 1.0/2.0 可能有所不同。)

Python Python 在语言参考手册 [21] 的显著位置标明，商是向负无穷取整。Plain or long integer division yields an integer of the same type; the result is that of mathematical division with the 'floor' function applied to the result.

[17] http://gcc.gnu.org/onlinedocs/gcc/Integers-implementation.html
[18] http://msdn.microsoft.com/en-us/library/eayc4fzk.aspx
[19] http://java.sun.com/docs/books/jls/third_edition/html/expressions.html#15.17.2
[20] http://msdn.microsoft.com/en-us/vcsharp/aa336809.aspx
[21] http://docs.python.org/reference/expressions.html#binary-arithmetic-operations

Ruby Ruby 的语言手册没有明说，不过库的手册说到也是向负无穷取整。The quotient is rounded toward -infinity. [22]

Perl [23] Perl 语言默认按浮点数来计算除法，所以没有这个问题。Perl 的整数取模运算规则与 Python/Ruby 一致。

不过要注意，`use integer;` 有可能会改变运算结果，例如。

```
print -10 % 3; // => 2

use integers;
print -10 % 3; // => -1
```

Lua Lua 缺省没有整数类型，除法一律按浮点数来算，因此不涉及商的取整问题。

可以看出，在整数除法的取整问题上，语言分为两个阵营，脚本语言彼此是相似的，C99/C++0x/Java/C# 则属于另一个阵营。既然 Python 和 Ruby 都是用 C 实现的，但是运算规则又自成一体，那么必定能从代码中找到证据。

8.4 脚本语言解释器代码

Python 的代码很好读，我很快就找到了 2.6.6 版实现整数除法和取模运算的函数 i_divmod() [24]

python/tags/r266/Objects/intobject.c

```
565 /* Return type of i_divmod */
566 enum divmod_result {
567     DIVMOD_OK,                  /* Correct result */
568     DIVMOD_OVERFLOW,            /* Overflow, try again using longs */
569     DIVMOD_ERROR                /* Exception raised */
570 };
571
572 static enum divmod_result
573 i_divmod(register long x, register long y,
574          long *p_xdivy, long *p_xmody)
575 {
576     long xdivy, xmody;
577
578     if (y == 0) {
```

[22] http://www.ruby-doc.org/docs/ProgrammingRuby/html/ref_c_numeric.html#Numeric.divmod
[23] http://perldoc.perl.org/perlop.html#Multiplicative-Operators
[24] http://svn.python.org/view/python/tags/r266/Objects/intobject.c?view=markup

```
579         PyErr_SetString(PyExc_ZeroDivisionError,
580                         "integer division or modulo by zero");
581         return DIVMOD_ERROR;
582     }
583     /* (-sys.maxint-1)/-1 is the only overflow case. */
584     if (y == -1 && UNARY_NEG_WOULD_OVERFLOW(x))
585         return DIVMOD_OVERFLOW;
586     xdivy = x / y;
587     /* xdiv*y can overflow on platforms where x/y gives floor(x/y)
588      * for x and y with differing signs. (This is unusual
589      * behaviour, and C99 prohibits it, but it's allowed by C89;
590      * for an example of overflow, take x = LONG_MIN, y = 5 or x =
591      * LONG_MAX, y = -5.)  However, x - xdivy*y is always
592      * representable as a long, since it lies strictly between
593      * -abs(y) and abs(y).  We add casts to avoid intermediate
594      * overflow.
595      */
596     xmody = (long)(x - (unsigned long)xdivy * y);
597     /* If the signs of x and y differ, and the remainder is non-0,
598      * C89 doesn't define whether xdivy is now the floor or the
599      * ceiling of the infinitely precise quotient.  We want the floor,
600      * and we have it iff the remainder's sign matches y's.
601      */
602     if (xmody && ((y ^ xmody) < 0) /* i.e. and signs differ */) {
603         xmody += y;
604         --xdivy;
605         assert(xmody && ((y ^ xmody) >= 0));
606     }
607     *p_xdivy = xdivy;
608     *p_xmody = xmody;
609     return DIVMOD_OK;
610 }
```

python/tags/r266/Objects/intobject.c

注意到这段代码甚至考虑了 -2 147 483 648 / -1 在 32-bit 下会溢出这个特殊情况，让我大吃一惊。宏定义 `UNARY_NEG_WOULD_OVERFLOW` 和函数 `int_mul()` 前面的注释也值得一读。

python/tags/r266/Objects/intobject.c

```
554 /* Integer overflow checking for unary negation: on a 2's-complement
555  * box, -x overflows iff x is the most negative long.  In this case we
556  * get -x == x.  However, -x is undefined (by C) if x /is/ the most
557  * negative long (it's a signed overflow case), and some compilers care.
558  * So we cast x to unsigned long first.  However, then other compilers
559  * warn about applying unary minus to an unsigned operand.  Hence the
560  * weird "0-".
561  */
562 #define UNARY_NEG_WOULD_OVERFLOW(x)     \
563     ((x) < 0 && (unsigned long)(x) == 0-(unsigned long)(x))
```

python/tags/r266/Objects/intobject.c

python/tags/r266/Objects/intobject.c

```
/*
Integer overflow checking for * is painful:  Python tried a couple ways, but
they didn't work on all platforms, or failed in endcases (a product of
-sys.maxint-1 has been a particular pain).

Here's another way:

The native long product x*y is either exactly right or *way* off, being
just the last n bits of the true product, where n is the number of bits
in a long (the delivered product is the true product plus i*2**n for
some integer i).

The native double product (double)x * (double)y is subject to three
rounding errors:  on a sizeof(long)==8 box, each cast to double can lose
info, and even on a sizeof(long)==4 box, the multiplication can lose info.
But, unlike the native long product, it's not in *range* trouble:  even
if sizeof(long)==32 (256-bit longs), the product easily fits in the
dynamic range of a double.  So the leading 50 (or so) bits of the double
product are correct.

We check these two ways against each other, and declare victory if they're
approximately the same.  Else, because the native long product is the only
one that can lose catastrophic amounts of information, it's the native long
product that must have overflowed.
*/

static PyObject *
int_mul(PyObject *v, PyObject *w)
{
    long a, b;
    long longprod;                      /* a*b in native long arithmetic */
    double doubled_longprod;            /* (double)longprod */
    double doubleprod;                  /* (double)a * (double)b */

    CONVERT_TO_LONG(v, a);
    CONVERT_TO_LONG(w, b);
    /* casts in the next line avoid undefined behaviour on overflow */
    longprod = (long)((unsigned long)a * b);
    doubleprod = (double)a * (double)b;
    doubled_longprod = (double)longprod;

    /* Fast path for normal case:  small multiplicands, and no info
       is lost in either method. */
    if (doubled_longprod == doubleprod)
        return PyInt_FromLong(longprod);

    /* Somebody somewhere lost info.  Close enough, or way off?  Note
       that a != 0 and b != 0 (else doubled_longprod == doubleprod == 0).
       The difference either is or isn't significant compared to the
       true value (of which doubleprod is a good approximation).
    */
    {
```

```
541         const double diff = doubled_longprod - doubleprod;
542         const double absdiff = diff >= 0.0 ? diff : -diff;
543         const double absprod = doubleprod >= 0.0 ? doubleprod :
544                                -doubleprod;
545         /* absdiff/absprod <= 1/32 iff
546            32 * absdiff <= absprod -- 5 good bits is "close enough" */
547         if (32.0 * absdiff <= absprod)
548             return PyInt_FromLong(longprod);
549         else
550             return PyLong_Type.tp_as_number->nb_multiply(v, w);
551     }
552 }
```

python/tags/r266/Objects/intobject.c

Ruby 的代码要混乱一些，花点时间还是能找到，这是 1.8.7-p334 的实现，在 `fixdivmod()` 函数。[25]

ruby/tags/v1_8_7_334/numeric.c

```
2185 static void
2186 fixdivmod(x, y, divp, modp)
2187     long x, y;
2188     long *divp, *modp;
2189 {
2190     long div, mod;
2191
2192     if (y == 0) rb_num_zerodiv();
2193     if (y < 0) {
2194         if (x < 0)
2195             div = -x / -y;
2196         else
2197             div = - (x / -y);
2198     }
2199     else {
2200         if (x < 0)
2201             div = - (-x / y);
2202         else
2203             div = x / y;
2204     }
2205     mod = x - div*y;
2206     if ((mod < 0 && y > 0) || (mod > 0 && y < 0)) {
2207         mod += y;
2208         div -= 1;
2209     }
2210     if (divp) *divp = div;
2211     if (modp) *modp = mod;
2212 }
```

ruby/tags/v1_8_7_334/numeric.c

注意到 Ruby 的 Fixnum 整数的表示范围比机器字长小 1bit，直接避免了溢出的可能。

[25] http://svn.ruby-lang.org/cgi-bin/viewvc.cgi/tags/v1_8_7_334/numeric.c?view=markup

8.5 硬件实现

既然 C/C++ 以效率著称，那么应该是贴近硬件实现的。我考察了几种熟悉的硬件平台，它们基本都支持 C99/C++0x 的语意，也就是说新规定没有额外开销。列举如下。（其实我们只关系带符号除法，不过为了完整性，这里一并列出 unsigned/signed 整数除法指令。）

Intel x86/x64 Intel x86 系列的 `DIV/IDIV` 指令明确提到是向 0 取整，与 C99、C++0x、Java、C# 一致。

MIPS 很奇怪，我在 MIPS 的参考手册里没有查到 `DIV/DIVU` 指令的取整方向，不过根据 Patternson&Hennessy 的讲解，似乎向 0 取整硬件上实现起来比较容易。或许我没找对地方？

ARM/Cortex-M3 ARM 没有硬件除法指令，所以不存在这个问题。Cortex-M3 有硬件除法，`SDIV/UDIV` 指令都是向 0 取整。Cortex-M3 的除法指令不能同时算出余数，这很特殊。

MMIX MMIX 是 Knuth 设计的 64-bit CPU，替换原来的 MIX 机器。`DIV` 和 `DIVU` 都是向负无穷取整（依据 TAOCP 第 1.2.4 节的定义，在第一卷 40 页头几行），这是我知道的惟一支持 Python/Ruby 语义的”硬件”平台。

总结：想不到小小的整数除法都有这么大名堂。一段只涉及整数运算的代码，即便能在各种语法相似的语言里运行，结果也可能完全不同。把 C 语言里运行得好好的整数运算代码原样复制到 Python 里，也可能因为负数除法而出错。

9 用异或来交换变量是错误的

翻转一个字符串，例如把 ”12345” 变成 ”54321”，这是一个最简单的不过的编码任务，即便是 C 语言初学者的也能毫不费力地写出类似如下的代码：

Version 1

```
// 版本一，用中间变量交换两个数，好代码
void reverse_by_swap(char* str, int n)
```

```
{
  char* begin = str;
  char* end = str + n - 1;
  while (begin < end) {
    char tmp = *begin;
    *begin = *end;
    *end = tmp;
    ++begin;
    --end;
  }
}
```

Version 1

这个代码清晰，直白，没有任何高深的技巧。

不知从什么时候开始，有人发明了不使用临时变量交换两个数的办法，用“不用临时变量交换两个数”在 google 上能搜到很多文章。下面是一个典型的实现：

Version 2

```
// 版本二，用异或运算交换两个数，烂代码
void reverse_by_xor(char* str, int n)
{
  // WARNING: BAD code
  char* begin = str;
  char* end = str + n - 1;
  while (begin < end) {
    *begin ^= *end;
    *end ^= *begin;
    *begin ^= *end;
    ++begin;
    --end;
  }
}
```

Version 2

受一些过时的教科书的误导，有人认为程序里少用一个变量，节省一个字节的空间，会让程序运行更快。这是不对的，至少在这里不成立：

1. 这个所谓的“技巧”在现代的机器上只会更慢（我甚至怀疑它从来就不可能比原始办法快）。原始办法是两次内存读和写，这个”技巧”是六读三写加三次异或（或许编译器可以优化成两读三写加三次异或）。
2. 同样也不能节省内存，因为中间变量 tmp 通常会是寄存器（稍后有汇编代码供分析）。就算它在函数的局部堆栈 (stack) 上，反正栈已经开在那儿了，也没有进一步的函数调用，根本节约不了一丁点内存。

3. 相反，由于计算步骤较多，会使用更多的指令，编译后的机器码长度会增加。(这不是什么大问题，短的代码不一定快，后面有另外一个例子。)

这个技巧的意义完全在于应付变态的面试，所以知道就行，但绝对不能放在产品代码中。我也想不出问这样的面试题意义何在。

更有甚者，把其中三句：

```
*begin ^= *end;
*end ^= *begin;
*begin ^= *end;
```

写成一句：

```
*begin ^= *end ^= *begin ^= *end;  // WRONG
```

这更是大有问题，会导致未定义的行为 (undefined behavior)。C 语言的一条语句中，一个变量的值只允许改变一次，像 `x = x++` 这种代码都是未定义行为。在 C 语言里没有哪条规则保证这两种写法是等价的。（致语言律师：我知道，黑话叫序列点 [26]，一个语句可能不止一个序列点，请允许我在这里使用不精确的表述。)

这不是一个值得炫耀的技巧，只会丑化劣化代码。

翻转字符串这个问题在 C++ 有更简单的解法——调用 STL 里的 `std::reverse()` 函数。有人担心调用函数会有开销，这种担心是多余的，现在的编译器会把 `std::reverse()` 这种简单函数自动内联展开，生成出来的优化汇编代码和“版本一”一样快。

Version 3

```
// 版本三，用 std::reverse 颠倒一个区间，优质代码
void reverse_by_std(char* str, int n)
{
  std::reverse(str, str + n);
}
```

Version 3

9.1 编译器会分别生成什么代码

注意：查看编译器生成的汇编代码固然是了解程序行为的一个重要手段，但是千万不要认为看到的东西是永恒真理，它只是一时一地的真相。将来换了硬件平台或编

[26] GCC 4.x 有一个编译警告选项 `-Wsequence-point` 可以报告这种错误。
见 http://gcc.gnu.org/bugzilla/show_bug.cgi?id=39121

译器，情况可能会变化。重要的不是为什么版本一比版本二快，而是如何发现这个事实。不要“猜 guess”，要“测 benchmark”。

g++ 版本 4.4.1，编译参数 `-O2 -march=core2`，x86 Linux 系统。

版本一 版本一编译的汇编代码是：

```
.L3:
        movzbl  (%edx), %ecx
        movzbl  (%eax), %ebx
        movb    %bl, (%edx)
        movb    %cl, (%eax)
        incl    %edx
        decl    %eax
        cmpl    %eax, %edx
        jb      .L3
```

我用 C 语言翻译一下：

```
register char bl, cl;
register char* eax;
register char* edx;

L3:
cl = *edx; // 读
bl = *eax; // 读
*edx = bl; // 写
*eax = cl; // 写
++edx;
--eax;
if (edx < eax) goto L3;
```

一共两读两写，临时变量没有使用内存，都在寄存器里完成。考虑指令级并行和 cache 的话，中间六条语句估计能在 3、4 个周期执行完。

版本二

```
.L9:
        movzbl  (%edx), %ecx
        xorb    (%eax), %cl
        movb    %cl, (%eax)
        xorb    (%edx), %cl
        movb    %cl, (%edx)
        decl    %edx
        xorb    %cl, (%eax)
        incl    %eax
        cmpl    %edx, %eax
        jb      .L9
```

C 语言翻译：

```
// 声明与前面一样
cl = *edx;   // 读
cl ^= *eax;  // 读，异或
*eax = cl;   // 写
cl ^= *edx;  // 读，异或
*edx = cl;   // 写
--edx;
*eax ^= cl;  // 读、写，异或
++eax;
if (eax < edx) goto L9;
```

一共六读三写三次异或，多了两条指令。指令多不一定就慢，但是这里异或版实测比临时变量版要慢许多，因为它每条指令都用到了前面一条指令的计算结果，没法并行执行。

版本三 ，生成的代码与版本一一样快。

```
.L21:
        movzbl  (%eax), %ecx
        movzbl  (%edx), %ebx
        movb    %bl, (%eax)
        movb    %cl, (%edx)
        incl    %eax
.L23:
        decl    %edx
        cmpl    %edx, %eax
        jb      .L21
```

这告诉我们，不要想当然地优化，也不要低估编译器的能力。关于现在的编译器有多聪明，这里有一个不错的介绍 [27]

Bjarne Stroustrup 说过，*I like my code to be elegant and efficient. The logic should be straightforward to make it hard for bugs to hide, the dependencies minimal to ease maintenance, error handling complete according to an articulated strategy, and performance close to optimal so as not to tempt people to* ***make the code messy with unprincipled optimizations****. Clean code does one thing well.* 中文据韩磊的翻译《代码整洁之道》[28] （陈硕对文字有修改，出错责任在我）：“我喜欢优雅和高效的代码。代码逻辑应当直截了当，叫缺陷难以隐藏；尽量减少依赖关系，使之便于维护；以某种全局策略一以贯

[27] http://www.linux-kongress.org/2009/slides/compiler_survey_felix_von_leitner.pdf
[28] http://www.china-pub.com/196266

之地处理全部出错情况；性能调校至接近最优，省得引诱别人实施无原则的优化 (unprincipled optimizations)，搞出一团乱麻。整洁的代码只做好一件事。”

这恐怕就是 Bjarne 提及的没有原则的优化，甚至根本连优化都不是。代码的清晰性是首要的。

9.2 为什么短的代码不一定快

我前一篇短文谈到负整数的除法运算（第 8 节），其中引用了一段把整数转为字符串的代码。函数反复计算一个整数除以 10 的商和余数。我原以为编译器会用一条 DIV 除法指令来算，实际生成的代码让我大吃一惊：

```
.L2:
        movl    $1717986919, %eax
        imull   %ebx
        movl    %ebx, %eax
        sarl    $31, %eax
        sarl    $2, %edx
        subl    %eax, %edx
        movl    %edx, %eax
        leal    (%edx,%edx,4), %edx
        addl    %edx, %edx
        subl    %edx, %ebx
        movl    %ebx, %edx
        movl    %eax, %ebx
        movzbl  (%edi,%edx), %eax
        movb    %al, (%esi)
        addl    $1, %esi
        testl   %ebx, %ebx
        jne     .L2
```

一条 DIV 指令被替换成了十来条指令，编译器不是傻子，必然有原因。这里我不详细解释到底是怎么算的，基本思路是把除法转换为乘法，用倒数来算。其中出现了一个魔数 1717986919，转换成 16 进制是 0x66666667，等于 $(2^33+3)/5$。

现代处理器上乘法运算和加减法一样快，比除法快一个数量级左右，编译器生成这样的代码是有理由的。10 多年前出版的神作《程序设计实践》上介绍过如何做 micro benchmarking，方法和结果都值得一读，当然里边的数据恐怕有点过时了。

有本奇书《Hacker's Delight》，国内译作《高效程序的奥秘》[29]，展示了大量这种速算技巧，第 10 章专门讲整数常量的除法。我不会把书中如天书般的技巧应用到产品代码中，但是我相信现代编译器的作者是知道这些技巧的，他们会合理地使用这

[29] http://www.china-pub.com/18801

些技巧来提高生成代码的质量。现在已经不是那个懂点汇编就能打败编译器的时代了。

Mark C. Chu-Carroll 有一篇博客文章《The "C is Efficient" Language Fallacy》[30] 的观点我非常赞同：

> Making real applications run really fast is something that's done with the help of a compiler. Modern architectures have reached the point where people can't code effectively in assembler anymore - switching the order of two independent instructions can have a dramatic impact on performance in a modern machine, and the constraints that you need to optimize for are just more complicated than people can generally deal with.
>
> So for modern systems, *writing an efficient program is sort of a partnership*. The human needs to careful choose algorithms - the machine can't possibly do that. And the machine needs to carefully compute instruction ordering, pipeline constraints, memory fetch delays, etc. The two together can build really fast systems. But the two parts aren't independent: *the human needs to express the algorithm in a way that allows the compiler to understand it well enough to be able to really optimize it.*

