

yoursunny.P2008.VirusScanner技术报告

IS217 《计算机病毒原理》 F0503602 石君霄 5050369043 2008-06-11

1 开发思路

1.1 背景

Windows是一款相当流行的操作系统。Windows的图形界面易于上手，因此很多计算机用户接触的操作系统往往就是Windows。正是由于初学者广泛使用Windows，导致攻击者针对Windows平台编写了各类计算机病毒，影响了系统的正常使用。Windows用户往往会购买各类防病毒软件，以求“解决”病毒对Windows的威胁。

然而，随着计算机病毒编制技术的发展，很多病毒启动后第一件事就是关闭并破坏系统中存在的防病毒软件——方法包括结束进程、篡改文件、修改系统日期至防杀病毒软件注册有效期以外等。防病毒软件被破坏后，病毒就可长驱直入、入驻Windows系统，而此时初学用户就很难再将系统恢复原状了。对于计算机维护人员来说，防病毒软件被破坏后，如果安全模式等也同时被破坏，在使用故障恢复控制台无效的情况下，大概也就只能重装Windows了。

在这种情况下，我提出了一个新思路——交叉杀毒！

1.2 规划

我们知道，由于Linux操作系统在商业市场和中国的家庭并不流行，并且Linux默认的权限管理，针对Linux的病毒相对较少。因此，可以开发一种杀毒工具，它本身运行于Linux操作系统中，而可以对Windows病毒进行查杀。这就是所谓的“交叉杀毒”。

虽然“针对Linux的病毒相对较少”，但是“较少”并不是“没有”，即Linux也会被病毒感染。但是，病毒感染后必须具有持久化的存储，才能够在下一次启动时发挥作用；持久化的存储必须有硬件作支撑，例如存储在硬盘、U盘或引导系统的tftp服务器上。试想，从光盘引导Linux，光盘一旦制作成功，硬件特性就决定了光盘上的Linux可以完全避免被病毒感染。

这个想法不是我第一个提出的。事实上，卡巴斯基杀毒软件已经做出了这样的一个产品——[Kaspersky Rescue Disk](#)，它基于Gentoo，可以用光盘启动Linux，并且查杀病毒。正如cnBeta网友的评论那样，它的最大弱点是无法自动更新病毒库，要使用新的病毒库就必须重新刻录光盘；虽然CD-RW可以多次写入，但是每次写入仍然需要消耗很多时间。

我的设计是：光盘启动后，可以通过网络更新病毒库。一次交互过程举例如下：

```
yoursunny.P2008.VirusScanner
Starting up.....

Configuring network with DHCP.....Failed
IP Address: 192.168.1.50
```

Subnet Mask: 255.255.255.0
Gateway: 192.168.1.1
DNS Server: 208.67.222.222

Looking for harddisk partitions.....
/dev/sda1 label=WINDOWS fs=ntfs size=8GB mount=/media/WINDOWS
/dev/sda5 label=SOFTWARE fs=fat32 size=15GB mount=/media/SOFTWARE
/dev/sdb1 label=MYUSB fs=fat size=64MB mount=/media/MYUSB

Resolving [signature.virusscanner.yoursunny.cn] - 10.0.7.50
Downloading latest virus signatures.....600KB
Uncompressing virus signatures.....35MB

Mounted partitions:
[1] WINDOWS
[2] SOFTWARE
[3] MYUSB
Which partitions do you want to scan? 13

Scanning WINDOWS..... 100%, ETA 00:00:00
Scanning MYUSB..... 3%, ETA 00:01:12

Found 2 virus:
WINDOWS:\windows\svch0st.exe Anomaly-277
MYUSB:\my.exe Scribble
Do you want to clean them [yn]? y

Username: test03
Password:
Resolving [member.virusscanner.yoursunny.cn] - 10.0.7.35
Login to server.....
Account balance: \$10.50

Available plans:
[1] 24-hour plan, \$1.0
[2] 72-hour plan, \$2.0
[3] 1-week plan, \$3.0
[4] 3-month plan, \$8.0
[5] 1-year plan, \$20.0
[6] 10-virus plan, \$2.0
[7] 50-virus plan, \$6.0
[8] 100-virus plan, \$10.0
[9] 1-virus plan, FREE!
Choose a plan: 2

New balance: \$8.50
Now you are: 72-hour plan member, until 2008-06.13 20:25

Resolving [cleaner.virusscanner.yoursunny.cn] - 10.0.7.65
Downloading cleaner for Anomaly-277.....
Cleaning virus on WINDOWS:\windows\svch0st.exe
Downloading cleaner for Scribble.....
To clean Scribble on MYUSB:\my.exe, it's required to submit it to the server,
it is okay [yn]? y
Resolving [c4.virusscanner.yoursunny.cn] - 10.0.7.24
Uploading MYUSB:\my.exe.....
Downloading clean version of MYUSB:\my.exe.....