最后，说几句 C++ 模板。假如要编写一个任意进制的转换程序。C 语言的函数声明是：

```
bool convert(char* buf, size_t bufsize, int value, int radix);
```

既然进制是编译期常量，C++ 可以用带非类型模板参数的函数模板来实现，函数里边的代码与 C 相同。

```
template<int radix>
bool convert(char* buf, size_t bufsize, int value);
```

模板确实会使代码膨胀，但是这样的膨胀有时候是好事情，编译器能针对不同的常数生成快速算法。滥用 C++ 模板当然是错的，适当使用不会有问题。

[30] http://scienceblogs.com/goodmath/2006/11/the_c_is_efficient_language_fa.php

10 在单元测试中 mock 系统调用

陈硕在《分布式程序的自动化回归测试》[31] 一文中曾经谈到单元测试在分布式程序开发中的优缺点（好吧，主要是缺点）。但是，在某些情况下，单元测试是很有必要的，在测试 failure 场景的时候尤显重要，比如：

- 在开发存储系统时，模拟 read(2)/write(2) 返回 `EIO` 错误（有可能是磁盘写满了，有可能是磁盘出坏道读不出数据）。
- 在开发网络库的时候，模拟 write(2) 返回 EPIPE 错误（对方意外断开连接）。
- 在开发网络库的时候，模拟自连接 (self-connection)，网络库应该用 getsockname(2) 和 getpeername(2) 判断是否是自连接，然后断开之。
- 在开发网络库的时候，模拟本地 ephemeral port 耗尽，connect(2) 返回 `EAGAIN` 临时错误。
- 让 gethostbyname(2) 返回我们预设的值，防止单元测试给公司的 DNS server 带来太大压力。

这些 test case 恐怕很难用前文提到的 test harness 来测试，该单元测试上场了。现在的问题是，如何 mock 这些系统函数？或者换句话说，如何把对系统函数的依赖注入到被测程序中？

10.1 系统函数的依赖注入

在《修改代码的艺术》[5] 一书第 4.3.2 节中，作者介绍了链接期接缝 (link seam)，正好可以解决我们的问题。另外，在 Stack Overflow 的一个帖子 [32] 里也总结了几种做法。

如果程序（库）在编写的时候就考虑了可测试性，那么用不到上面的 hack 手段，我们可以从设计上解决依赖注入的问题。这里提供两个思路。

[31] `http://blog.csdn.net/Solstice/archive/2011/04/25/6359748.aspx`
[32] `http://stackoverflow.com/questions/2924440/advice-on-mocking-system-calls`

其一 采用传统的面向对象的手法，借助运行期的迟绑定实现注入与替换。自己写一个 System interface，把程序里用到的 open、close、read、write、connect、bind、listen、accept、gethostname、getpeername、getsockname 等等函数统统用虚函数封装一层。然后在代码里不要直接调用 open()，而是调用 System::instance().open()。这样代码主动把控制权交给了 System interface，我们可以在这里动动手脚。在写单元测试的时候，把这个 singleton instance 替换为我们的 mock object，这样就能模拟各种 error code。

其二 采用编译期或链接期的迟绑定。注意到在第一种做法中，运行期多态是不必要的，因为程序从生到死只会用到一个 implementation object。为此付出虚函数调用的代价似乎有些不值。（其实，跟系统调用比起来，虚函数这点开销可忽略不计。）

我们可以写一个 system namespace 头文件，在其中声明 read() 和 write() 等普通函数，然后在.cc 文件里转发给对应系统的系统函数::read() 和::write() 等。

muduo/net/SocketsOps.h
```
namespace sockets
{
  int connect(int sockfd, const struct sockaddr_in& addr);
}
```
muduo/net/SocketsOps.h

muduo/net/SocketsOps.cc
```
int sockets::connect(int sockfd, const struct sockaddr_in& addr)
{
  return ::connect(sockfd, sockaddr_cast(&addr), sizeof addr);
}
```
muduo/net/SocketsOps.cc

有了这么一层间接性，就可以在编写单元测试的时候动动手脚，链接我们的 stub 实现，以达到替换实现的目的：

MockSocketsOps.cc
```
int sockets::connect(int sockfd, const struct sockaddr_in& addr)
{
  errno = EAGAIN;
  return -1;
}
```
MockSocketsOps.cc

C++ 一个程序只能有一个 main() 入口，所以要先把程序做成 library，再用单元测试代码链接这个 library。假设有一个 mynetcat 程序，为了编写 C++ 单元测试，我们把它拆成两部分，library 和 main()，源文件分别是 mynetcat.cc 和 main.cc。

在编译普通程序的时候：

```
g++ main.cc mynetcat.cc SocketsOps.cc -o mynetcat
```

在编译单元测试时这么写：

```
g++ test.cc mynetcat.cc MockSocketsOps.cc -o test
```

以上是最简单的例子，在实际开发中可以让 stub 功能更强大一些，比如根据不同的 test case 返回不同的错误。

第二种做法无需用到虚函数，代码写起来也比较简洁，只用前缀 sockets:: 即可。例如应用程序的代码里写 sockets::connect(fd, addr)。

muduo 目前还没有单元测试，只是预留了这些 stubs。

namespace 的好处在于它不是封闭的，我们可以随时打开往里添加新的函数，而不用改动原来的头文件。这也是以 non-member non-friend 函数为接口的优点。

以上两种做法还有一个好处，即只 mock 我们关心的部分代码。如果程序用到了 SQLite 或 Berkeley DB 这些会访问本地文件系统的第三方库，那么我们的 System interface 或 system namespace 不会拦截这些第三方库的 open(2)、close(2)、read(2)、write(2) 等系统调用。

10.2 链接期垫片 (link seam)

如果程序在一开始编码的时候没有考虑单元测试，那么又该如何注入 mock 系统调用呢？

上面第二种做法已经给出了答案，那就是使用 link seam （链接期垫片）。

比方说要仿冒 connect(2) 函数，那么我们在单元测试程序里实现一个自己的 connect() 函数，它遮盖了同名的系统函数。在链接的时候，linker 会优先采用我们自己定义的函数。（这对动态链接是成立的，如果是静态链接，会报 multiple definition 错误。好在绝大多数情况下 libc 是动态链接的。）

mock connect(2)

```
typedef int (*connect_func_t)(int sockfd,
                              const struct sockaddr *addr,
                              socklen_t addrlen);

connect_func_t connect_func = dlsym(RTDL_NEXT, "connect");

bool mock_connect;
```

```
int mock_connect_errno;

// mock connect
extern "C" int connect(int sockfd,
                       const struct sockaddr *addr,
                       socklen_t addrlen)
{
  if (mock_connect) {
    errno = mock_connect_errno;
    return errno == 0 ? 0 : -1;
  } else {
    return connect_func(sockfd, addr, addrlen);
  }
}
```

mock connect(2)

如果程序真的要调用 connect(2) 怎么办？在我们自己的 mock connect(2) 里不能再调用 connect() 了，否则会出现无限递归。为了防止这种情况，我们用 dlsym(RTDL_NEXT, "connect") 获得 connect(2) 系统函数的真实地址，然后通过函数指针 connect_func 来调用它。

10.3 例子：ZooKeeper 的 C client library

ZooKeeper 的 C client library 正是采用了 link seams 来编写单元测试，代码见：

http://svn.apache.org/repos/asf/zookeeper/tags/release-3.3.3/src/c/tests/LibCMocks.h

http://svn.apache.org/repos/asf/zookeeper/tags/release-3.3.3/src/c/tests/LibCMocks.cc

10.4 其他做法

Stack Overflow 的帖子里还提到一个做法，可以方便地替换动态库里的函数，即使用 ld 的 –wrap 参数，文档里说得很清楚，这里不再赘述。

man ld(1)

```
--wrap=symbol
    Use a wrapper function for symbol.  Any undefined reference to
    symbol will be resolved to "__wrap_symbol".  Any undefined
    reference to "__real_symbol" will be resolved to symbol.

    This can be used to provide a wrapper for a system function.  The
    wrapper function should be called "__wrap_symbol".  If it wishes to
    call the system function, it should call "__real_symbol".
```

```
Here is a trivial example:

        void *
        __wrap_malloc (size_t c)
        {
          printf ("malloc called with %zu\n", c);
          return __real_malloc (c);
        }

If you link other code with this file using --wrap malloc, then all
calls to "malloc" will call the function "__wrap_malloc" instead.
The call to "__real_malloc" in "__wrap_malloc" will call the real
"malloc" function.

You may wish to provide a "__real_malloc" function as well, so that
links without the --wrap option will succeed.  If you do this, you
should not put the definition of "__real_malloc" in the same file
as "__wrap_malloc"; if you do, the assembler may resolve the call
before the linker has a chance to wrap it to "malloc".
```

man ld(1)

10.5 第三方 C++ 库

Link seam 同样适用于第三方 C++ 库

比方说公司某个基础库团队提供了了 File class，但是这个 class 没有使用虚函数，我们无法通过 sub-classing 的办法来实现 mock object。

File.h

```
class File : boost::noncopyable
{
 public:
  File(const char* filename);
  ~File();

  int readn(void* data, int len);
  int writen(const void* data, int len);
  size_t getSize() const;
 private:
};
```

File.h

如果需要为用到 File class 的程序编写单元测试，那么我们可以自己定义其成员函数的实现，这样可以注入任何我们想要的结果。

MockFile.cc

```
int File::readn(void* data, int len)
{
```

```
  return -1;
}
```
MockFile.cc

（这个做法对动态库是可行的，静态库会报错。我们要么让对方提供专供单元测试的动态库，要么拿过源码来自己编译一个。）

Java 也有类似的做法，在 class path 里替换我们自己的 stub jar 文件，以实现 link seam。不过 Java 有动态代理，很少用得着 link seam 来实现依赖注入。

11 iostream 的用途与局限

本文主要考虑 x86 Linux 平台，不考虑跨平台的可移植性，也不考虑国际化 (i18n)，但是要考虑 32-bit 和 64-bit 的兼容性。本文以 stdio 指代 C 语言的 `scanf/printf` 系列格式化输入输出函数。本文提及“C 语言”（包括库函数和线程安全性），指的是 Linux 下 gcc + glibc 这一套编译器和库的具体实现，也可以认为是符合 POSIX.1-2001 的实现。本文注意区分“编程初学者”和“C++ 初学者”，二者含义不同。

C++ iostream 的主要作用是让初学者有一个方便的命令行输入输出试验环境，在真实的项目中很少用到 iostream，因此不必把精力花在深究 iostream 的格式化与 manipulator（格式操控符）。iostream 的设计初衷是提供一个可扩展的类型安全的 IO 机制，但是后来莫名其妙地加入了 locale 和 facet 等累赘。其整个设计复杂不堪，多重 + 虚拟继承的结构也很巴洛克，性能方面几无亮点。iostream 在实际项目中的用处非常有限，为此投入过多学习精力实在不值。

11.1 stdio 格式化输入输出的缺点

11.1.1 对编程初学者不友好

看看下面这段简单的输入输出代码，这是 C 语言教学的基本示例。

```
#include <stdio.h>

int main()
{
  int i;
  short s;
```

```
  float f;
  double d;
  char name[80];

  scanf("%d %hd %f %lf %s", &i, &s, &f, &d, name);
  printf("%d %d %f %f %s\n", i, s, f, d, name);
}
```

注意到其中

- 输入和输出用的格式字符串不一样。输入 short 要用 `%hd`，输出用 `%d`；输入 double 要用 `%lf`，输出用 `%f`。
- 输入的参数不统一。对于 `i`、`s`、`f`、`d` 等变量，在传入 `scanf()` 的时候要取地址 (&)，而对于字符数组 `name`，则不用取地址。

  读者可以试一试如何用几句话向刚开始学编程的初学者解释上面两条背后原因 (涉及到传递函数不定参数时的类型转换，函数调用栈的内存布局，指针的意义，字符数组退化为字符指针等等)，如果一开始解释不清，只好告诉学生“这是规定”。
- 缓冲区溢出的危险。上面的例子在读入 `name` 的时候没有指定大小，这是用 C 语言编程的安全漏洞的主要来源。应该在一开始就强调正确的做法，避免养成错误的习惯。

正确而安全的做法如 Bjarne Stroustrup 在《Learning Standard C++ as a New Language》所示：

```
int main()
{
  const int max_name = 80;
  char name[max_name];

  char fmt[10];
  sprintf(fmt, "%%%ds", max_name - 1);
  scanf(fmt, name);
  printf("%s\n", name);
}
```

这个动态构造格式化字符串的做法恐怕更难向初学者解释。

11.1.2 安全性 (security)

C 语言的安全性问题近十几年来引起了广泛的注意，C99 增加了 `snprintf()` 等能够指定输出缓冲区大小的函数，输出方面的安全性问题已经得到解决；输入方面似乎没有太大进展，还要靠程序员自己动手。

考虑一个简单的编程任务：从文件或标准输入读入一行字符串，行的长度不确定。我发现竟然没有哪个 C 语言标准库函数能完成这个任务，除非自己动手 (roll your own)。

首先，`gets()` 是错误的，因为不能指定缓冲区的长度。

其次，`fgets()` 也有问题。它能指定缓冲区的长度，所以是安全的。但是程序必须预设一个长度的最大值，这不满足题目要求“行的长度不确定”。另外，程序无法判断 `fgets()` 到底读了多少个字节。为什么？考虑一个文件的内容是 9 个字节的字符串 "Chen\000Shuo"，注意中间出现了 '\0' 字符，如果用 `fgets()` 来读取，客户端如何知道 "\000Shuo" 也是输入的一部分？毕竟 `strlen()` 只返回 4，而且整个字符串里没有 '\n' 字符。

最后，可以用 glibc 定义的 `getline(3)` 函数来读取不定长的“行”。这个函数能正确处理各种情况，不过它返回的是 `malloc()` 分配的内存，要求调用端自己 `free()`。

11.1.3 类型安全 (type-safety)

如果 `printf()` 的整数参数类型是 int、long 等内置类型，那么 `printf()` 的格式化字符串很容易写。但是如果参数类型是系统头文件里 typedef 的类型呢？

如果你想在程序中用 `printf()` 来打印日志，你能一眼看出下面这些类型该用 "%d" "%ld" "%lld" 中的哪一个来输出？你的选择是否同时兼容 32-bit 和 64-bit 平台？

- `clock_t`。这是 `clock(3)` 的返回类型
- `dev_t`。这是 `mknod(3)` 的参数类型
- `in_addr_t`、`in_port_t`。这是 struct `sockaddr_in` 的成员类型
- `nfds_t`。这是 `poll(2)` 的参数类型
- `off_t`。这是 `lseek(2)` 的参数类型，麻烦的是，这个类型与宏定义 `_FILE_OFFSET_BITS` 有关。

- pid_t、uid_t、gid_t。这是 getpid(2) getuid(2) getgid(2) 的返回类型
- ptrdiff_t。printf() 专门定义了 "t" 前缀来支持这一类型（即使用 "%td" 来打印）。
- size_t、ssize_t。这两个类型到处都在用。printf() 为此专门定义了 "z" 前缀来支持这两个类型（即使用 "%zu" 或 "%zd" 来打印）。
- socklen_t。这是 bind(2) 和 connect(2) 的参数类型
- time_t。这是 time(2) 的返回类型，也是 gettimeofday(2) 和 clock_gettime(2) 的结构体参数的成员类型

如果在 C 程序里要正确打印以上类型的整数，恐怕要费一番脑筋。《The Linux Programming Interface》的作者建议（3.6.2 节）先统一转换为 long 类型再用 "%ld" 来打印；对于某些类型仍然需要特殊处理，比如 off_t 的类型可能是 long long。

还有，int64_t 在 32-bit 和 64-bit 平台上是不同的类型，为此，如果程序要打印 int64_t 变量，需要包含 <inttypes.h> 头文件，并且使用 PRId64 宏：

```
#include <stdio.h>
#define __STDC_FORMAT_MACROS
#include <inttypes.h>

int main()
{
  int64_t x = 100;
  printf("%" PRId64 "\n", x);
  printf("%06" PRId64 "\n", x);
}
```

muduo 的 Timestamp 使用了 PRId64。[33] Google C++ 编码规范也提到了 64-bit 兼容性。[34]

这些问题在 C++ 里都不存在，在这方面 iostream 是个进步。

C stdio 在类型安全方面原本还有一个缺点，即格式化字符串与参数类型不匹配会造成难以发现的 bug，不过现在的编译器已经能够检测很多这种错误（使用 -Wall 编译选项）：

[33] http://code.google.com/p/muduo/source/browse/trunk/muduo/base/Timestamp.cc#25
[34] http://google-styleguide.googlecode.com/svn/trunk/cppguide.xml#64-bit_Portability

```
int main()
{
  double d = 100.0;
// warning: format '%d' expects type 'int', but argument 2 has type 'double'
  printf("%d\n", d);

  short s;
// warning: format '%d' expects type 'int*', but argument 2 has type 'short int*'
  scanf("%d", &s);

  size_t sz = 1;
  // no warning
  printf("%zd\n", sz);
}
```

11.1.4 不可扩展？

C stdio 的另外一个缺点是无法支持自定义的类型，比如我写了一个 `Date` class，我无法像打印 int 那样用 `printf()` 来直接打印 `Date` 对象。

```
struct Date
{
  int year, month, day;
};

Date date;
printf("%D", &date); // WRONG
```

Glibc 放宽了这个限制，允许用户调用 `register_printf_function(3)` 注册自己的类型。当然，前提是与现有的格式字符不冲突（这其实大大限制了这个功能的用处，现实中也几乎没有人真的去用它）。[35] [36]

11.1.5 性能

C stdio 的性能方面有两个弱点。

1. 使用一种 little language （现在流行叫 DSL）来配置格式。固然有利于紧凑性和灵活性，但损失了一点点效率。每次打印一个整数都要先解析 "%d" 字符串，大多数情况下不是问题，某些场合需要自己写整数到字符串的转换。

[35] http://www.gnu.org/s/hello/manual/libc/Printf-Extension-Example.html
[36] http://en.wikipedia.org/wiki/Printf#Custom_format_placeholders

2. C locale 的负担。locale 指的是不同语种对“什么是空白”、“什么是字母”，“什么是小数点”有不同的定义（德语里边小数点是逗号，不是句点）。C 语言的 `printf()`、`scanf()`、`isspace()`、`isalpha()`、`ispunct()`、`strtod()` 等等函数都和 locale 有关，而且可以在运行时动态更改 locale。就算是程序只使用默认的"C" locale，仍然要为这个灵活性付出代价。

11.2 iostream 的设计初衷

iostream 的设计初衷包括克服 C stdio 的缺点，提供一个高效的可扩展的类型安全的 IO 机制。“可扩展”有两层意思，一是可以扩展到用户自定义类型，二是通过继承 iostream 来定义自己的 stream，本文把前一种称为“类型可扩展”后一种称为“功能可扩展”。

类型可扩展和类型安全

“类型可扩展”和“类型安全”都是通过函数重载来实现的。

iostream 对初学者很友好，用 iostream 重写与前面同样功能的代码：

```
#include <iostream>
#include <string>
using namespace std;

int main()
{
  int i;
  short s;
  float f;
  double d;
  string name;

  cin >> i >> s >> f >> d >> name;
  cout << i << " " << s << " " << f << " " << d << " " << name << endl;
}
```

这段代码恐怕比 scanf/printf 版本容易解释得多，而且没有安全性 (security) 方面的问题。

我们自己的类型也可以融入 iostream，使用起来与 built-in 类型没有区别。这主要得力于 C++ 可以定义 non-member functions/operators。

```
#include <ostream>  // 是不是太重量级了？

class Date
{
 public:
  Date(int year, int month, int day)
    : year_(year), month_(month), day_(day)
  {
  }

  void writeTo(std::ostream& os) const
  {
    os << year_ << '-' << month_ << '-' << day_;
  }

 private:
  int year_, month_, day_;
};

std::ostream& operator<<(std::ostream& os, const Date& date)
{
  date.writeTo(os);
  return os;
}

int main()
{
  Date date(2011, 4, 3);
  std::cout << date << std::endl;
}
```

iostream 凭借这两点（类型安全和类型可扩展），基本克服了 stdio 在使用上的不便与不安全。如果 iostream 止步于此，那它将是一个非常便利的库，可惜它前进了另外一步。

iostream 的演变大致可分为三个阶段，第一阶段是 Bjarne Stroustrup 在 CFront 1.0 里实现的 streams 库。[37] 这个库符合前述“类型安全、可扩展、高效”等特征，Bjarne 发明了用移位操作符（<< 和 >>）做 I/O 的办法，`istream` 和 `ostream` 都是具体类，也没有 manipulator。第二阶段，Jerry Schwarz 设计了“经典”iostream，在 CFront 2.0 中他的设计大部分得以体现。他发明了 manipulator，实现手法是以函数指针参数来重载输入输出操作符；他还采用多重继承和虚拟继承手法，设计了现在我们看到的 ios 菱形继承体系；此外，`istream` 有了基类 `ios`，也有了派生类 `ifstream` 和 `istrstream`，`ostream` 也是如此。第三阶段，在 C++ 标准化的过程中，iostream

[37] http://www.softwarepreservation.org/projects/c_plus_plus/cfront/release_-1.0/src/cfront/incl/stream.h/view

有大幅更新，Nathan Myers 设计了 Locale/Facet 体系，iostream 被模板化以适应宽窄两种字符，以及以 stringstreams 替换 strstreams 等等。

11.3 iostream 与标准库其他组件的交互

11.3.1 “值语义”与“对象语义”

不同于标准库其他 class 的“值语义/value semantics”，iostream 是“对象语义/object semantics”[38]，即 iostream 是 non-copyable。这是正确的，因为如果 fstream 代表一个打开的文件的话，拷贝一个 fstream 对象意味着什么呢？表示打开了两个文件吗？如果销毁一个 fstream 对象，它会关闭文件句柄，那么另一个 fstream 对象副本会因此受影响吗？

iostream 禁止拷贝，利用对象的生命期来明确管理资源（如文件），很自然地就避免了这些问题。这就是 RAII，一种重要且独特的 C++ 编程手法。

C++ 同时支持“数据抽象/data abstraction”和“面向对象编程/object-oriented”，其实主要就是“值语义”与“对象语义”的区别，这是一个比较大的话题，见12节。

11.3.2 std::string

iostream 可以与 std::string 配合得很好。但是有一个问题：谁依赖谁？

std::string 的 operator<< 和 operator>> 是如何声明的？注意 operator<<是个二元操作符，它的参数是 std::ostream 和 std::string。<string> 头文件在声明这两个 operators 的时候要不要 #include <iostream>？

iostream 和 std::string 都可以单独 include 来使用，显然 iostream 头文件里不会定义 std::string 的 << 和 >> 操作。但是，如果 <string>要 #include <iostream>，岂不是让 string 的用户被迫也用了 iostream？编译 iostream 头文件可是相当的慢啊（因为 iostream 是 template，其实现代码都放到了头文件中）。

标准库的解决办法是定义 <iosfwd> 头文件，其中包含 istream 和 ostream 等的前向声明 (forward declarations)，这样 <string> 头文件在定义输入输出操作符时就

[38]对象语义在其他面向对象的语言里通常叫做“引用语义/reference semantics”，为了避免与 C++ 的“引用”类型冲突，我这里用“对象语义”这个术语。

可以不必包含 <iostream>，只需要包含简短得多的 <iosfwd>，避免引入不必要的依赖。我们自己写程序也可借此学习如何支持可选的功能。

值得注意的是，istream::getline() 成员函数的参数类型是 char*，因为 <istream> 没有包含 <string>，而我们常用的 std::getline() 函数是个 non-member function，定义在 <string> 里边。

11.3.3 std::complex

标准库的复数类 std::complex 的情况比较复杂。<complex> 头文件会自动包含 <sstream>，后者会包含 <istream> 和 <ostream>，这是个不小的负担。问题是，为什么？

它的 operator>> 操作比 string 复杂得多，如何应对格式不正确的情况？输入字符串不会遇到格式不正确，但是输入一个复数可能遇到各种问题，比如数字的格式不对等。我怀疑有谁会真的在产品项目里用 operator>> 来读入字符方式表示的复数，这样的代码的健壮性如何保证？基于同样的理由，我认为产品代码中应该避免用 istream 来读取带格式的内容，后面也不再谈 istream 格式化输入的缺点，它已经被秒杀。

它的 operator<< 也很奇怪，它不是直接使用参数 ostream& os 对象来输出，而是先构造 ostringstream，输出到该 string stream，再把结果字符串输出到 ostream。简化后的代码如下：

```
template<typename T>
std::ostream& operator<<(std::ostream& os, const std::complex<T>& x)
{
  std::ostringstream s;
  s << '(' << x.real() << ',' << x.imag() << ')';
  return os << s.str();
}
```

注意到 ostringstream 会用到动态分配内存，也就是说，每输出一个 complex 对象就会分配释放一次内存，效率堪忧。

根据以上分析，我认为 iostream 和 complex 配合得不好，但是它们耦合得更紧密（与 string/iostream 相比），这可能是个不得已的技术限制吧（complex 是 class template，其 operator<< 必须在头文件中定义，而这个定义又用到了 ostringstream，不得已包含了 sstream 的实现）。

如果程序要对 complex 做 IO，从效率和健壮性方面考虑，建议不要使用 iostream。

11.4 iostream 在使用方面的缺点

在简单使用 iostream 的时候，它确实比 stdio 方便，但是深入一点就会发现，二者可说各擅胜场。下面谈一谈 iostream 在使用方面的缺点。

11.4.1 格式化输出很繁琐

iostream 采用 manipulator 来格式化，如果我想按照 2010-04-03 的格式输出前面定义的 `Date class`，那么代码要改成：

```
  class Date
  {
    // ...

    void writeTo(std::ostream& os) const
    {
-     os << year_ << '-' << month_ << '-' << day_;
+     os << year_ << '-'
+        << std::setw(2) << std::setfill('0') << month_ << '-'
+        << std::setw(2) << std::setfill('0') << day_;
    }

    // ...
```

假如用 stdio，会简短得多，因为 printf 采用了一种表达能力较强的小语言来描述输出格式。

```
  class Date
  {
    // ...

    void writeTo(std::ostream& os) const
    {
-     os << year_ << '-' << month_ << '-' << day_;
+     char buf[32];
+     snprintf(buf, sizeof buf, "%d-%02d-%02d", year_, month_, day_);
+     os << buf;
    }

    // ...
```

使用小语言来描述格式还带来另外一个好处：外部可配置。

11.4.2 外部可配置性

能不能用外部的配置文件来定义程序中日期的格式？C stdio 很好办，把格式字符串 "%d-%02d-%02d" 保存到配置里就行。但是 iostream 呢？它的格式是写死在代码里的，灵活性大打折扣。

再举一个例子，程序的 message 的多语言化。

```
const char* name = "Shuo Chen";
int age = 29;
printf("My name is %1$s, I am %2$d years old.\n", name, age);
cout << "My name is " << name << ", I am " << age << " years old." << endl;
```

对于 stdio，要让这段程序支持中文的话，把代码中的"My name is ..."，替换为 " 我叫%1$s，今年%2$d 岁。\n" 即可。也可以把这段提示语做成资源文件，在运行时读入。而对于 iostream，恐怕没有这么方便，因为代码是支离破碎的。

C stdio 的格式化字符串体现了重要的“数据就是代码”的思想，这种“数据”与“代码”之间的相互转换是程序灵活性的根源，远比 OO 更为灵活。

11.4.3 stream 的状态

如果我想用 16 进制方式输出一个整数 x，那么可以用 hex 操控符，但是这会改变 ostream 的状态。比如说

```
int x = 8888;
cout << hex << showbase << x << endl;  // print 0x22b8
cout << 123 << endl;                   // print 0x7b
```

这这段代码会把 123 也按照 16 进制方式输出，这恐怕不是我们想要的。

再举一个例子，setprecision() 也会造成持续影响：

```
double d = 123.45;
printf("%8.3f\n", d);
cout << d << endl;
cout << setw(8) << fixed << setprecision(3) << d << endl;
cout << d << endl;
```

输出是：

```
$ ./a.out
 123.450    %8.3f 的输出
123.45      默认 cout 格式
 123.450    我们设置的精度
123.450     精度持续影响后续输出
```

可见代码中的 setprecision() 影响了后续输出的精度。注意 setw() 不会造成影响，它只对下一个输出有效。

这说明，如果使用 manipulator 来控制格式，需要时刻小心防止影响了后续代码。而使用 C stdio 就没有这个问题，它是“上下文无关的”。

11.4.4 知识的通用性

在 C 语言之外，有其他很多语言也支持 printf() 风格的格式化，例如 Java、Perl、Ruby 等等 [39]。学会 printf() 的格式化方法，这个知识还可以用到其他语言中。但是 C++ iostream 只此一家别无分店，反正都是格式化输出，学习 stdio 的投资回报率更高。

基于这点考虑，我认为不必深究 iostream 的格式化方法，只需要用好它最基本的类型安全输出即可。在真的需要格式化的场合，可以考虑 snprintf() 打印到栈上缓冲，再用 ostream 输出。

11.4.5 线程安全与原子性

iostream 的另外一个问题是线程安全性。POSIX.1-2001 明确要求 stdio 函数是线程安全的，[40] 而且还提供了 flockfile(3)/funlockfile(3) 之类的函数来明确控制 FILE* 的加锁与解锁。

iostream 在线程安全方面没有保证，就算单个 operator<< 是线程安全的，也不能保证原子性。因为 cout << a << b; 是两次函数调用，相当于 cout.operator<<(a).operator<<(b)。两次调用中间可能会被打断进行上下文切换，造成输出内容不连续，插入了其他线程打印的字符。

而 fprintf(stdout, "%s %d", a, b); 是一次函数调用，而且是线程安全的，打印的内容不会受其他线程影响。

因此，iostream 并不适合在多线程程序中做 logging。

[39] http://en.wikipedia.org/wiki/Printf#Programming_languages_with_printf
[40] http://www.kernel.org/doc/man-pages/online/pages/man7/pthreads.7.html

11.4.6 iostream 的局限

根据以上分析，我们可以归纳 iostream 的局限：

- 输入方面，`istream` 不适合输入带格式的数据，因为“纠错”能力不强，进一步的分析请见孟岩写的《契约思想的一个反面案例》，孟岩说“复杂的设计必然带来复杂的使用规则，而面对复杂的使用规则，用户是可以投票的，那就是：你做你的，我不用!”可谓鞭辟入里。如果要用 `istream`，我推荐的做法是用 `std::getline()` 读入一行数据到 `std::string`，然后用正则表达式来判断内容正误，并做分组，最后用 `strtod()/strtol()` 之类的函数做类型转换。这样似乎更容易写出健壮的程序。
- 输出方面，`ostream` 的格式化输出非常繁琐，而且写死在代码里，不如 stdio 的小语言那么灵活通用。建议只用作简单的无格式输出。
- log 方面，由于 `ostream` 没有办法在多线程程序中保证一行输出的完整性，建议不要直接用它来写 log。如果是简单的单线程程序，输出数据量较少的情况下可以酌情使用。当然，产品代码应该用成熟的 logging 库，而不要用其它东西来凑合。
- in-memory 格式化方面，由于 `ostringstream` 会动态分配内存，它不适合性能要求较高的场合。
- 文件 IO 方面，如果用作文本文件的输入或输出，`fstreams` 有上述的缺点；如果用作二进制数据输入输出，那么自己简单封装一个 `File` class 似乎更好用，也不必为用不到的功能付出代价（后文还有具体例子）。`ifstream` 的一个用处是在程序启动时读入简单的文本配置文件。如果配置文件是其他文本格式（XML 或 JSON），那么用相应的库来读，也用不到 `ifstream`。
- 性能方面，iostream 没有兑现“高效性”诺言。iostream 在某些场合比 stdio 快，在某些场合比 stdio 慢，对于性能要求较高的场合，我们应该自己实现字符串转换（见后文的代码与测试）。iostream 性能方面的一个注脚：在线 ACM/ICPC 判题网站上，如果一个简单的题目发生超时错误，那么把其中 iostream 的输入输出换成 stdio，有时就能过关 [41]。

[41] 另外可以先试试调用 `cin.sync_with_stdio(false);`，见 http://stackoverflow.com/questions/9371238

既然有这么多局限，iostream 在实际项目中的应用就大为受限了，在这上面投入太多的精力实在不值得。说实话，我没有见过哪个 C++ 产品代码使用 iostream 来作为输入输出设施。Google 的 C++ 编程规范也对 stream 的使用做了明确的限制。[42]

11.5 iostream 在设计方面的缺点

iostream 的设计有相当多的 WTFs，stackoverflow 有人吐槽说“If you had to judge by today's software engineering standards, would C++'s IOStreams still be considered well-designed?”[43]。

11.5.1 面向对象的设计

iostream 是个面向对象的 IO 类库，本节简单介绍它的继承体系。

对 iostream 略有了解的人会知道它用了多重继承和虚拟继承，简单地画个类图如下，是典型的菱形继承：

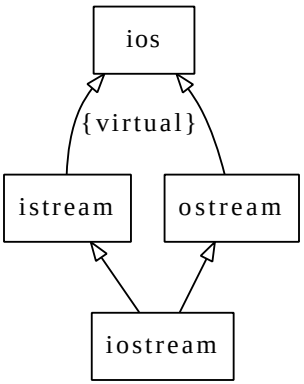

如果加深一点了解，会发现 iostream 现在是模板化的，同时支持窄字符和宽字符。下图是现在的继承体系，同时画出了 `fstreams` 和 `stringstreams`。图中方框的第二三行是模板的具现化类型，也就是我们代码里常用的具体类型（通过 typedef 定义）。

这个继承体系糅合了面向对象与泛型编程，但可惜它两方面都不讨好。

[42] http://google-styleguide.googlecode.com/svn/trunk/cppguide.xml#Streams

[43] http://stackoverflow.com/questions/2753060/who-architected-designed-cs-iostreams-and-would-it-still-be-considered-well

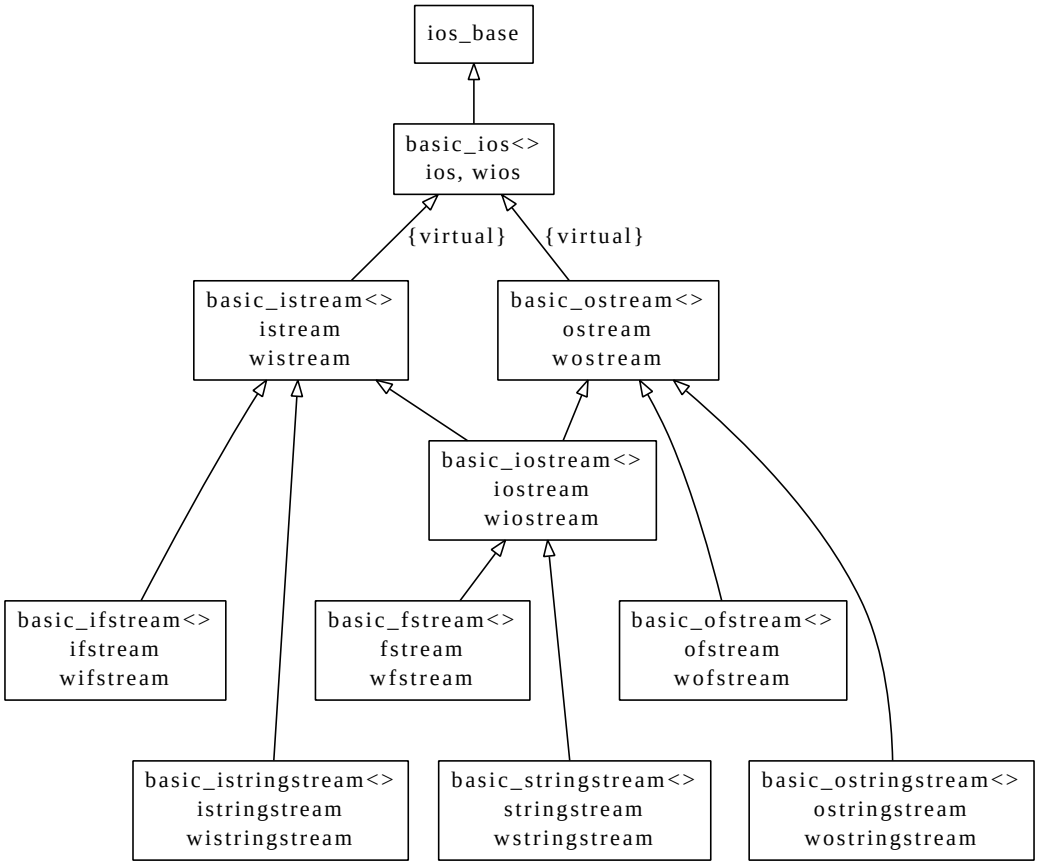

再进一步加深了解，发现还有一个平行的 `streambuf` 继承体系，`fstream` 和 `stringstream` 的不同之处主要就在于它们使用了不同的 `streambuf` 派生类型。