这个交互过程比较长，主要步骤是：

1. 通过DHCP获取网络参数，如果获取失败则请用户输入
2. 从服务器下载最新的病毒库，解压缩
3. 检测系统中存在的所有硬盘分区和U盘分区，让用户选择要扫描哪些分区
4. 依次扫描选择的各分区，显示估计剩余时间
5. 列出发现的病毒列表，询问是否清除病毒；如果用户选择不清除病毒，结束并重启系统
6. 输入杀毒服务用户名和密码
7. 让用户付费购买杀毒服务，杀毒服务可以根据时间或者病毒种数计费
8. 下载每种病毒的杀毒器，杀掉病毒；部分病毒需要提交到服务器进行杀毒，提交前要提示用户
9. 结束并重启系统

上述过程可以做成gnome图形界面，已熟悉Windows的用户更加容易上手。

2 技术要点

刚才已经介绍了这个程序的整体设计。下面来看点更加实际的东西：演示中实现了什么？我已经编程实现了这个程序中最核心的部分——查毒模块。具体的说，我实现了1个算法和4个程序。

2.1 SMA多模式匹配算法

这个是最重要的部分，用C语言完成。

查毒（不是杀毒）的最基本方法就是模式匹配。模式匹配的本质，就是判定一个大字符串（称为haystack）中是否某个子串（这个子串称为模式pattern）；例如"A quick brown fox jumps over a lazy dog."中存在"brown"而不存在"love"。如果你使用过高级编程语言，你一定已经接触过模式匹配：

- JavaScript: `if (haystack.indexOf(pattern)>=0) {...} else {...}`
- PHP: `if (strpos(haystack,pattern)>=0) {...} else {...}`

模式匹配的基本方法是：从大字符串开头开始，逐字符比较与子串是否相等，一旦发现不相等，就把子串后移一位，从头比较。高级点的方法是使用KMP算法：对子串进行一定的分析，以便发现不相等的时候可以多后移一点，效率就提高了。

然而，基本方法和KMP算法，它们都只能对一个子串进行处理，也就是“单模式匹配”。病毒有成千上万种，查毒不能只查一种。你一定会想到另一个方法：`foreach (pattern in virus_array) {if (KMP(haystack,pattern)){...}else{...}}`。首先，这个循环的方法是可以完成功能的；然后，这个循环的方法是效率极低的——它消耗的时间与病毒种数成正比。

于是，我们要用一定的方法，只扫描haystack一次，而要找出其中包含的所有pattern——这就是“多模式匹配”要完成的。

如果你了解编译器词法分析的原理，你可以把多模式匹配看成一个词法分析器，所有的

病毒特征码都是这个词法分析器接受的单词。这个方法正确，但是实践起来并不容易。词法分析器可以使用GNU flex自动生成，或者用NFA->DFA->规约DFA的方法手工完成。不论采用哪一种途径，都有一个巨大的问题：不是所有的文件都是病毒，而且带毒文件也仅仅有一部分是特征码。例如"A quick brown fox jumps over a lazy dog."，用"brown"和"jumps"两个pattern来匹配，那么词法分析器是否要接受"fox"等单词呢？如果不接受，词法分析会失败；如果接受，你需要接受多少单词呢？因此用词法分析器解决多模式匹配问题并不容易。

还有一种常用的方法是使用树，从树顶开始，根据字符分支，逐级深入。如果匹配失败，则根据一定算法找到下一个节点：匹配到"brown"的w，后面却不是n，则转到owe的w上；如果后面不是e，再转到was的w上，如果仍然不行，只能回到树根上。