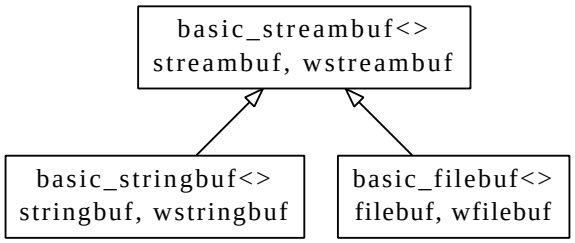

再把这两个继承体系画到一幅图里：

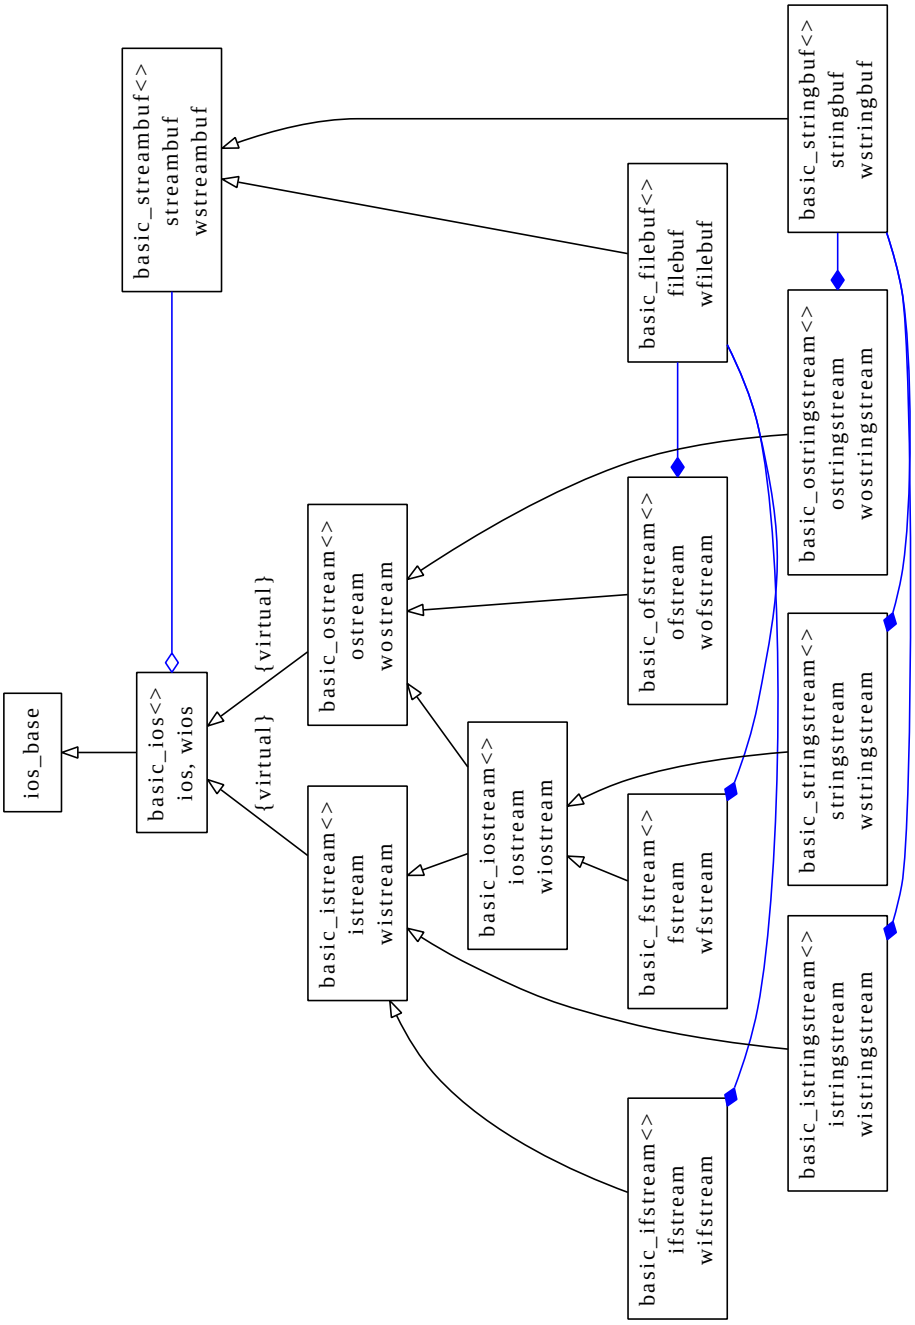

注意到 basic_ios 持有了 streambuf 的指针；而 fstreams 和 stringstreams 则

分别包含 `filebuf` 和 `stringbuf` 的对象。看上去有点像 Bridge 模式。

看了这样巴洛克的设计，有没有人还打算在自己的项目中想通过继承 iostream 来实现自己的 stream，以实现功能扩展么？

11.5.2 面向对象方面的设计缺陷

本节我们分析一下 iostream 的设计违反了哪些 OO 准则。

我们知道，面向对象中的 public 继承需要满足 Liskov 替换原则。（见《Effective C++ 第 3 版》[2, item 32]：确保你的 public 继承模塑出 is-a 关系。《C++ 编程规范》[4, item 37]：public 继承意味可替换性。**继承非为复用，乃为被复用。**）

在程序里需要用到 `ostream` 的地方（例如 `operator<<` ），我传入 `ofstream` 或 `ostringstream` 都应该能按预期工作，这就是 OO 继承强调的“可替换性”，派生类的对象可以替换基类对象，从而被客户端代码 `operator<<` 复用。

iostream 的继承体系多次违反了 Liskov 原则，这些地方继承的目的是为了复用基类的代码，下图中我把违规的继承关系用虚线标出。

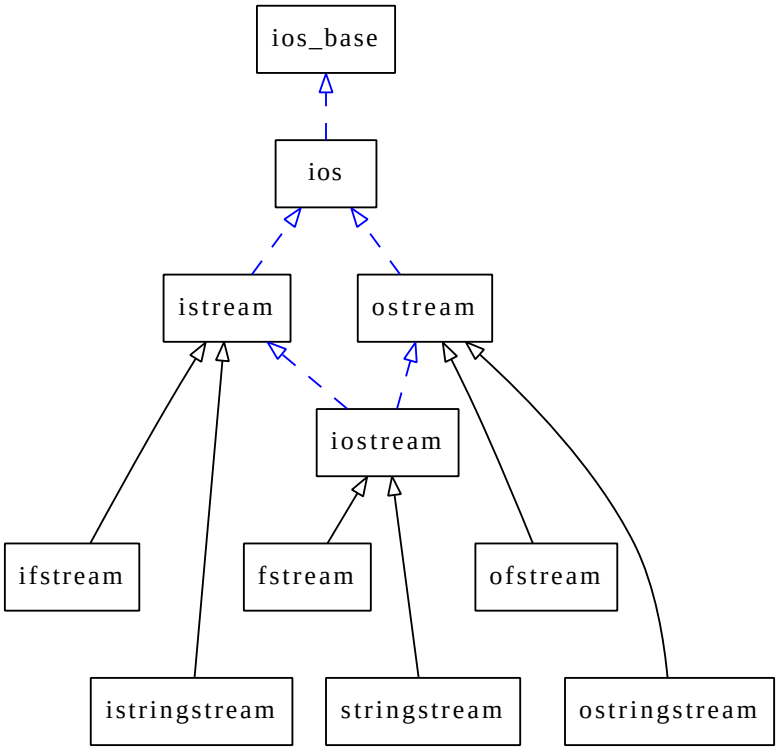

在现有的继承体系中，合理的有：

- ifstream **is-a** istream
- istringstream **is-a** istream
- ofstream **is-a** ostream
- ostringstream **is-a** ostream
- fstream **is-a** iostream
- stringstream **is-a** iostream

我认为不怎么合理的有：

- `ios` 继承 `ios_base`，有没有哪种情况下程序代码期待 `ios_base` 对象，但是客户可以传入一个 `ios` 对象替代之？如果没有，这里用 public 继承是不是违反 OO 原则？
- `istream` 继承 `ios`，有没有哪种情况下程序代码期待 `ios` 对象，但是客户可以传入一个 `istream` 对象替代之？如果没有，这里用 public 继承是不是违反 OO 原则？
- `ostream` 继承 `ios`，有没有哪种情况下程序代码期待 `ios` 对象，但是客户可以传入一个 `ostream` 对象替代之？如果没有，这里用 public 继承是不是违反 OO 原则？
- `iostream` 多重继承 `istream` 和 `ostream`。为什么 iostream 要同时继承两个 non-interface class？这是接口继承还是实现继承？是不是可以用组合 (composition) 来替代？（见《Effective C++ 第 3 版》[2, item 38]：通过组合模塑出 has-a 或“以某物实现”。《C++ 编程规范》[4, item 34]：尽可能以组合代替继承。）

用组合替换继承之后的体系：

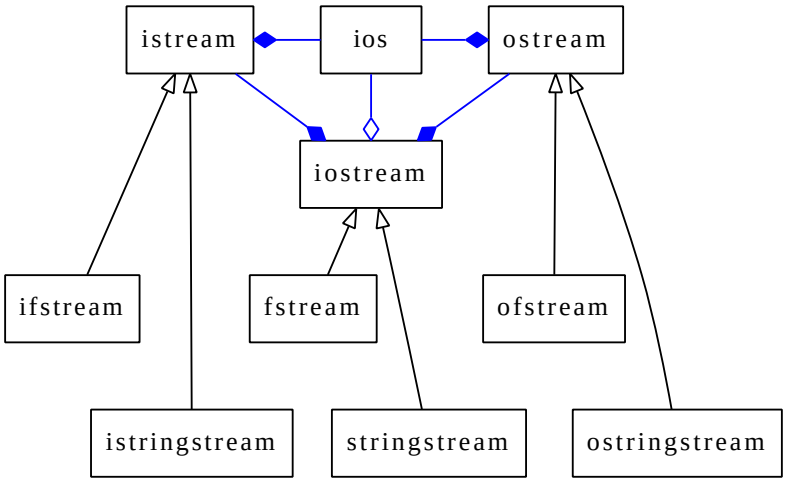

注意到在新的设计中，只有真正的 **is-a** 关系采用了 public 继承，其他均以组合来代替，组合关系以红线表示。新的设计没有用的虚拟继承或多重继承。

其中 iostream 的新实现值得一提，代码结构如下：

```
class istream;
class ostream;

class iostream
{
 public:
  istream& get_istream();
  ostream& get_ostream();
  virtual ~iostream();

  // ...
};
```

这样一来，在需要 `iostream` 对象表现得像 `istream` 的地方，调用 `get_istream()` 函数返回一个 `istream` 的引用；在需要 `iostream` 对象表现得像 `ostream` 的地方，调用 `get_ostream()` 函数返回一个 ostream 的引用。功能不受影响，而且代码更清晰，`istream`和 `ostream`也不必使用虚拟继承了。（我非常怀疑 `iostream` class 的真正价值，一个东西既可读又可写，说明是个 sophisticated IO 对象，为什么还用这么厚的 OO 封装？）

11.5.3 阳春的 locale

iostream 的故事还不止这些，它还包含一套阳春的 locale/facet 实现，这套实践中没人用的东西进一步增加了 iostream 的复杂度，而且不可避免地影响其性能。Nathan Myers 正是始作俑者[44]。

ostream 自身定义的针对整数和浮点数的 operator<< 成员函数的函数体是：

```
ostream& ostream::operator<<(int val) // 或 double val
{
  bool failed =
    use_facet<num_put>(getloc()).put(
      ostreambuf_iterator(*this), *this, fill(), val).failed();
  // ...
```

它会调用 num_put::put()，后者会去调用 num_put::do_put()，而 do_put() 是个虚函数，没办法 inline。iostream 在性能方面的不足恐怕部分来自于此。这个虚函数白白浪费了把 template 的实现放到头文件应得的好处，编译和运行速度都快不起来。这就是为什么我说 iostream 在泛型方面不讨好。

我没有深入挖掘其中的细节，感兴趣的同学可以移步观看 facet 的继承体系：http://gcc.gnu.org/onlinedocs/libstdc++/libstdc++-html-USERS-4.4/a00431.html

据此分析，我不认为以 iostream 为基础的上层程序库（比方说那些克服 iostream 格式化方面的缺点的库）有多大的实用价值。

11.5.4 臆造抽象

孟岩评价“iostream 最大的缺点是臆造抽象”，我非常赞同他老人家的观点。

这个评价同样适用于 Java 那一套叠床架屋的 InputStream、OutputStream、Reader、Writer 继承体系，.NET 也搞了这么一套繁文缛节。

乍看之下，用 input stream 表示一个可以“读”的数据流，用 output stream 表示一个可以“写”的数据流，屏蔽底层细节，面向接口编程，“符合面向对象原则”，似乎是一件美妙的事情。但是，真实的世界要残酷得多。

IO 是个极度复杂的东西，就拿最常见的 memory stream、file stream、socket stream 来说，它们之间的差异极大：

[44] http://www.cantrip.org/locale.html

- 是单向 IO 还是双向 IO。只读或者只写？还是既可读又可写？
- 顺序访问还是随机访问。可不可以 seek？可不可以退回 n 字节？
- 文本数据还是二进制数据。输入数据格式有误怎么办？如何编写健壮的处理输入的代码？
- 有无缓冲。write 500 字节是否能保证完全写入？有没有可能只写入了 300 字节？余下 200 字节怎么办？
- 是否阻塞。会不会返回 EWOULDBLOCK 错误？
- 有哪些出错的情况。这是最难的，memory stream 几乎不可能出错，file stream 和 socket stream 的出错情况完全不同。socket stream 可能遇到对方断开连接，file stream 可能遇到超出磁盘配额。

根据以上列举的初步分析，我不认为有办法设计一个公共的基类把各方面的情况都考虑周全。各种 IO 设施之间共性太小，差异太大，例外太多。如果硬要用面向对象来建模，基类要么太瘦（只放共性，这个基类包含的 interface functions 没多大用），要么太肥（把各种 IO 设施的特性都包含进来，这个基类包含的 interface functions 很多，但是不是每一个都能调用）。

一个基类设计得好，大家才愿意去继承它。比如 Runnable 是个很好的抽象，有不计其数的实现。InputStream/OutputStream 好歹也有若干个实现（见下图）。反观 `istream/ostream`，只有标准库提供的两套默认实现，在项目中极少有人会去继承并扩展它，是不是说明 `istream/ostream` 这一套抽象不怎么灵光呢？

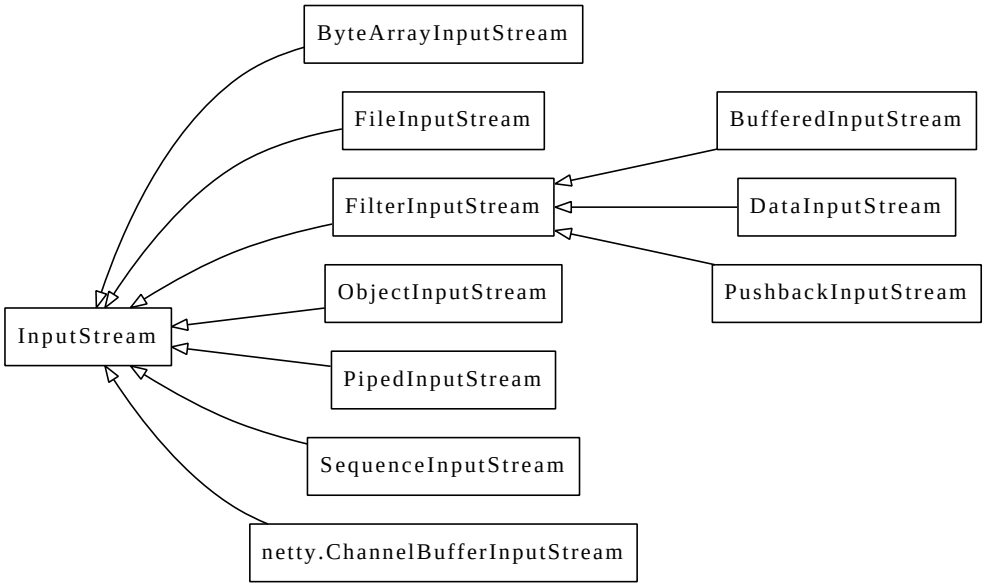

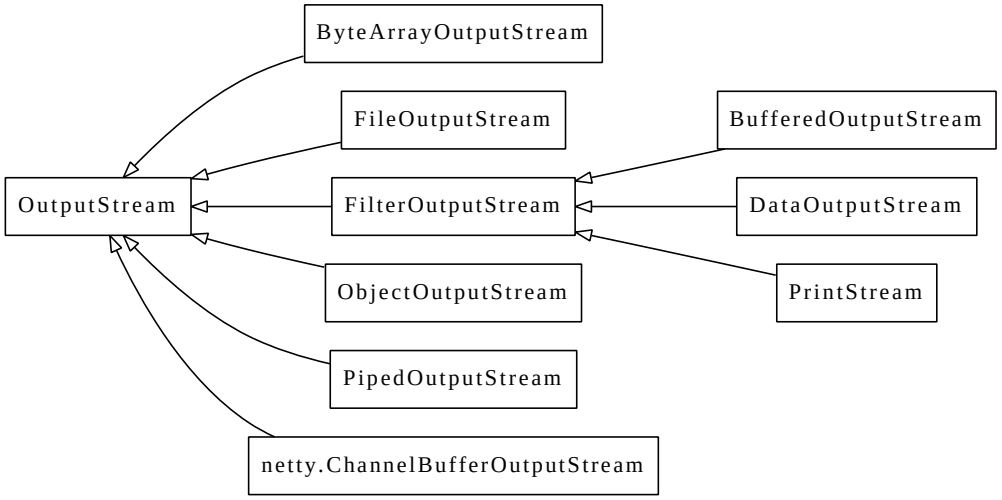

（当然，假如 Java 有 C++ 那样强大的 template 机制，上面这个继承体系能简化不少。）

若要在 C 语言里解决这个问题，通常的办法是用一个 int 表示 IO 对象（file 或 PIPE 或 socket），然后配以 `read()/write()/lseek()/fcntl()` 等一系列全局函数，

程序员自己搭配组合。这个做法我认为比面向对象的方案要简洁高效。

iostream 在性能方面没有比 stdio 高多少，在健壮性方面多半不如 stdio，在灵活性方面受制于本身的复杂设计而难以让使用者自行扩展。目前看起来只适合一些简单的要求不高的应用，但是又不得不为它的复杂设计付出运行时代价，总之其定位有点不上不下。

在实际的项目中，我们可以提炼出一些简单高效的 strip-down 版本，在获得便利性的同时避免付出不必要的代价。

11.6 一个 300 行的 memory buffer output stream

我认为以 `operator<<` 来输出数据非常适合 logging，因此写了一个简单的 `muduo::LogStream` class。代码不到 300 行，完全独立于 iostream，代码位于 https://github.com/chenshuo/recipes/blob/master/logging/。

这个 `LogStream` 做到了类型安全和类型可扩展，效率也较高。它不支持定制格式化、不支持 locale/facet、没有继承、buffer 也没有继承与虚函数、没有动态分配内存、buffer 大小固定。简单地说，适合 logging 以及简单的字符串转换。这基本上是 Bjarne 在 1984 年写的 `ostream` 的翻版。

LogStream 的接口定义是

```
class Buffer;

class LogStream : boost::noncopyable
{
  typedef LogStream self;
 public:

  self& operator<<(bool);

  self& operator<<(short);
  self& operator<<(unsigned short);
  self& operator<<(int);
  self& operator<<(unsigned int);
  self& operator<<(long);
  self& operator<<(unsigned long);
  self& operator<<(long long);
  self& operator<<(unsigned long long);

  self& operator<<(const void*);

  self& operator<<(float);
  self& operator<<(double);
```

```
    // self& operator<<(long double);

    self& operator<<(char);
    // self& operator<<(signed char);
    // self& operator<<(unsigned char);

    self& operator<<(const char*);
    self& operator<<(const string&);

    void append(const char* data, int len);
    const Buffer& buffer() const { return buffer_; }
    void resetBuffer() { buffer_.reset(); }

  private:
    Buffer buffer_;
  };
```

LogStream 本身不是线程安全的，它不适合做线程间共享对象。正确的使用方式是每条 log 消息构造一个 LogStream，用完就扔。LogStream 的成本极低，这么做不会有什么性能损失。

目前这个 logging 库还在开发之中，只完成了 LogStream 这一部分。将来可能改用动态分配的 buffer，这样方便在线程之间传递数据。

11.6.1 整数到字符串的高效转换

muduo::LogStream 的整数转换是自己写的，用的是 Matthew Wilson 的算法，见前面第 8 节“带符号整数的除法与余数”。这个算法比 stdio 和 iostream 都要快。

11.6.2 浮点数到字符串的高效转换

目前 muduo::LogStream 的浮点数格式化采用的是 snprintf()。所以从性能上与 stdio 持平，比 ostream 快一些。

浮点数到字符串的转换是个复杂的话题，这个领域 20 年以来没有什么进展（目前的实现大都基于 David M. Gay 在 1990 年的工作《Correctly Rounded Binary-Decimal and Decimal-Binary Conversions》，代码 http://netlib.org/fp/），直到 2010 年才有突破。

Florian Loitsch 发明了新的更快的算法 Grisu3，他的论文《Printing floating-point numbers quickly and accurately with integers》发表在 PLDI 2010，代码见

Google V8 引擎，还有这里 http://code.google.com/p/double-conversion/ 。有兴趣的同学可以阅读这篇博客 [45]。

将来 muduo::LogStream 可能会改用 Grisu3 算法实现浮点数转换。

11.6.3 性能对比

由于 muduo::LogStream 抛掉了很多负担，可以预见它的性能好于 ostringstream 和 stdio。我做了一个简单的性能测试，结果如下表。表中的数字是打印 1 000 000 次的用时，以毫秒为单位，越小越好。

64-bit code

	snprintf	ostringstream	LogStream
int	499	363	113
double	2315	3835	2338
int64_t	486	347	145
void*	419	330	47

32-bit code

	snprintf	ostringstream	LogStream
int	544	453	116
double	2241	4030	2267
int64_t	725	958	654
void*	690	425	65

从上表看出，ostreamstream 有时候比 snprintf() 快，有时候比它慢，muduo::LogStream 比它们两个都快得多（double 类型除外）。

11.6.4 泛型编程

其他程序库如何使用 LogStream 作为输出呢？办法很简单，用模板。

前面我们定义了 Date class 针对 std::ostream 的 operator<<，只要稍作修改就能同时适用于 std::ostream 和 LogStream。而且 Date 的头文件不再需要 include <ostream>，降低了耦合。

[45] http://www.serpentine.com/blog/2011/06/29/here-be-dragons-advances-in-problems-you-didnt-even-know-you-had/

```
 // 不必包含 LogStream 或 ostream 头文件
 class Date
 {
  public:
   Date(int year, int month, int day)
     : year_(year), month_(month), day_(day)
   {
   }

-  void writeTo(std::ostream& os) const
+  template<typename OStream>
+  void writeTo(OStream& os) const
   {
     char buf[32];
     snprintf(buf, sizeof buf, "%d-%02d-%02d", year_, month_, day_);
     os << buf;
   }

  private:
   int year_, month_, day_;
 };

-std::ostream& operator<<(std::ostream& os, const Date& date)
+template<typename OStream>
+OStream& operator<<(OStream& os, const Date& date)
 {
   date.writeTo(os);
   return os;
 }
```

11.6.5 格式化

muduo::LogStream 本身不支持格式化，不过我们很容易为它做扩展，定义一个简单的 Fmt class 就行，而且不影响 stream 的状态。

```
class Fmt : boost::noncopyable
{
 public:
  template<typename T>
  Fmt(const char* fmt, T val)
  {
    BOOST_STATIC_ASSERT(boost::is_arithmetic<T>::value == true);
    length_ = snprintf(buf_, sizeof buf_, fmt, val);
  }

  const char* data() const { return buf_; }
  int length() const { return length_; }

 private:
  char buf_[32];
```

```
  int length_;
};

inline LogStream& operator<<(LogStream& os, const Fmt& fmt)
{
  os.append(fmt.data(), fmt.length());
  return s;
}
```

使用方法

```
LogStream os;
double x = 19.82;
int y = 43;
os << Fmt("%8.3f", x) << Fmt("%4d", y);
```

11.7 现实的 C++ 程序如何做文件 IO

举三个例子，Google Protobuf Compiler、Google leveldb、Kyoto Cabinet。

11.7.1 Google Protobuf Compiler

Google Protobuf 是一种高效的网络传输格式，它用一种协议描述语言来定义消息格式，并且自动生成序列化代码。Protobuf Compiler 是这种“协议描述语言”的编译器，它读入协议文件 .proto，编译生成 C++、Java、Python 代码。proto 文件是个文本文件，然而 Protobuf Compiler 并没有使用 ifstream 来读取它，而是使用了自己的 FileInputStream 来读取文件。

大致代码流程如下：

1. ZeroCopyInputStream [46] 是一个抽象基类
2. FileInputStream [47] 继承并实现了 ZeroCopyInputStream
3. Tokenizer [48] 是词法分析器，它把 proto 文件分解为一个个字元 (token)。Tokenizer 的构造函数以 ZeroCopyInputStream 为参数，从该 stream 读入文本。

[46] http://code.google.com/p/protobuf/source/browse/trunk/src/google/protobuf/io/zero_copy_stream.h#122

[47] http://code.google.com/p/protobuf/source/browse/trunk/src/google/protobuf/io/zero_copy_stream_impl.h#55

[48] http://code.google.com/p/protobuf/source/browse/trunk/src/google/protobuf/io/tokenizer.h#75

4. Parser[49] 是语法分析器，它把 proto 文件解析为语法树，以 FileDescriptorProto 表示。Parser 的构造函数以 Tokenizer 为参数，从它读入字元。

由此可见，即便是读取文本文件，C++ 程序也不一定要用 ifstream。

11.7.2 Google leveldb

Google leveldb 是一个高效的持久化 key-value db。[50] 它定义了三个精简的 interface 用于文件输入输出：

- SequentialFile
- RandomAccessFile
- WritableFile

接口函数如下

```
struct Slice {
  const char* data_;
  size_t size_;
};

// A file abstraction for reading sequentially through a file
class SequentialFile {
 public:
  SequentialFile() { }
  virtual ~SequentialFile();

  virtual Status Read(size_t n, Slice* result, char* scratch) = 0;
  virtual Status Skip(uint64_t n) = 0;
};

// A file abstraction for randomly reading the contents of a file.
class RandomAccessFile {
 public:
  RandomAccessFile() { }
  virtual ~RandomAccessFile();

  virtual Status Read(uint64_t offset, size_t n, Slice* result,
                      char* scratch) const = 0;
};

// A file abstraction for sequential writing.  The implementation
```

[49] http://code.google.com/p/protobuf/source/browse/trunk/src/google/protobuf/compiler/parser.h#59
[50] http://code.google.com/p/leveldb

```
// must provide buffering since callers may append small fragments
// at a time to the file.
class WritableFile {
 public:
  WritableFile() { }
  virtual ~WritableFile();

  virtual Status Append(const Slice& data) = 0;
  virtual Status Close() = 0;
  virtual Status Flush() = 0;
  virtual Status Sync() = 0;
};
```

leveldb 明确区分 input 和 output，进一步它又把 input 分为 sequential 和 random access，然后提炼出了三个简单的接口，每个接口只有屈指可数的几个函数。这几个接口在各个平台下的实现也非常简单明了 [51] [52]，一看就懂。

注意这三个接口使用了虚函数，我认为这是正当的，因为一次 IO 往往伴随着 context switch，虚函数的开销比起 context switch 来可以忽略不计。相反，iostream 每次 `operator<<()` 就调用虚函数，似乎不太明智。

11.7.3 Kyoto Cabinet

Kyoto Cabinet 也是一个 key-value db，是前几年流行的 Tokyo Cabinet 的升级版。它采用了与 leveldb 不同的文件抽象。

KC 定义了一个 File class，同时包含了读写操作，这是个 fat interface。[53]

在具体实现方面，它没有使用虚函数，而是采用 `#ifdef` 来区分不同的平台 [54]，等于把两份独立的代码写到了同一个文件里边。

相比之下，Google leveldb 的做法更高明一些。

11.8 小结

在 C++ 项目里边自己写个 File class，把项目用到的文件 IO 功能简单封装一下 (以 RAII 手法封装 `FILE*` 或者 file descriptor 都可以，视情况而定)，通常就能满足

[51] http://code.google.com/p/leveldb/source/browse/trunk/util/env_posix.cc#35
[52] http://code.google.com/p/leveldb/source/browse/trunk/util/env_chromium.cc#176
[53] http://fallabs.com/kyotocabinet/api/classkyotocabinet_1_1File.html
[54] http://code.google.com/p/read-taobao-code/source/browse/trunk/tair/src/storage/kdb/kyotocabinet/kcfile.cc

需要。记得把拷贝构造和赋值操作符禁用，在析构函数里释放资源，避免泄露内部的 handle，这样就能自动避免很多 C 语言文件操作的常见错误。

如果要用 stream 方式做 logging，可以抛开繁重的 iostream 自己写一个简单的 `LogStream`，重载几个 `operator<<` 操作符，用起来一样方便；而且可以用 stack buffer，轻松做到线程安全与高效。

12 值语义与数据抽象

本文是第11节《iostream 的用途与局限》的后续，在11.3“iostream 与标准库其他组件的交互”这一小节，我简单地提到 iostream 的对象和 C++ 标准库中的其他对象（主要是容器和 string）具有不同的语义，主要体现在 iostream 不能拷贝或赋值。今天全面谈一谈我对这个问题的理解。

本文的“对象”定义较为宽泛，a region of memory that has a type，在这个定义下，int、double、bool 变量都是对象。

12.1 什么是值语义

值语义 (value sematics) 指的是对象的拷贝与原对象无关，就像拷贝 int 一样。C++ 的内置类型 (bool/int/double/char) 都是值语义，标准库里的 complex<> 、pair<>、vector<>、map<>、string 等等类型也都是值语意，拷贝之后就与原对象脱离关系。Java 语言的 primitive types 也是值语义。

与值语义对应的是“对象语义/object sematics”，或者叫做引用语义 (reference sematics)，由于“引用”一词在 C++ 里有特殊含义，所以我在本文中使用“对象语义”这个术语。对象语义指的是面向对象意义下的对象，对象拷贝是禁止的。例如 muduo 里的 Thread 是对象语义，拷贝 Thread 是无意义的，也是被禁止的：因为 Thread 代表线程，拷贝一个 Thread 对象并不能让系统增加一个一模一样的线程。

同样的道理，拷贝一个 Employee 对象是没有意义的，一个雇员不会变成两个雇员，他也不会领两份薪水。拷贝 TcpConnection 对象也没有意义，系统里边只有一个 TCP 连接，拷贝 TcpConnection 对象不会让我们拥有两个连接。Printer 也是不能拷贝的，系统只连接了一个打印机，拷贝 Printer 并不能凭空增加打印机。此总总，面向对象意义下的“对象”是 non-copyable。

Java 里边的 class 对象都是对象语义/引用语义。

```
ArrayList<Integer> a = new ArrayList<Integer>();
ArrayList<Integer> b = a;
```

那么 a 和 b 指向的是同一个 ArrayList 对象，修改 a 同时也会影响 b。

值语义与 immutable 无关。Java 有 value object 一说，按 (PoEAA 486) 的定义，它实际上是 immutable object，例如 String、Integer、BigInteger、joda.time.DateTime 等等（因为 Java 没有办法实现真正的值语义 class，只好用 immutable object 来模拟）。尽管 immutable object 有其自身的用处，但不是本文的主题。muduo 中的 Date、Timestamp 也都是 immutable 的。

C++ 中的值语义对象也可以是 mutable，比如 complex<>、pair<>、vector<>、map<>、string 都是可以修改的。muduo 的 InetAddress 和 Buffer 都具有值语义，它们都是可以修改的。

值语义的对象不一定是 POD，例如 string 就不是 POD，但它是值语义的。

值语义的对象不一定小，例如 vector<int> 的元素可多可少，但它始终是值语义的。当然，很多值语义的对象都是小的，例如 complex<>、muduo::Date、muduo::Timestamp。

12.2 值语义与生命期

值语义的一个巨大好处是生命期管理很简单，就跟 int 一样——你不需要操心 int 的生命期。值语义的对象要么是 stack object，或者直接作为其他 object 的成员，因此我们不用担心它的生命期（一个函数使用自己 stack 上的对象，一个成员函数使用自己的数据成员对象）。相反，对象语义的 object 由于不能拷贝，我们只能通过指针或引用来使用它。

一旦使用指针和引用来操作对象，那么就要担心所指的对象是否已被释放，这一度是 C++ 程序 bug 的一大来源。此外，由于 C++ 只能通过指针或引用来获得多态性，那么在 C++ 里从事基于继承和多态的面向对象编程有其本质的困难——资源管理。

考虑一个简单的对象建模——家长与子女：a Parent has a Child, a Child knows his/her Parent。在 Java 里边很好写，不用担心内存泄漏，也不用担心空悬指针：

```
public class Parent
{
    private Child myChild;
```

```
}

public class Child
{
    private Parent myParent;
}
```

只要正确初始化 myChild 和 myParent，那么 Java 程序员就不用担心出现访问错误。一个 handle 是否有效，只需要判断其是否 non null。

在 C++ 里边就要为资源管理费一番脑筋：Parent 和 Child 都代表的是真人，肯定是不能拷贝的，因此具有对象语义。Parent 是直接持有 Child 吗？抑或 Parent 和 Child 通过指针互指？Child 的生命期由 Parent 控制吗？如果还有 ParentClub 和 School 两个 class，分别代表家长俱乐部和学校：ParentClub has many Parent(s)，School has many Child(ren)，那么如何保证它们始终持有有效的 Parent 对象和 Child 对象？何时才能安全地释放 Parent 和 Child ？

直接但是易错的写法：

```
class Child;

class Parent : boost::noncopyable
{
 private:
  Child* myChild;
};

class Child : boost::noncopyable
{
 private:
  Parent* myParent;
};
```

如果直接使用指针作为成员，那么如何确保指针的有效性？如何防止出现空悬指针？Child 和 Parent 由谁负责释放？在释放某个 Parent 对象的时候，如何确保程序中没有指向它的指针？在释放某个 Child 对象的时候，如何确保程序中没有指向它的指针？

这一系列问题一度是 C++ 面向对象编程头疼的问题，不过现在有了 smart pointer，我们可以借助 smart pointer 把对象语义转换为值语义[55]，从而轻松解决对象生命期：让 Parent 持有 Child 的 smart pointer，同时让 Child 持有 Parent 的 smart pointer，这样始终引用对方的时候就不用担心出现空悬指针。当然，其中一个

[55] 即像持有 int 一样持有对象（的智能指针）

smart pointer 应该是 weak reference，否则会出现循环引用，导致内存泄漏。到底哪一个是 weak reference，则取决于具体应用场景。

如果 Parent 拥有 Child，Child 的生命期由其 Parent 控制，Child 的生命期小于 Parent，那么代码就比较简单：

```
class Parent;
class Child : boost::noncopyable
{
 public:
  explicit Child(Parent* myParent_)
    : myParent(myParent_)
  {
  }

 private:
  Parent* myParent;
};

class Parent : boost::noncopyable
{
 public:
  Parent()
    : myChild(new Child(this))
  {
  }

 private:
  boost::scoped_ptr<Child> myChild;
};
```

在上面这个设计中，Child 的指针不能泄露给外界，否则仍然有可能出现空悬指针。

如果 Parent 与 Child 的生命期相互独立，就要麻烦一些：

```
class Parent;
typedef boost::shared_ptr<Parent> ParentPtr;

class Child : boost::noncopyable
{
 public:
  explicit Child(const ParentPtr& myParent_)
    : myParent(myParent_)
  {
  }

 private:
  boost::weak_ptr<Parent> myParent;
};
typedef boost::shared_ptr<Child> ChildPtr;
```

```
class Parent : public boost::enable_shared_from_this<Parent>,
               private boost::noncopyable
{
 public:
  Parent()
  {
  }

  void addChild()
  {
    myChild.reset(new Child(shared_from_this()));
  }

 private:
  ChildPtr myChild;
};

int main()
{
  ParentPtr p(new Parent);
  p->addChild();
}
```

上面这个 shared_ptr+weak_ptr 的做法似乎有点小题大做。

考虑一个稍微复杂一点的对象模型：a Child has parents: mom and dad; a Parent has one or more Child(ren); a Parent knows his/her spouser. 这个对象模型用 Java 表述一点都不复杂，垃圾收集会帮我们搞定对象生命期。

```
public class Parent
{
    private Parent mySpouser;
    private ArrayList<Child> myChildren;
}

public class Child
{
    private Parent myMom;
    private Parent myDad;
}
```

如果用 C++ 来实现，如何才能避免出现空悬指针，同时避免出现内存泄漏呢？借助 shared_ptr 把裸指针转换为值语义，我们就不用担心这两个问题了：

```
class Parent;
typedef boost::shared_ptr<Parent> ParentPtr;

class Child : boost::noncopyable
```

```
{
 public:
  explicit Child(const ParentPtr& myMom_,
                 const ParentPtr& myDad_)
    : myMom(myMom_),
      myDad(myDad_)
  {
  }

 private:
  boost::weak_ptr<Parent> myMom;
  boost::weak_ptr<Parent> myDad;
};
typedef boost::shared_ptr<Child> ChildPtr;

class Parent : boost::noncopyable
{
 public:
  Parent()
  {
  }

  void setSpouser(const ParentPtr& spouser)
  {
    mySpouser = spouser;
  }

  void addChild(const ChildPtr& child)
  {
    myChildren.push_back(child);
  }

 private:
  boost::weak_ptr<Parent> mySpouser;
  std::vector<ChildPtr> myChildren;
};

int main()
{
  ParentPtr mom(new Parent);
  ParentPtr dad(new Parent);
  mom->setSpouser(dad);
  dad->setSpouser(mom);
  {
    ChildPtr child(new Child(mom, dad));
    mom->addChild(child);
    dad->addChild(child);
  }
  {
    ChildPtr child(new Child(mom, dad));
    mom->addChild(child);
    dad->addChild(child);
  }
```

```
}
```

如果不使用 smart pointer，用 C++ 做面向对象编程将会困难重重。

12.3 值语义与标准库

C++ 要求凡是能放入标准容器的类型必须具有值语义。准确地说：type 必须是 SGIAssignable concept 的 model。但是，由于 C++ 编译器会为 class 默认提供 copy constructor 和 assignment operator，因此除非明确禁止，否则 class 总是可以作为标准库的元素类型——尽管程序可以编译通过，但是隐藏了资源管理方面的 bug。

因此，在写一个 class 的时候，先让它继承 boost::noncopyable，几乎总是正确的。

在现代 C++ 中，一般不需要自己编写 copy constructor 或 assignment operator，因为只要每个数据成员都具有值语义的话，编译器自动生成的 member-wise copying&assigning 就能正常工作；如果以 smart ptr 为成员来持有其他对象，那么就能自动启用或禁用 copying&assigning。例外：编写 HashMap 这类底层库时还是需要自己实现 copy control。

12.4 值语义与 C++ 语言

C++ 的 class 本质上是值语义的，这才会出现 object slicing 这种语言独有的问题，也才会需要程序员注意 pass-by-value 和 pass-by-const-reference 的取舍。在其他面向对象编程语言中，这都不需要费脑筋。

值语义是 C++ 语言的三大约束之一，C++ 的设计初衷是让用户定义的类型 (class) 能像内置类型 (int) 一样工作，具有同等的地位。为此 C++ 做了以下设计（妥协）：

- class 的 layout 与 C struct 一样，没有额外的开销。定义一个“只包含一个 int 成员的 class”的对象开销和定义一个 int 一样。
- 甚至 class data member 都默认是 uninitialized，因为函数局部的 int 是 uninitialized。
- class 可以在 stack 上创建，也可以在 heap 上创建。因为 int 可以是 stack variable。

- class 的数组就是一个个 class 对象挨着，没有额外的 indirection。因为 int 数组就是这样。
- 编译器会为 class 默认生成 copy constructor 和 assignment operator。其他语言没有 copy constructor 一说，也不允许重载 assignment operator。C++ 的对象默认是可以拷贝的，这是一个尴尬的特性。
- 当 class type 传入函数时，默认是 make a copy （除非参数声明为 reference）。因为把 int 传入函数时是 make a copy。
- 当函数返回一个 class type 时，只能通过 make a copy（C++ 不得不定义 RVO 来解决性能问题）。因为函数返回 int 时是 make a copy。
- 以 class type 为成员时，数据成员是嵌入的。例如 pair<complex<double>, size_t> 的 layout 就是 complex<double> 挨着 size_t。