学术论文《[基于有序二叉树的多模式匹配算法](#)》提出了另一种方法：使用二叉树结构代替树结构，大大降低内存占用，而匹配速度基本一致；这个方法的原理较为复杂，请参见论文。论文中给出了一些伪代码，遗憾的是，这些伪代码存在诸多错误，直接写成程序是无法运行的。论文作者在某光盘上给出了一份C++语言的代码，但是需要Visual C++开发环境，而VirusScanner是运行于Linux的程序，因此也无法使用；不过这份C++代码虽然几乎没有注释，但是其中错误较少，可以参考。

经过本人的不懈努力，成功用C语言实现了SMA二叉树多模式匹配算法。该算法的接口是sma.h，接口主要内容有：

节点数据结构

```
//SMA算法二叉树节点
typedef struct smaNode smaNode;
typedef smaNode* smaState;
struct smaNode {
    unsigned int id;
    unsigned int Lchar;
    smaState Lchild;
    unsigned int Rchar;
    smaState Rchild;
    smaState Parent;//SMA意义上的父节点
    smaState Fail;
    smaUserData value;//用户数据
};

typedef smaNode* smaTree;
```

节点内存管理操作函数

- 创建新的SMA有序二叉树节点：smaNode* smaNode_make();
- 释放SMA有序二叉树节点及其所有后代内存：void smaNode_destroy(smaNode* n);

SMA算法基本计算函数

- 根据访问规则从状态p出发到子状态child时，若栈中有且只有ch，则返回child：
smaState sma_goto(smaState p, unsigned int ch);

- 计算状态深度: `int sma_StateDepth(smaState p);`

SMA二叉树构造函数

- 向有序二叉树添加一个pattern: `void sma_AddPattern(smaTree tree, const char* pattern, int len, smaUserData value);`
- 创建节点编号: `void sma_SetId(smaTree tree);`
- 创建失败指针: `void sma_BuildFail(smaTree tree);`

持久化函数

- 将有序二叉树输出为XML流: `void sma_dumpXML(smaTree tree, FILE* fd);`
- 注: XML输出目前只能用于查看, 因为没有实现从XML读取二叉树的函数
- 将有序二叉树输出为文本流: `void sma_dumpText(smaTree tree, FILE* fd);`
- 从文本流读取有序二叉树: `smaTree sma_loadText(FILE* fd);`

匹配查找函数

- 查找回调函数: `typedef void (*sma_callback)(int index, smaUserData value, void* data);`
- 从输入字符串中查找有序二叉树中的模式: `void sma_search(smaTree tree, const char* haystack, int len, sma_callback cb, void* data);`
- 从输入文件中查找有序二叉树中的模式: `void sma_search_file(smaTree tree, FILE* haystack, sma_callback cb, void* data);`

2.2 credo

credo并不是查毒工具的必要组成部分。它的目的是将开源查毒软件OpenAntiVirus的病毒库clamav.strings转换成smaconv可以识别的格式, 同时创建一份“模式id=>病毒名称”的列表。这个程序用C语言完成。

目前只能转换clamav.strings, 也就是单模式病毒库。OpenAntiVirus的另一个病毒库clamav2.strings定义了一个病毒需要依次匹配多个模式, 但是credo并不支持这种病毒库。

credo的使用方法: 下载[VirusSignatures-latest.zip](#), 解压出其中的clamav.strings, 然后在解压后所在目录运行credo程序, 当前目录中即会生成pattern-list.txt和virus-name.txt两个文件。

- pattern-list.txt: 作为smaconv的输入, 依此创建SMA二叉树
- virus-name.txt: “模式id=>病毒名称”的列表, 若要显示病毒名称是肯定需要它

OpenAntiVirus的病毒库, 现在看到的更新日期是在2004年, 也就是已经好长时间没有更新了。查毒工具的重中之重就是病毒库, 但是作为技术研究, 用一个较老的病毒库同样可以达到演示目的。

2.3 smaconv

smaconv的作用是把形如pattern-list.txt的文件转换成SMA二叉树, 用C语言完成。

pattern-list.txt的格式是: 每行一条记录, 模式id=模式十六进制串, 例如:

```
fcbb=58354F2150254041505B345C505A58353428505E2937434329377D2445494341522D5354414E4441
```

smaconv读入这样的文件，然后根据其中的记录构建SMA二叉树，最后输出成XML和文本文件。

smaconv的使用方法：`smaconv pattern-list.txt sma.txt sma.xml`

2.4 scanner

scanner是唯一需要发布给最终用户的程序。它读入sma.txt，然后根据其中的信息还原SMA二叉树，然后对各个文件作匹配。这个程序用C语言完成。

scanner有三种使用方法：

- 在命令行参数指定被扫描文件：`scanner sma.txt file1.ext file2.ext ...`
- 从文件指定被扫描文件：`scanner sma.txt @list`，list文件中包含被扫描文件的路径、每行一个
- 从标准输入流指定被扫描文件：`scanner sma.txt @-`，标准输入流包含被扫描文件的路径、每行一个

推荐使用第三种方法。例如要扫描/media/MYUSB的所有文件，可以用命令：

```
find /media/MYUSB -xtype f | tee list | scanner sma.txt @- > result
```

scanner会向标准输出流输出发现的所有特征信息，格式为：每行一条记录，“文件序号(从0开始),发现位置,特征id”。

这个程序对于查毒工具的性能至关重要。这个程序需要从文件读入数据，而系统调用引起的映像切换会消耗大量时间。读文件有三种方式：

- 使用fgetc逐字节读取：每次读一个字节就需要一次系统调用，效率很低
- 使用fread一次性读取一块：系统调用次数减少，但是管理缓冲区并不容易，而且需要对SMA算法库进行修改
- 使用mmap将文件映射到进程地址空间：我选择了这种方法，程序只需从“内存”取数据，操作系统会自动在缺页中断时加载所需的文件块；不但效率高，而且不需要程序管理缓冲区。这种方法的缺点是无法扫描大文件，因为我是将整个文件映射到地址空间，而地址空间的大小是有限的

2.5 result.sh

result.sh是一个shell脚本，读入scanner输出的结果，然后在被扫描文件列表、病毒名称列表中提取出病毒名称。

由于这是使用shell脚本实现的，它只能适合发现了很少几个病毒的情况，如果发现了大量病毒、scanner输出了一份很长很长的结果，那么它需要耗费大量的时间。

这个脚本仅仅用于测试。如果要制作杀毒光盘，应该使用更为高效的方法重写这个脚本，例如Python。

result.sh的使用方法：`result.sh < result > result.txt`

3 程序测试

测试环境：Ubuntu 8.04 hardy, kernel 2.6.24-16-generic, gnome 2.22.1; 奔腾M 1.70GHz, 512MB内存。

先编译上面三个程序，可执行文件复制到同一目录，并准备好clamav.strings病毒库。准备一些[病毒样本](#)和正常文件在sample/目录中，我准备了3827个文件，总共13.0MB，处于ext3文件系统中。

第一步，转换OpenAntiVirus病毒库

clamav.strings大小为2.6MB，有21096行。

运行命令：./credo

计时结果：real 0m0.089s, user 0m0.052s, sys 0m0.024s（用time命令计时）

产生文件：

pattern-list.txt, 2.2MB、21096行

virus-name.txt, 467.8KB、21096行

第二步，创建SMA二叉树

运行命令：./smaconv pattern-list.txt sma.txt sma.xml

计时结果：real 0m7.256s, user 0m5.672s, sys 0m0.312s

产生文件：

sma.txt, 32.9MB、1028296个状态

sma.xml, 74.6MB

注：sma.txt文件比pattern-list.txt大得多，但是可以对病毒库保密；尝试对sma.txt进行bz2压缩，9.1MB

第三步，扫描病毒

运行命令：find ./sample -xtype f | tee list | ./scanner sma.txt @- > result

计时结果：real 0m22.107s, user 0m11.869s, sys 0m0.524s

产生文件：

list, 123.3k、3766行, 被扫描的文件列表

result, 118.5k、9013行, 发现了9013个特征码

第四步, 整理扫描结果

运行命令: `./result.sh virus-name.txt list < result > result.txt`

计时结果: real 3m31.299s, user 1m51.827s, sys 1m3.812s

产生文件:

result.txt, 519.1k、9013行, 包含result文件的所有内容, 加上带毒文件名称、病毒名称
这个文件是可以人工阅读的, 节选如下:

```
1845, ./sample/atozvirus/k/KILLER1.COM, 1, 3cc1, VGEN.153.0 (Clam)
1846, ./sample/atozvirus/k/KIT.COM, 586, 1b6a, Kit.1
1846, ./sample/atozvirus/k/KIT.COM, 1181, 1b88, KitG
1846, ./sample/atozvirus/k/KIT.COM, 2254, 1b6b, Kit.2384 (Clam)
1847, ./sample/atozvirus/k/KLAEREN.COM, 7, 2b34, Small.130-gen (Clam)
1847, ./sample/atozvirus/k/KLAEREN.COM, 5946, 1b97, Klaeren
1848, ./sample/atozvirus/k/KHIZ751.COM, 2013, 184b, Infector-624.726
1849, ./sample/atozvirus/k/KENNEDY.COM, 63, 1ae8, Kennedy.4
1849, ./sample/atozvirus/k/KENNEDY.COM, 97, 1ae7, Kennedy.3
1849, ./sample/atozvirus/k/KENNEDY.COM, 120, 1ae6, Kennedy.1
1850, ./sample/atozvirus/k/KUKAC-NA.COM, 68, 3894, Turbo-448.A
1850, ./sample/atozvirus/k/KUKAC-NA.COM, 365, 3895, Turbo-448.B
1851, ./sample/atozvirus/k/KING1424.EXE, 1428, 280a, Satan 3.00
1852, ./sample/atozvirus/k/KUKAC448.COM, 68, 3894, Turbo-448.A
1852, ./sample/atozvirus/k/KUKAC448.COM, 365, 3895, Turbo-448.B
1853, ./sample/atozvirus/i/IRONMAID.COM, 7, 2b34, Small.130-gen (Clam)
1853, ./sample/atozvirus/i/IRONMAID.COM, 636, 18ca, Iron Maiden.1
1853, ./sample/atozvirus/i/IRONMAID.COM, 636, 18cb, Iron Maiden
1854, ./sample/atozvirus/i/ICELANDC.EXE, 127, 201f, Mix-664
1854, ./sample/atozvirus/i/ICELANDC.EXE, 169, 1800, Icelandic-Saratoga
1854, ./sample/atozvirus/i/ICELANDC.EXE, 249, 17fc, Icelandic I
1855, ./sample/atozvirus/i/ICEMIX1B.EXE, 8929, 2021, Mixer-1B
1855, ./sample/atozvirus/i/ICEMIX1B.EXE, 9227, 2023, Mix-I
1856, ./sample/atozvirus/i/INT1319C.EXE, 814, 189b, Intruder.1
1856, ./sample/atozvirus/i/INT1319C.EXE, 987, 189e, Intruder.4
1857, ./sample/atozvirus/i/IV-APRIL.EXE, 2571, 18db, Italian.8 (Clam)
1858, ./sample/atozvirus/i/INCOM.COM, 50, 1824, IKV-512
1859, ./sample/atozvirus/i/ITTI-MAL.COM, 4, 18ed, Itti-Malmsey
1860, ./sample/atozvirus/i/INTN1381.COM, 230, 188e, Internal.2
1860, ./sample/atozvirus/i/INTN1381.COM, 636, 188b, Internal.1
1860, ./sample/atozvirus/i/INTN1381.COM, 653, 188c, Internal-1381
```

可见, 查毒工具对病毒种类的识别基本正确; sample目录里还有一份Nachos源代码作为正常文件, 它没有被识别为病毒。

最大的缺点是, 这个脚本太慢了! 不过这次扫描的目标包括病毒样本包从而有大量病毒, 而平时的扫描不会是这样的情况。

效率的一个对比

连接上我的移动硬盘（USB2.0、NTFS分区），使用上面的音乐目录作为样本，并且放入一个eicar测试病毒。总共88个文件、305.8MB。

运行命令：`find /media/M1/music -xtype f | tee list.m1 | ./scanner sma.txt @- > result.m1`

计时结果：`real 10m36.176s, user 8m47.537s, sys 0m1.864s`

运行命令：`./result.sh virus-name.txt list.m1 < result.m1 > result.m1.txt`

计时结果：`real 0m0.073s, user 0m0.024s, sys 0m0.016s`

产生文件：

result.m1.txt，内容只有一行：

```
0,/media/M1/music/eicar,2,fcb,Eicar-Test-Signature
```

查毒的正确性得到了验证：音乐文件没有病毒，只有一个eicar是病毒。效率方面，19分钟显得有点慢，但作为自己写的一个原型，就不要苛求了。

4 结论

yoursunny.P2008.VirusScanner使用SMA多模式匹配算法正确实现了特征码查病毒功能。