这些设计带来了性能上的好处，原因是 memory locality。比方说我们在 C++ 里定义 complex<double> class，array of complex<double>，vector<complex<double> >，它们的 layout 分别是：（re 和 im 分别是复数的实部和虚部。）

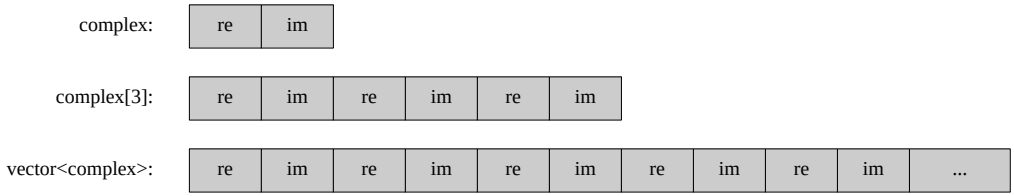

而如果我们在 Java 里干同样的事情，layout 大不一样，memory locality 也差很多：[56]

[56]图中的 handle 是 Java 的 reference，为了避免与 C++ 引用混淆，这里换个写法。

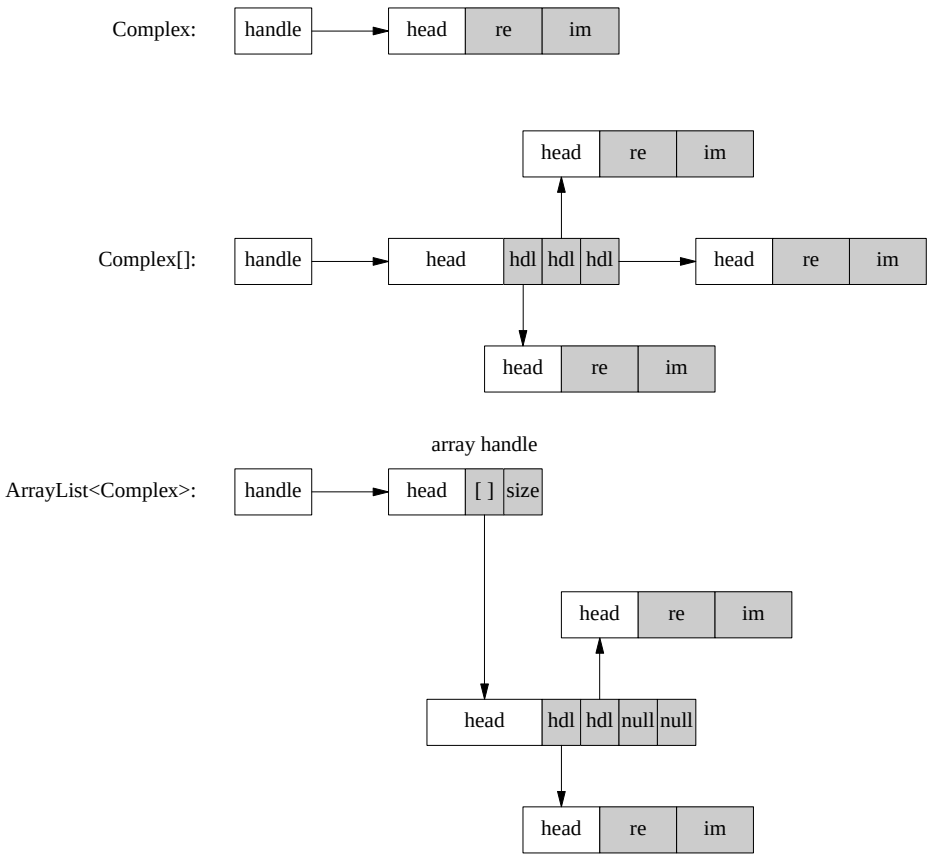

Java 里边每个 object 都有 header，在常见的 JVM 中有两个 word 的开销。对比 Java 和 C++，可见 C++ 的对象模型要紧凑得多。

12.5 什么是数据抽象

本节谈一谈与值语义紧密相关的数据抽象 (data abstraction)，解释为什么它是与面向对象并列的一种编程范式，为什么支持面向对象的编程语言不一定支持数据抽象。C++ 在最初的时候是以 data abstraction 为卖点，不过随着时间的流逝，现在似乎很多人只知 Object-Oriented，不知 data abstraction 了。C++ 的强大之处在于“抽象”不以性能损失为代价，下一篇文章我们将看到具体例子。

数据抽象 (data abstraction) 是与面向对象 (object-oriented) 并列的一种编程范式 (programming paradigm)。说“数据抽象”或许显得陌生，它的另外一个名字“抽象数据类型/abstract data type/ADT”想必如雷贯耳。

“支持数据抽象”一直是 C++ 语言的设计目标，Bjarne Stroustrup 在他的《The C++ Programming Language》第二版（1991 年出版）中写道 [2nd]：

The C++ programming language is designed to

- be a better C
- support data abstraction
- support object-oriented programming

这本书第三版（1997 年出版）[3rd] 增加了一条：

C++ is a general-purpose programming language with a bias towards systems programming that

- is a better C,
- supports data abstraction,
- supports object-oriented programming, and
- supports generic programming.

在 C++ 的早期文献 [57] 中中有一篇 Bjarne Stroustrup 在 1984 年写的《Data Abstraction in C++》[58]。在这个页面还能找到 Bjarne 写的关于 C++ 操作符重载和复数运算的文章，作为数据抽象的详解与范例。可见 C++ 早期是以数据抽象为卖点的，支持数据抽象是 C++ 相对于 C 的一大优势。

作为语言的设计者，Bjarne 把数据抽象作为 C++ 的四个子语言之一。这个观点不是普遍接受的，比如作为语言的使用者，Scott Meyers 在《Effective C++ 第三版》中把 C++ 分为四个子语言：C、Object-Oriented C++、Template C++、STL。在 Scott Meyers 的分类法中，就没有出现数据抽象，而是归入了 object-oriented C++。

[57] http://www.softwarepreservation.org/projects/c_plus_plus/index.html#cfront

[58] http://www.softwarepreservation.org/projects/c_plus_plus/cfront/release_-e/doc/DataAbstraction.pdf

那么到底什么是数据抽象? 简单的说，数据抽象是用来描述数据结构的。数据抽象就是 ADT。一个 ADT 主要表现为它支持的一些操作，比方说 stack.push、stack.pop，这些操作应该具有明确的时间和空间复杂度。另外，一个 ADT 可以隐藏其实现细节，比方说 stack 既可以用动态数组实现，又可以用链表实现。

按照这个定义，数据抽象和基于对象 (object-based) 很像，那么它们的区别在哪里？语义不同。ADT 通常是值语义，而 object-based 是对象语义。（这两种语义的定义见前一节《什么是值语义》12.1）。ADT class 是可以拷贝的，拷贝之后的 instance 与原 instance 脱离关系。

比方说

```
stack<int> a;
a.push(10);
stack<int> b = a;
b.pop();
```

这时候 a 里仍然有元素 10。

12.5.1 C++ 标准库中的数据抽象

C++ 标准库里 complex<>、pair<>、vector<>、list<>、map<>、set<>、string、stack、queue 都是数据抽象的例子。vector 是动态数组，它的主要操作有 push_back()、size()、begin()、end() 等等，这些操作不仅含义清晰，而且计算复杂度都是常数。类似的，list 是链表，map 是有序关联数组，set 是有序集合、stack 是 FILO 栈、queue 是 FIFO 队列。“动态数组”、“链表”、“有序集合”、“关联数组”、“栈”、“队列”都是定义明确（操作、复杂度）的抽象数据类型。

12.5.2 数据抽象与面向对象的区别

本文把 data abstraction、object-based、object-oriented 视为三个编程范式。这种细致的分类或许有助于理解区分它们之间的差别。

庸俗地讲，面向对象 (object-oriented) 有三大特征：封装、继承、多态。而基于对象 (object-based) 则只有封装，没有继承和多态，即只有具体类，没有抽象接口。它们两个都是对象语义。

面向对象真正核心的思想是消息传递 (messaging)，“封装继承多态”只是表象。这一点孟岩 [59] 和王益 [60] 都有精彩的论述，陈硕不再赘言。

数据抽象与它们两个的界限在于“语义”，数据抽象不是对象语义，而是值语义。比方说 muduo 里的 TcpConnection 和 Buffer 都是具体类，但前者是基于对象的 (object-based)，而后者是数据抽象。

类似的，muduo::Date、muduo::Timestamp 都是数据抽象。尽管这两个 classes 简单到只有一个 int/long 数据成员，但是它们各自定义了一套操作 (operation)，并隐藏了内部数据，从而让它从 data aggregation 变成了 data abstraction。

数据抽象是针对“数据”的，这意味着 ADT class 应该可以拷贝，只要把数据复制一份就行了。如果一个 class 代表了其他资源（文件、员工、打印机、账号），那么它就是 object-based 或 object-oriented，而不是数据抽象。

ADT class 可以作为 Object-based/object-oriented class 的成员，但反过来不成立，因为这样一来 ADS class 的拷贝就失去意义了。

12.6 数据抽象所需的语言设施

不是每个语言都支持数据抽象，下面简要列出“数据抽象”所需的语言设施。

支持数据聚合 数据聚合 data aggregation，或者 value aggregates。即定义 C-style struct，把有关数据放到同一个 struct 里。FORTRAN77 没有这个能力，FORTRAN77 无法实现 ADT。这种数据聚合 struct 是 ADT 的基础，struct List、struct HashTable 等能把链表和哈希表结构的数据放到一起，而不是用几个零散的变量来表示它。

全局函数与重载 例如我定义了 complex，那么我可以同时定义 complex sin(const complex& x); 和 complex exp(const complex& x); 等等全局函数来实现复数的三角函数和指数运算。sin 和 exp 不是 complex 的成员，而是全局函数 double sin(double) 和 double exp(double) 的重载。这样能让 double a = sin(b); 和 complex a = sin(b); 具有相同的代码形式，而不必写成 complex a = b.sin();。

C 语言可以定义全局函数，但是不能与已有的函数重名，也就没有重载。Java 没有全局函数，而且 Math class 是封闭的，并不能往其中添加 sin(Complex)。

[59] http://blog.csdn.net/myan/article/details/5928531
[60] http://cxwangyi.wordpress.com/2011/06/19/杂谈现代高级编程语言/

成员函数与 private 数据 数据也可以声明为 private，防止外界意外修改。不是每个 ADT 都适合把数据声明为 private，例如 complex、point、pair<> 这样的 ADT 使用 public data 更加合理。

要能够在 struct 里定义操作，而不是只能用全局函数来操作 struct。比方说 vector 有 push_back() 操作，push_back 是 vector 的一部分，它必须直接修改 vector 的 private data members，因此无法定义为全局函数。

这两点其实就是定义 class，现在的语言都能直接支持，C 语言除外。

拷贝控制 (copy control) copy control 是拷贝 stack a; stack b = a; 和赋值 stack b; b = a; 的合称。

当拷贝一个 ADT 时会发生什么？比方说拷贝一个 stack，是不是应该把它的每个元素按值拷贝到新 stack？

如果语言支持显示控制对象的生命期（比方说 C++ 的确定性析构），而 ADT 用到了动态分配的内存，那么 copy control 更为重要，不然如何防止访问已经失效的对象？

由于 C++ class 是值语义，copy control 是实现深拷贝的必要手段。而且 ADT 用到的资源只涉及动态分配的内存，所以深拷贝是可行的。相反，object-based 编程风格中的 class 往往代表某样真实的事物（Employee、Account、File 等等），深拷贝无意义。

C 语言没有 copy control，也没有办法防止拷贝，一切要靠程序员自己小心在意。FILE* 可以随意拷贝，但是只要关闭其中一个 copy，其他 copies 也都失效了，跟空悬指针一般。整个 C 语言对待资源（malloc 得到的内存，open() 打开的文件，socket() 打开的连接）都是这样，用整数或指针来代表（即“句柄”）。而整数和指针类型的“句柄”是可以随意拷贝的，很容易就造成重复释放、遗漏释放、使用已经释放的资源等等常见错误。这方面 C++ 是一个显著的进步，boost::noncopyable 是 boost 里最值得推广的库。

操作符重载 如果要写动态数组，我们希望能像使用内置数组一样使用它，比如支持下标操作。C++ 可以重载 operator[] 来做到这一点。

如果要写复数，我们系统能像使用内置的 double 一样使用它，比如支持加减乘除。C++ 可以重载 operator+ 等操作符来做到这一点。

如果要写日期时间，我们希望它能直接用大于小于号来比较先后，用 == 来判断是否相等。C++ 可以重载 operator< 等操作符来做到这一点。

这要求语言能重载成员与全局操作符。操作符重载是 C++ 与生俱来的特性，1984 年的 CFront E 就支持操作符重载，并且提供了一个 complex class，这个 class 与目前标准库的 complex<> 在使用上无区别。

如果没有操作符重载，那么用户定义的 ADT 与内置类型用起来就不一样（想想有的语言要区分 == 和 equals，代码写起来实在很累赘）。Java 里有 BigInteger，但是 BigInteger 用起来和普通 int/long 大不相同：

```
// Java code

public static BigInteger mean(BigInteger x, BigInteger y) {
    BigInteger two = BigInteger.valueOf(2);
    return x.add(y).divide(two);
}

public static long mean(long x, long y) {
    return (x + y) / 2;
}
```

当然，操作符重载容易被滥用，因为这样显得很酷。我认为只在 ADT 表示一个“数值”的时候才适合重载加减乘除，其他情况下用具名函数为好，因此 muduo::Timestamp 只重载了关系操作符，没有重载加减操作符。另外一个理由见第3节《采用有利于版本管理的代码格式》。

效率无损 “抽象”不代表低效。在 C++ 中，提高抽象的层次并不会降低效率。不然的话，人们宁可在低层次上编程，而不愿使用更便利的抽象，数据抽象也就失去了市场。后面我们将看到一个具体的例子。

模板与泛型 如果我写了一个 int vector，那么我不想为 doule 和 string 再实现一遍同样的代码。我应该把 vector 写成 template，然后用不同的类型来具现化它，从而得到 vector<int>、vector<double>、vector<complex>、vector<string> 等等具体类型。

不是每个 ADT 都需要这种泛型能力，一个 Date class 就没必要让用户指定该用哪种类型的整数，int32_t 足够了。

根据上面的要求，不是每个面向对象语言都能原生支持数据抽象，也说明数据抽象不是面向对象的子集。

12.7 数据抽象的例子

下面我们看看数值模拟 N-body 问题的两个程序，前一个用 C 语言，后一个是 C++ 的。这个例子来自编程语言的性能对比网站 [61]。

两个程序使用了相同的算法。

C 语言版，完整代码见 [62]，下面是代码骨干。planet 保存与行星位置、速度、质量，位置和速度各有三个分量，程序模拟几大行星在三维空间中受引力支配的运动。

```
// C code

struct planet
{
  double x, y, z;
  double vx, vy, vz;
  double mass;
};

void advance(int nbodies, struct planet *bodies, double dt)
{
  for (int i = 0; i < nbodies; i++)
  {
    struct planet *p1 = &(bodies[i]);
    for (int j = i + 1; j < nbodies; j++)
    {
      struct planet *p2 = &(bodies[j]);
      double dx = p1->x - p2->x;
      double dy = p1->y - p2->y;
      double dz = p1->z - p2->z;
      double distance_squared = dx * dx + dy * dy + dz * dz;
      double distance = sqrt(distance_squared);
      double mag = dt / (distance * distance_squared);
      p1->vx -= dx * p2->mass * mag;
      p1->vy -= dy * p2->mass * mag;
      p1->vz -= dz * p2->mass * mag;
      p2->vx += dx * p1->mass * mag;
      p2->vy += dy * p1->mass * mag;
      p2->vz += dz * p1->mass * mag;
    }
  }
  for (int i = 0; i < nbodies; i++)
  {
    struct planet * p = &(bodies[i]);
    p->x += dt * p->vx;
    p->y += dt * p->vy;
    p->z += dt * p->vz;
  }
}
```

[61] http://shootout.alioth.debian.org/gp4/benchmark.php?test=nbody&lang=all
[62] https://gist.github.com/1158889#file_nbody.c

其中最核心的算法是 advance() 函数实现的数值积分，它根据各个星球之间的距离和引力，算出加速度，再修正速度，然后更新星球的位置。这个 naive 算法的复杂度是 O(N^2)。

C++ 数据抽象版，完整代码见 [63]，下面是代码骨架。

首先定义 Vector3 这个抽象，代表三维向量，它既可以是位置，有可以是速度。本处略去了 Vector3 的操作符重载，Vector3 支持常见的向量加减乘除运算。

然后定义 Planet 这个抽象，代表一个行星，它有两个 Vector3 成员：位置和速度。

需要说明的是，按照语义，Vector3 是数据抽象，而 Planet 是 object-based.

```
// C++ code
struct Vector3
{
  Vector3(double x, double y, double z)
    : x(x), y(y), z(z)
  {
  }

  double x;
  double y;
  double z;
};

struct Planet
{
  Planet(const Vector3& position, const Vector3& velocity, double mass)
    : position(position), velocity(velocity), mass(mass)
  {
  }

  Vector3 position;
  Vector3 velocity;
  const double mass;
};
```

相同功能的 advance() 代码简短得多，而且更容易验证其正确性。（想想如果把 C 语言版的 advance() 中的 vx、vy、vz、dx、dy、dz 写错位了，这种错误较难发现。）

```
// C++ code
void advance(int nbodies, Planet* bodies, double delta_time)
{
```

[63] https://gist.github.com/1158889#file_nbody.cc

```
    for (Planet* p1 = bodies; p1 != bodies + nbodies; ++p1)
    {
      for (Planet* p2 = p1 + 1; p2 != bodies + nbodies; ++p2)
      {
        Vector3 difference = p1->position - p2->position;
        double distance_squared = magnitude_squared(difference);
        double distance = std::sqrt(distance_squared);
        double magnitude = delta_time / (distance * distance_squared);
        p1->velocity -= difference * p2->mass * magnitude;
        p2->velocity += difference * p1->mass * magnitude;
      }
    }
    for (Planet* p = bodies; p != bodies + nbodies; ++p)
    {
      p->position += delta_time * p->velocity;
    }
  }
```

性能上，尽管 C++ 使用了更高层的抽象 Vector3，但它的性能和 C 语言一样快。看看 memory layout 就会明白：

C struct 的成员是连续存储的，struct 数组也是连续的。

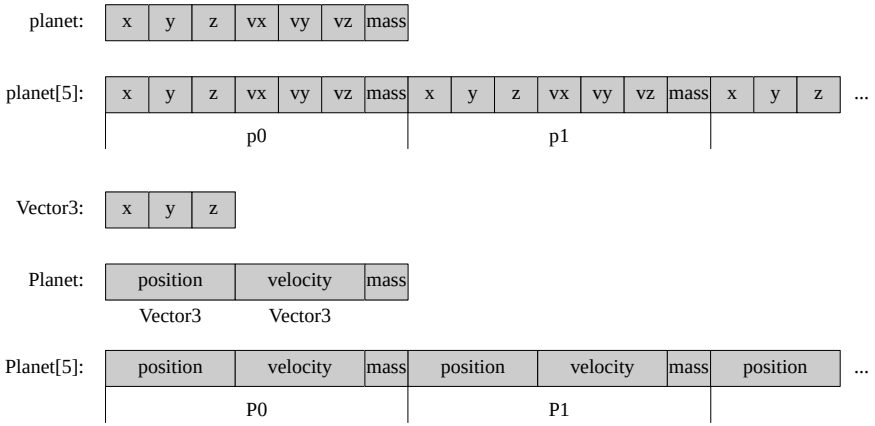

C++ 尽管定义了了 Vector3 这个抽象，它的内存布局并没有改变，Planet 的布局和 C planet 一模一样，Planet[] 的布局也和 C 数组一样。

另一方面，C++ 的 inline 函数在这里也起了巨大作用，我们可以放心地调用 Vector3::operator+=() 等操作符，编译器会生成和 C 一样高效的代码。

不是每个编程语言都能做到在提升抽象的时候不影响性能，来看看 Java 的内存布局。

如果我们用 class Vector3、class Planet、Planet[] 的方式写一个 Java 版的 N-body 程序，内存布局将会是：

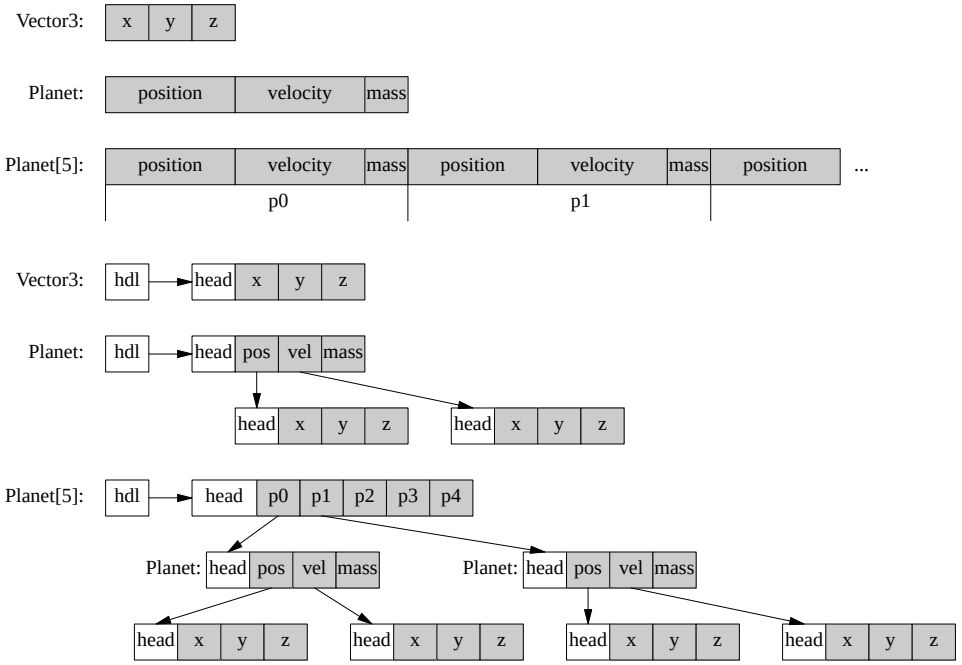

这样大大降低了 memory locality，有兴趣的读者可以对比 Java 和 C++ 的实现效率。

注：这里的 N-body 算法只为比较语言之间的性能与编程的便利性，真正科研中用到的 N-body 算法会使用更高级和底层的优化，复杂度是 O($N \log N$)，在大规模模拟时其运行速度也比本 naive 算法快得多。

12.7.1 更多的例子

- Date 与 Timestamp，这两个 class 的“数据”都是整数，各定义了一套操作，用于表达日期与时间这两个概念。
- BigInteger，它本身就是一个“数”。如果用 C++ 实现 BigInteger，那么阶乘函数写出来十分自然，下面第二个函数是 Java 语言的版本。

```
// C++ code
BigInteger factorial(int n)
{
    BigInteger result(1);
    for (int i = 1; i <= n; ++i) {
        result *= i;
```

```
    }
    return result;
}

// Java code
public static BigInteger factorial(int n) {
    BigInteger result = BigInteger.ONE;
    for (int i = 1; i <= n; ++i) {
        result = result.multiply(BigInteger.valueOf(i));
    }
    return result;
}
```

高精度运算库 gmp 有一套高质量的 C++ 封装 [64]

- 图形学中的三维齐次坐标 Vector4 和对应的 4x4 变换矩阵 Matrix4，例如 [65]
- 金融领域中经常成对出现的“买入价/卖出价”，可以封装为 BidOffer struct，这个 struct 的成员可以有 mid() “中间价”，spread() “买卖差价”，加减操作符，等等。

12.8 小结

数据抽象是 C++ 的重要抽象手段，适合封装“数据”，它的语义简单，容易使用。数据抽象能简化代码书写，减少偶然错误。

13 再探 std::string

Scott Meyers 在《Effective STL》[6] 第 15 条提到 std::string 有多种实现方式，归纳起来有三类，而每类又有多种变化。

1. 无特殊处理 (eager copy)，采用类似 std::vector 的数据结构。现在很少有实现采用这种方式。
2. Copy-on-Write (COW)。g++ 的 std::string 一直采用这种方式实现 [66]。
3. 短字符串优化 (SSO)，利用 string 对象本身的空间来存储短字符串。Visual C++ 用的是这种实现方式。

[64] http://gmplib.org/manual/C_002b_002b-Interface-General.html#C_002b_002b-Interface-General
[65] http://www.ogre3d.org/docs/api/html/classOgre_1_1Matrix4.html
[66] libstdc++ 的 std::string 是 Nathan Myers 的手笔。

下表总结了我知道的各个库的 string 实现方式和 string 对象分别在 32-bit/64-bit x86 系统中的大小。

库	32-bit	64-bit	实现方式
g++ std::string	4	8	COW
__gnu_cxx::__sso_string	24	32	SSO
__gnu_cxx::__rc_string	4	8	COW
clang libc++	12	24	SSO
SGI STL	12	24	eager copy
STLPort	24	48	SSO
Apache libstdcxx	4	8	COW
Visual C++ 2010	28/32	40/48	SSO

Visual C++ 的 std::string 的大小跟编译模式有关，表中小的那个数字是 release 编译，大的是 debug 编译。因此 debug 库和 release 库不能混用。除此之外，其他库的 string 大小是固定的。

以下分别介绍这几种实现方式的代码骨架和数据结构示意图，无论哪种实现方式都要保存三个数据：1. 字符串本身 (char*)，2. 字符串的长度 (size)，3. 字符串的容量 (capacity)。

13.1 直接拷贝 (eager copy)

类似 std::vector 的“三指针”结构。代码骨架 (省略模板)：

eager copy string 1

```
// http://www.sgi.com/tech/stl/string

// Class invariants:
// (1) [start, finish) is a valid range.
// (2) Each iterator in [start, finish) points to a valid object
//     of type value_type.
// (3) *finish is a valid object of type value_type; in particular,
//     it is value_type().
// (4) [finish + 1, end_of_storage) is a valid range.
// (5) Each iterator in [finish + 1, end_of_storage) points to
//     unininitialized memory.

// Note one important consequence: a string of length n must manage
// a block of memory whose size is at least n + 1.

class string
{
```

```
 public:
  const_pointer data() const  { return start; }
  iterator begin()            { return start; }
  iterator end()              { return finish; }
  size_type size() const      { return finish - start; }
  size_type capacity() const  { return end_of_storage - start; }

 private:
  char* start;
  char* finish;
  char* end_of_storage;
};
```

eager copy string 1

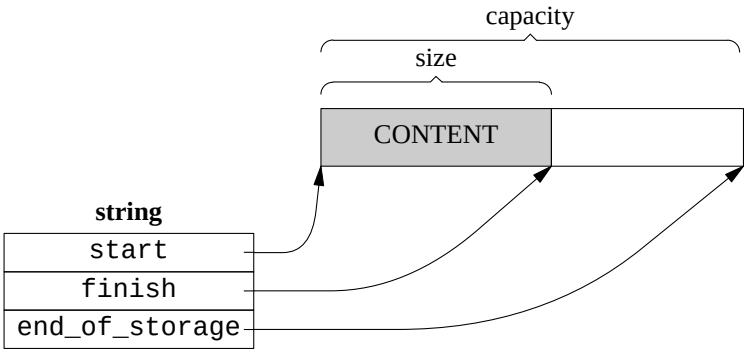

对象的大小是 3 个指针，在 32-bit 中是 12 字节，在 64-bit 中是 24 字节。

Eager copy string 的另一种实现方式是把后两个成员变量替换成整数，表示字符串的长度和容量，即：

eager copy string 2

```
class string
{
 public:
  const_pointer data() const  { return start; }
  iterator begin()            { return start; }
  iterator end()              { return start + size_; }
  size_type size() const      { return size_; }
  size_type capacity() const  { return capacity_; }

 private:
  char* start;
  size_t size_;
  size_t capacity_;
};
```

eager copy string 2

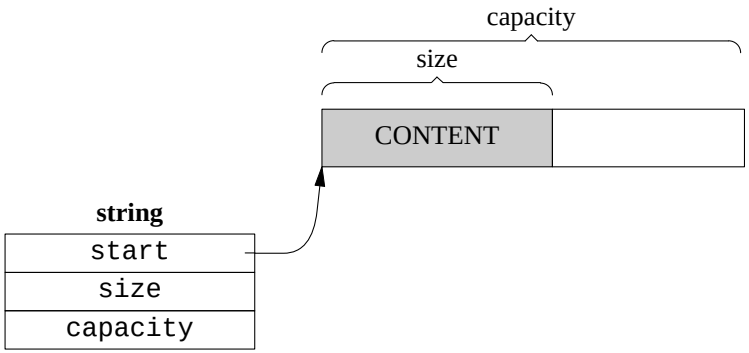

这种做法并没有多大的改变，因为 size_t 和 char* 是一样大的。但是，我们通常用不到单个几百兆字节的字符串 [67]，那么可以再改变一下长度和容量的类型（从 64-bit 整数改成 32-bit 整数），这样在 64-bit 下可以减小对象的大小。

eager copy string 3

```
class string
{
 private:
  char* start;
  uint32_t size;
  uint32_t capacity;
};
```

eager copy string 3

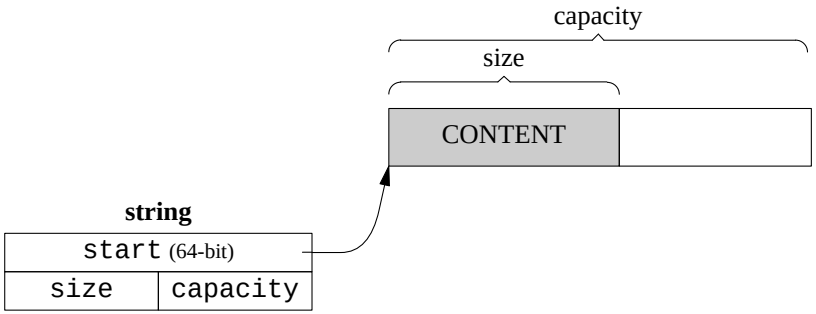

新的 string 结构在 64-bit 中是 16 字节，比原来的 24 字节小了一些。

13.2 Copy-on-Write

string 对象里只放一个指针。值得一提的是 COW 对多线程不友好，Andrei Alexandrescu 提倡在多核时代应该改用 eager copy string。

[67] 如果真的用到了，就继续使用 std::string 或 std::vector<char> 好了。

copy-on-write string

```
class cow_string  // libstdc++-v3
{
  struct Rep
  {
    size_t size;
    size_t capacity;
    size_t refcount;
    char*  data[1]; // variable length
  };
  char* start;
};
```

copy-on-write string

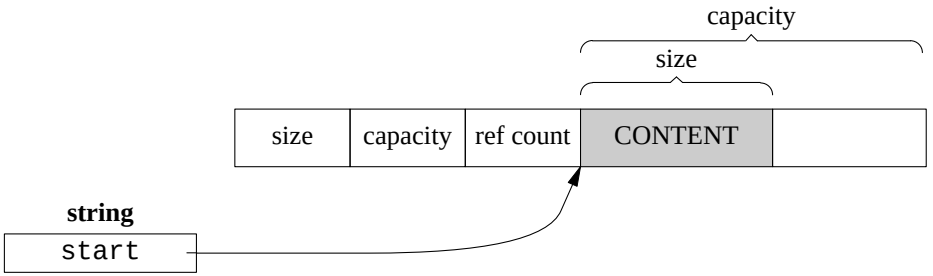

这种数据结构没啥好说的，在 64-bit 中似乎也没有优化空间。另外 COW 的操作复杂度不一定符合直觉，它拷贝字符串是 $O(1)$ 时间，但是拷贝之后的第一次 operator[] 有可能是 $O(N)$ 时间。[68]

13.3 短字符串优化 (SSO)

string 对象比前面两个都大，因为有本地缓冲区 (local buffer)。

short-string-optimized string

```
class sso_string  // __gnu_ext::__sso_string
{
  char* start;
  size_t size;

  static const int kLocalSize = 15;

  union
  {
    char buffer[kLocalSize+1];
    size_t capacity;
  } data;
};
```

short-string-optimized string

[68] http://coolshell.cn/articles/1443.html

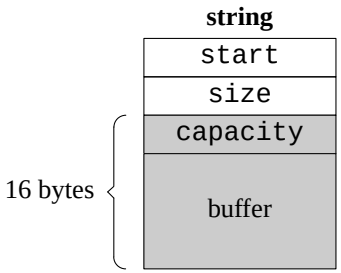

如果字符串比较短（通常的阈值是 15 字节），那么直接存放在对象的 buffer 里。start 指向 data.buffer。

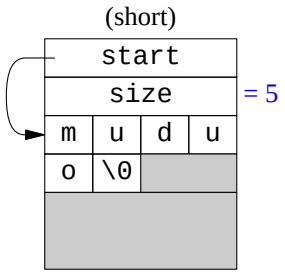

如果字符串超过 15 字节，那么就变成第117页的 eager copy 2 那种结构，start 指向堆上分配的空间。

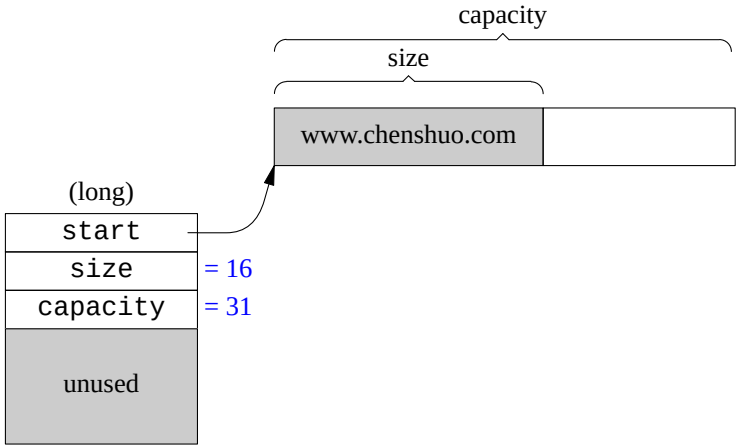

短字符串优化的实现方式不止一种，主要区别是把那三个指针/整数中的哪一个与本地缓冲重合。例如《Effective STL》[6] 第 15 条展现的“实现 D”是将 buffer 与 start 指针重合，这正是 Visual C++ 的做法。而 STLPort 的 string 是将 buffer 与 end_of_storage 指针重合。

SSO string 在 64-bit 中有一个小小的优化空间：如果允许字符串 max_size() 不大于 4G 的话，我们可以用 32-bit 整数来表示长度和容量，这样同样是 32 字节的 string 对象，local buffer 可以增大至 19 字节。

short-string-optimized string 2

```
class sso_string  // optimized for 64-bit
{
  char* start;
  uint32_t size;

  static const int kLocalSize = sizeof(void*) == 8 ? 19 : 15;

  union
  {
    char buffer[kLocalSize+1];
    uint32_t capacity;
  } data;
};
```

short-string-optimized string 2

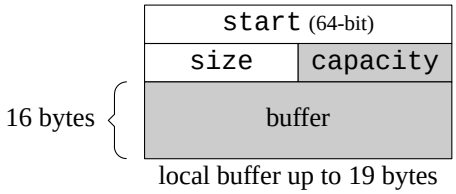

llvm/clang/libc++ 采用了与众不同的 SSO 实现，空间利用率最高，local buffer 几乎与三个指针/整数完全重合，在 64-bit 上对象大小是 24 字节，本地缓冲区可达 22 字节。

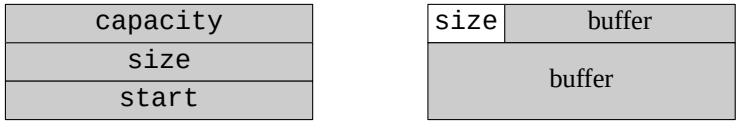

它用一个 bit 来区分是长字符还是短字符，然后用位操作和掩码 (mask) 来取重叠部分的数据，因此实现是 SSO 里最复杂的 [69]。

[69] http://llvm.org/viewvc/llvm-project/libcxx/trunk/include/string?view=markup

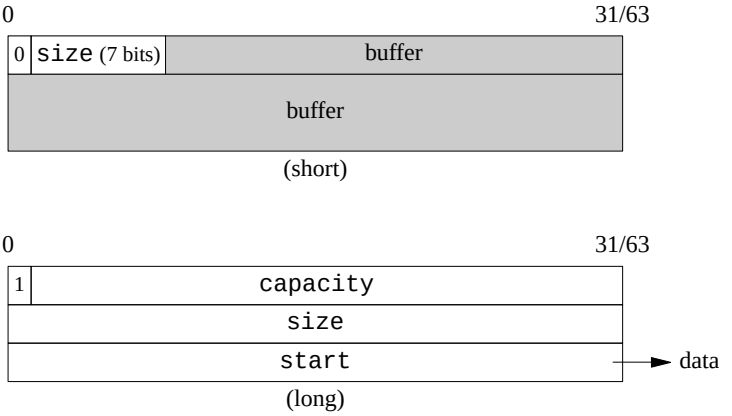

Andrei Alexandrescu 建议[8] 针对不同的应用负载选用不同的 string，对于短字符串，用 SSO string；对于中等长度的字符串，用 eager copy；对于长字符串，用 COW。具体分界点需要靠 profiling 来确定，选用合适的字符串可能提高 10% 的整体性能。

从实现的复杂度上看，eager copy 是最简单的，SSO 稍微复杂一些，COW 最难。性能也各有千秋，见 Petr Ovtchenkov 写的《Comparison of Strings Implementations in C++ language》[70]。

我准备自己写一个 non-standard [71] non-template [72] 的 string 库 [73]作为练手，计划采用 eager copy 3 和 sso 2 的数据结构。

注脚：C++03/98 标准没有规定 string 中的字符是连续存储的，但是《Generic Programming and the STL》的作者 Matthew Austern 指出 [74]：现在所有的 std::string 实现都是连续存储的，因此建议在新标准中明确规定下来 [75]。

[70] http://complement.sourceforge.net/compare.pdf

[71] C++ 标准库 string 有很多设计缺陷，见 Herb Sutter 的《Exceptional C++ Style》[7] 第 37~40 条。

[72] 云风：C++ 里 string 用 template 实现, 纯粹是没事找事。同时区分宽字符和单字符极少在同一份代码里同时出现。结果把好好一个结实的库变成了一个源代码级的模板。另外见 Steve Donovan 写的《Overdoing C++ Templates》http://blog.csdn.net/myan/article/details/1915

[73] https://github.com/chenshuo/recipes/tree/master/string

[74] http://code.google.com/p/protobuf/source/browse/tags/2.4.1/src/google/protobuf/stubs/stl_util-inl.h#78

[75] http://www.open-std.org/JTC1/SC22/WG21/docs/lwg-defects.html#530

14 用 STL algorithm 秒杀几道算法面试题

C++ STL 的 algorithm 配合自定义的 functor (仿函数、函数对象) 可以秒杀不少面试题，代码简洁，正确性也容易验证。本节仍旧采用 C++03 的 functor 写法，没有采用 C++11 的 Lambda 表达式写法，尽管后者会简洁得多。本节代码在 Debian Linux 6.0/g++ 4.4 下测试通过，完整代码及测试用例见 [76]。

14.1 用 next_permutation() 生成排列与组合

本小节内容源自十年前我写的一篇博客[77]，这篇博客还找到了 Visual C++ 7.0 的 STL 的一个疑似 bug（或者叫 feature)。生成排列、组合、整数划分的具体算法见 Donald Knuth 的《The Art of Computer Programming, Volume 4A》[78]第 7.2.1 节。本处只给出使用 STL 的实现代码。

14.1.1 生成 N 个不同元素全排列

这是 next_permutation() 的基本用法，把元素从小到大放好（即字典序最小的排列)，然后反复调用 next_permutation() 就行了。

recipes/algorithm/permutation.cc

```
#include <algorithm>
#include <iostream>
#include <iterator>
#include <vector>

int main()
{
  int elements[] = { 1, 2, 3, 4 };
  const size_t N = sizeof(elements)/sizeof(elements[0]);
  std::vector<int> vec(elements, elements + N);

  int count = 0;
  do
  {
    std::cout << ++count << ": ";
    std::copy(vec.begin(), vec.end(),
              std::ostream_iterator<int>(std::cout, ", "));
    std::cout << std::endl;
  } while (next_permutation(vec.begin(), vec.end()));
}
```

recipes/algorithm/permutation.cc

[76] https://github.com/chenshuo/recipes/
[77] http://blog.csdn.net/solstice/article/details/2059
[78] http://cs.utsa.edu/ wagner/knuth/

整个程序最关键的就是第 19 行。输出的前几行是

```
1: 1, 2, 3, 4,
2: 1, 2, 4, 3,
3: 1, 3, 2, 4,
4: 1, 3, 4, 2,
5: 1, 4, 2, 3,
6: 1, 4, 3, 2,
7: 2, 1, 3, 4,
8: 2, 1, 4, 3,
9: 2, 3, 1, 4,
// 一共 24 行
```

类似的代码还能生成多重排列，比如 2 个 a、3 个 b 的全部排列，代码见 permutation2.cc。输出是

```
1: a, a, b, b, b,
2: a, b, a, b, b,
3: a, b, b, a, b,
4: a, b, b, b, a,
5: b, a, a, b, b,
6: b, a, b, a, b,
7: b, a, b, b, a,
8: b, b, a, a, b,
9: b, b, a, b, a,
10: b, b, b, a, a,
```

注：$\frac{5!}{2! \times 3!} = 10$

思考：能不能把 do {} while() 循环换成 while () {} 循环？

14.1.2 生成从 N 个元素中取出 M 个的所有组合

题目 输出从 7 个不同元素中取出 3 个元素的所有组合。

思路：对序列 { 1, 1, 1, 0, 0, 0, 0 } 做全排列，对于每个排列，输出数字 1 对应的位置上的元素。代码如下

recipes/algorithm/combination.cc

```
7  int main()
8  {
9    int values[] = { 1, 2, 3, 4, 5, 6, 7 };
10   int elements[] = { 1, 1, 1, 0, 0, 0, 0 };
11   const size_t N = sizeof(elements)/sizeof(elements[0]);
12   assert(N == sizeof(values)/sizeof(values[0]));
13   std::vector<int> selectors(elements, elements + N);
14
```

```
15    int count = 0;
16    do
17    {
18      std::cout << ++count << ": ";
19      for (size_t i = 0; i < selectors.size(); ++i)
20      {
21        if (selectors[i])
22        {
23          std::cout << values[i] << ", ";
24        }
25      }
26      std::cout << std::endl;
27    } while (prev_permutation(selectors.begin(), selectors.end()));
28  }
```

recipes/algorithm/combination.cc

注意，为了照顾输出顺序，第 27 行用的是 prev_permutation()。程序输出是

```
1: 1, 2, 3,
2: 1, 2, 4,
3: 1, 2, 5,
4: 1, 2, 6,
// 省略若干行
33: 4, 5, 7,
34: 4, 6, 7,
35: 5, 6, 7,
```

可见完整地输出了 $C(7,4) = 35$ 种组合。

14.2 用 {make,push,pop}_heap() 实现多路归并

题目 用一台 4G 内存的机器对磁盘上的单个 100G 文件排序。

这种单机外部排序题目的标准思路是先分块排序，然后多路归并成输出文件。多路归并很容易用 heap 排序实现，比方说要归并已经按从小到大的顺序排好序的 32 个文件，我们可以构造一个 32 元素的 min heap，每个元素是 std::pair<Record, FILE*>。然后每次取出堆顶的元素，将其 Record 写入输出文件；如果 FILE* 还可读，就读入一条 Record，再向 heap 中添加 std::pair<Record, FILE*>。这样当 heap 为空的时候，多路归并就完成了。注意在这个过程中 heap 的大小通常会慢慢变小，因为有可能某个输入文件已经全部读完了。

这种方法比传统的二路归并要节省很多遍磁盘读写，假如用教科书上的二路归并来做外部排序[79]，那么我们要先读一遍这 32 个文件，两两归并输出 16 个稍大的已排

[79]这种教科书有可能是在大型机还在使用磁带外存的时候写成的。

序中间文件；然后再读一遍这 16 个中间文件，两两归并输出 8 个更大的中间文件；如此往复，最后归并两个已经排好序的大文件，输出最终的结果。读者可以算算这比直接多路归并要多读写多少遍磁盘。

完整的外部排序代码见 recipes/esort/sort02.cc 及其改进版 sort{03,04}.cc。这里展示一个内存里的多路归并，以说明基本思路。

recipes/algorithm/mergeN.cc

```
39  File mergeN(const std::vector<File>& files)
40  {
41    File output;
42    std::vector<Input> inputs;
43
44    for (size_t i = 0; i < files.size(); ++i) {
45      Input input(&files[i]);
46      if (input.next()) {
47        inputs.push_back(input);
48      }
49    }
50
51    std::make_heap(inputs.begin(), inputs.end());
52    while (!inputs.empty()) {
53      std::pop_heap(inputs.begin(), inputs.end());
54      output.push_back(inputs.back().value);
55
56      if (inputs.back().next()) {
57        std::push_heap(inputs.begin(), inputs.end());
58      } else {
59        inputs.pop_back();
60      }
61    }
62
63    return output;
64  }
```

recipes/algorithm/mergeN.cc

第 44~51 行构造一个 heap，第 52 行开始的 while 循环反复取出堆顶元素（第 53 行 std::pop_heap() 会把堆顶元素放到序列末尾，即 inputs.back() 处），第 54 行把取出的元素（当前最小值）输出。第 56~60 行从堆顶元素所属的文件读入下一条记录，如果成功，就把它放回堆中（第 57 行）。当循环结束的时候，堆为空，说明每个文件都读完了。

其中用到的 Input 类型定义如下。

recipes/algorithm/mergeN.cc

```
typedef int Record;
typedef std::vector<Record> File;
```

```
struct Input
{
  Record value;
  const File* file;

  explicit Input(const File* f);
  bool next();

  bool operator<(const Input& rhs) const
  {
    // make_heap to build min-heap, for merging
    return value > rhs.value;
  }
};
```

recipes/algorithm/mergeN.cc

类似的题目：有 a、b 两个文件，大小各是 100G 左右，每行长度不超过 1k，这两个文件有少量（几百个）重复的行，要求用一台 4G 内存的机器找出这些重复行。

解这道题目有两个方向，一是 hash，把 a、b 两个文件按行的 hash 取模分成几百个小文件，每个小文件都在 1G 以内，然后对 a1、b1 求交集 c1，对 a2、b2 求交集 c2，这样就能在内存里解决了。

第二个思路是外部排序，但是跟前面完整的外部排序不同，我们并不需要得到 a′、b′ 两个已排序的文件再求交集，只需要把 a 分块排序成 100 个小文件，再把 b 分块排序成 100 个小文件，剩下的工作就是一边读这些小文件，一边在内存中同时归并出 a′ 和 b′，一边求出交集。内存中的两个多路归并需要两个 heap，分别对应 a 和 b 的小文件 s。

代码写起来估计比单个 heap 归并要复杂一些，特别是 C++ 不支持类似 C# 的 yield 关键字来方便地实现迭代。假如 C++ 有 yield，那么“求交集”这一步我们直接调用 std::set_intersection() 并配合适当的迭代器就行了，但是在没有 yield 的情况下要实现这样的迭代器恐怕要费事得多，因为每个迭代器要维护更多的状态。这算是 coroutine 的一个使用场景。

14.3 用 unique() 去除重复空白

孟岩在谈《C++ 程序设计原理与实践》[80] 时曾说“比如对我来说，C++ 这个语言最强的地方在于它的模板技术提供了足够复杂的程序库开发机制，可以把复杂性高度

[80] http://blog.csdn.net/hzbooks/article/details/5767169

集中在程序库里。做得好的话，在应用代码部分我连一个 for 循环都不用写，犯错误的机会就少，效率还不打折扣，关键是看着代码心里爽。”这几小节可算是他这番话的一个注脚。C++11 有了 Lambda 表达式，Scott Meyers 倡导的“Prefer algorithm calls to hand-written loops”就更容易落实了[81]。

题目 给你一个字符串，要求原地 (in-place) 把相邻的多个空格替换为一个[82]。例如，输入 "a␣␣b"，输出 "a␣b"；输入 "aaa␣␣␣bbb␣␣"，输出 "aaa␣bbb␣"。

这道题目不难，手写的话也就是单重循环，复杂度是 $O(N)$ 时间和 $O(1)$ 空间。这里展示用 std::unique() 的解法，思路很简单：std::unique() 的作用是去除相邻的重复元素，我们只要把“重复元素”定义为“两个元素都是空格”即可。注意所有针对区间的 STL algorithm 都只能调换区间内元素的顺序，不能真正删除容器内的元素，因此需要第 17 行。关键代码如下

recipes/algorithm/removeContinuousSpaces.cc

```
5  struct AreBothSpaces
6  {
7    bool operator()(char x, char y) const
8    {
9      return x == ' ' && y == ' ';
10   }
11 };
12
13 void removeContinuousSpaces(std::string& str)
14 {
15   std::string::iterator last
16     = std::unique(str.begin(), str.end(), AreBothSpaces());
17   str.erase(last, str.end());
18 }
```

recipes/algorithm/removeContinuousSpaces.cc

14.4 用 partition() 实现“调整数组顺序使得奇数位于偶数前面”

std::partition() 的作用是把符合条件的元素放到区间首部，不符合条件的元素放到区间后部，我们只需把“符合条件”定义为“元素是奇数”就能解决这道题。复杂度是 $O(N)$ 时间 $O(1)$ 空间。为节省篇幅，isOdd() 直接做成了函数，而不是函数对象，缺点是有可能阻碍编译器做 inlining。

[81] http://drdobbs.com/184401446
[82] https://gist.github.com/2227226

recipes/algorithm/partition.cc

```
bool isOdd(int x)
{
  return x % 2 != 0;  // x % 2 == 1 is WRONG
}

void moveOddsBeforeEvens()
{
  int oddeven[] = { 1, 2, 3, 4, 5, 6 };
  std::partition(oddeven, oddeven+6, &isOdd);
  std::copy(oddeven, oddeven+6, std::ostream_iterator<int>(std::cout, ", "));
  std::cout << std::endl;
}
```

recipes/algorithm/partition.cc

输出如下，注意确实满足“奇数位于偶数之前”，但奇数元素之间的相对位置有变化，偶数元素亦是如此。

```
1, 5, 3, 4, 2, 6,
```

如果题目要求改成“调整数组顺序使奇数位于偶数前面，并且保持奇数的先后顺序不变，偶数的先后顺序不变”，解决办法也一样简单，改用 stable_partition() 即可，代码及输出如下：

```
int oddeven[] = { 1, 2, 3, 4, 5, 6 };
std::stable_partition(oddeven, oddeven+6, &isOdd);
std::copy(oddeven, oddeven+6, std::ostream_iterator<int>(std::cout, ", "));
std::cout << std::endl;
// 输出 1, 3, 5, 2, 4, 6,
```

注意，stable_partition() 的复杂度较特殊：在内存充足的情况下，开辟原数组一样大的空间，复杂度是 $O(N)$ 时间和 $O(N)$ 空间；在内存不足的情况下，要做 in-place 位置调换，复杂度是 $O(N \log N)$ 时间和 $O(1)$ 空间。

类似的题目还有“调整数组顺序使负数位于非负数前面”，读者自能举一反三。

14.5 用 lower_bound() 查找 IP 地址所属的城市

题目 已知 N 个 IP 地址区间和它们对应的城市名称，写一个程序，能从 IP 地址找到它所在的城市。注意这些 IP 地址区间互不重叠。

这道题目的 naïve 解法是 $O(N)$，借助 std::lower_bound() 可以轻易做到 $O(\log N)$ 查找，代价是事先做一遍 $O(N \log N)$ 的排序，如果区间相对固定而查找很频繁，这么做是值得的。

基本思路是按 IP 区间的首地址排好序，再进行二分查找。比如说有两个区间 [300, 500]、[600, 750]，分别对应北京和香港两个城市，那么 std::lower_bound() 查找 299, 300, 301, 499, 500, 501, 599, 600, 601, 749, 750, 751 等“IP 地址”返回的迭代器如下。

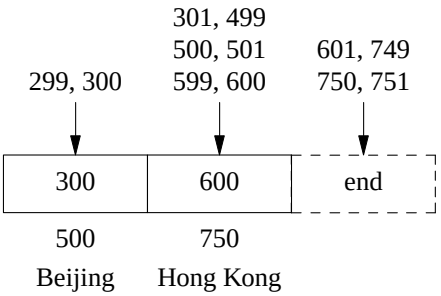

我们需要对返回的结果微调（第 28~32 行），使得迭代器 it 所指的区间是惟一有可能包含该 IP 地址的区间。

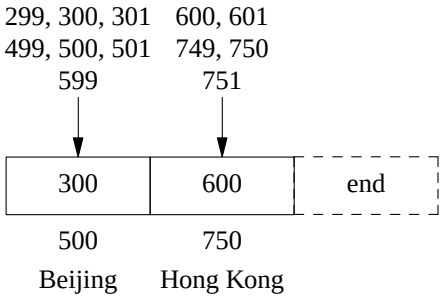

最后判断一下 IP 地址是否位于这个区间就行了（第 34 行）。完整代码如下，为了简化，“城市”用整数表示，-1 表示未找到。另外这个实现对于整个 IP 地址空间都是正确的，即便区间中包括 [255.255.255.0, 255.255.255.255] 这种边界条件。

recipes/algorithm/iprange.cc

```
7  struct IPrange
8  {
9    uint32_t startIp;  // inclusive
10   uint32_t endIp;    // inclusive
11   int value;         // >= 0
12
13   bool operator<(const IPrange& rhs) const
14   {
15     return startIp < rhs.startIp;
16   }
17 };
18
19 // REQUIRE: ranges is sorted.
```

```
20  int findIpValue(const std::vector<IPrange>& ranges, uint32_t ip)
21  {
22    int result = -1;
23
24    if (!ranges.empty()) {
25      IPrange needle = { ip, 0, 0 };
26      std::vector<IPrange>::const_iterator it
27          = std::lower_bound(ranges.begin(), ranges.end(), needle);
28      if (it == ranges.end()) {
29        --it;
30      } else if (it != ranges.begin() && it->startIp > ip) {
31        --it;
32      }
33
34      if (it->startIp <= ip && it->endIp >= ip) {
35        result = it->value;
36      }
37    }
38
39    return result;
40  }
```

recipes/algorithm/iprange.cc

说明：如果 IP 地址区间有重复，那么我们通常要用线段树 [83]来实现高效的查询。

14.6 小结

想到正确的思路是一码事，写出正确的经得起推敲的代码是另一码事。例如第 14.4 节用 (x % 2 != 0) 来判断 int x 是否为奇数，如果写成 (x % 2 == 1) 就是错的，因为 x 可能是负数，负数的取模运算的关窍见第 8 节。常见的错误还包括误用 char 的值作为数组下标（题目：统计文件中每个字符出现的次数），但是没有考虑 char 可能是负数，造成访问越界。有的人考虑到了 char 可能是负数，因此先强制转型为 unsigned int 再用作下标，这仍然是错的。正确的做法是强制转型为 unsigned char 再用作下标，这涉及到 C/C++ 整形提升的规则，就不详述了。这些细节往往是面试官的考察点[84]。本节给出的解法在正确性方面应该是没问题的，效率方面，可以说在 Big-*O* 意义下是最优的，但不一定是运行最快的。

另外，面试题的目的可能就是让你动手实现一些 STL 算法，例如求两个有序集合的交集 (set_intersection)、洗牌 (random_shuffle) 等等，这就不属于本文所讨论的范围了。从“算法”本身的难度上看，我个人把 STL algorithm 分为三类，面试时要求手写的往往是第二类算法。

[83]http://en.wikipedia.org/wiki/Segment_tree

[84]工作 5 年以来，我面试过近百人，因此这番话是从面试官的角度说的。

- 容易，即闭着眼睛一想就知道是如何实现的，自己手写一遍的难度跟 strlen() 和 strcpy() 差不多。这类算法基本上就是遍历一遍输入区间，对每个元素做些判断或操作，一个 for 循环就解决战斗。一半左右的 STL algorithm 属于此类，例如 for_each()、transform()、accumulate() 等等。
- 较难，知道思路，但是要写出正确的实现要考虑清楚各种边界条件。例如 merge()、unique()、remove()、random_shuffle()、partition()、lower_bound() 等等，三成左右的 STL algorithm 属于此类。
- 难，要在一个小时内写出正确的健壮的实现基本不现实，例如 sort() [85]、nth_element()、next_permutation()、inplace_merge() 等等，越有两成 STL algorithm 属于此类。

注意，“容易”级别的算法是指写出正确的实现很容易，不一定意味着写出高效的实现也同样容易，例如 std::copy() 拷贝 POD 类型的效率可媲美 memcpy()，这需要用一点模板技巧。

以上分类纯属个人主观看法，或许换个人来分类结果就大不一样，例如把 remove() 归入简单，把 next_permutation() 归入较难，把 lower_bound() 归入难等等。

[85] 快速排序是本科生数据结构课上就有的内容，但是工业强度的实现是足以在顶级期刊上发论文的。

Bibliography

[1] 侯捷. 《池內春秋——Memory Pool 的設計哲學與無痛運用》. 《程序员》2002 年第 9 期。

[2] Scott Meyers 著, 侯捷译. 《Effective C++ 中文版》(第 3 版). 电子工业出版社, 2006.

[3] 俞甲子 石凡 潘爱民著. 《程序员的自我修养——链接、装载与库》. 电子工业出版社, 2009.

[4] Herb Sutter and Andrei Alexandrescu 著, 侯捷 陈硕译. *C++ Coding Standards: 101 Rules, Guidelines, and Best Practices*. 《C++ 编程规范》. 碁峰出版社, 2008.

[5] Michael Feathers 著, 刘未鹏译. *Working Effectively with Legacy Code*. 《修改代码的艺术》. 人民邮电出版社, 2007.

[6] Scott Meyers 著. 《Effective STL》. Addison-Wesley, 2001.

[7] Herb Sutter 著, 刘未鹏译. 《Exceptional C++ Style 中文版》. 人民邮电出版社, 2006.

[8] Andrei Alexandrescu. Scalable Use of the STL. C++ and Beyond 2010. http://www.artima.com/shop/cpp_and_beyond_2010

[9] 陈硕. 从《C++ Primer 第四版》入手学习 C++. 《C++ Primer 第 4 版 评注版》前言. 电子工业出版社，2012.
https://github.com/downloads/chenshuo/documents/LearnCpp.pdf