ENGENHARIA REVERSA

UFF – Universidade Federal Fluminense

Graduação em Ciência da Computação

Informática I – 2005/2

Antonio Jorge Sapage da Canhota Junior
Diego Alves de Souza
Diogo dos Santos Moutinho
Felipe Paixão Lohnefink

Índice

1. INTRODUÇÃO

A Engenharia Reversa é uma atividade que trabalha com um produto existente (um software, uma peça mecânica, uma placa de computador, etc.) tentando entender como este produto funciona, o que ele faz exatamente e como ele se comporta em todas as circunstâncias. Fazemos engenharia reversa quando queremos trocar, modificar uma peça (ou um software) por outro, com as mesmas características ou entender como esta funciona e não temos acesso a sua documentação.

Por exemplo, numa fábrica, uma bomba falhou e tem que ser trocada por uma nova. A bomba foi instalada há 25 anos e as pessoas que fizeram o trabalho se aposentaram há muito tempo. A empresa que vendia essas bombas faliu. A fábrica tem que achar uma nova bomba, com exatamente as mesmas características, ou seja, ela tem que ser montada sobre a tubulação existente (dimensões definidas, como a bomba está fixada, volume ocupado pela bomba, etc.) que são características fáceis de descobrir, mas podem também existir outras menos evidentes (a bomba tem que fornecer um débito definido, ela precisa respeitar algumas restrições desconhecidas). Todas essas características da bomba podem ser importante ou não, a fábrica tem que descobrir isso antes de comprar uma nova.

Por que a Engenharia Reversa na Informática?

Organizações trabalham com sistemas apresentando problemas tais como:

- O sistema foi iniciado há muitos anos (até 20 anos atrás).
- O sistema tem pouca documentação e ela não foi atualizada. O que quer dizer que a documentação descreve um estado anterior do sistema, mas não a configuração atual.
- As pessoas que criaram o sistema deixaram a empresa, ninguém pode explicar muitas decisões que foram tomadas.
- Algumas partes do sistema foram implementadas com métodos “estranhos” ou sem método nenhum.
- Muitos programadores diferentes implementaram pequenas partes do sistema. Cada um usava um método e um estilo particular de programação.
- O sistema é implementado numa linguagem de programação antiga (Cobol, Fortran, APL, etc.) para a qual existem poucas ferramentas.

Mas o sistema tem que evoluir:

- Para ser adaptado a novos computadores (mais barato, mais rápido ou porque ninguém mantém mais os velhos).
- Para ser adaptado a novos softwares (novas bibliotecas, novas linguagem de programação, novas ferramentas).
- Para ser adaptado a novas regras (troca de moeda em todos os países da Europa).
- Para disponibilizar novas funcionalidades que outras empresas usam.
- Para corrigir bugs (bug do ano 2000).

A engenharia reversa pode ser de programas como nos exemplos acima ou de dados. Por exemplo, se queremos construir um editor de texto compatível com o MS-Word, vamos ter que entender a representação que ele usa para ler os documentos MS-Word ou poder salvar documentos nesse formato. Outro exemplo é de banco de dados, ou seja, para passar de um banco de dados relacional a um banco de dados orientado a objeto.

Para software, restrições físicas como as dimensões da tubulação sobre a qual a bomba tem que ser montada, são restrições de interface. O velho programa tinha uma interface específica, e costumava ser chamado de maneira bem definida. O novo programa tem que respeitar a mesma interface. As outras características do programa vão se tornar requisitos não funcionais para o novo programa.

É importante observar que esses problemas não são raros, pelo contrário, são muito freqüentes.

Exemplos de Engenharia Reversa

Fora da Computação

Tupolev Tu-4: Em 1945, durante a segunda guerra mundial, três bombardeiros americanos modelo B-29 foram forçados a aterrissar em território russo. Os soviéticos os desmontaram e estudaram. Usaram a engenharia reversa para copiar o bombardeiro nos mínimos detalhes. O resultado foi o bombardeiro Tupolev Tu-4 que voou pela primeira vez em 19 de maio de 1947. A produção em série do bombardeiro começou neste mesmo ano.

Na Computação

IBM-PC compatível: A IBM abriu mão da patente de sua plataforma, deixando o caminho livre para qualquer um produzir uma maquina que fosse compatível com o IBM-PC. Assim surgiram vários clones do IBM-PC.

Samba: Software que permite sistemas que não estão rodando o Microsoft Windows a compartilhar arquivos com sistemas que estão. A engenharia reversa foi utilizada para descobrir como o compartilhamento de arquivos do Windows funcionava, para que então computadores que não estivessem com a plataforma Windows pudessem emula a mesma.

Wine: Programa que funciona como a API do Windows. Permite executar aplicativos desenvolvidos para Windows 3.1X, 9X, NT e 200x no GNU/Linux.

OpenOffice.org: É um conjunto de aplicativos em OpenSource (código aberto). Está disponível para diferentes plataformas: incluindo Microsoft Windows, Unix, Solaris, Linux e Mac OS X. A Suite é compatível com o Microsoft Office.

Reengenharia

A engenharia reversa consiste em apenas analisar o sistema ou a ferramenta para criar uma representação dela. Já a Reengenharia vai além. Analisa-se o projeto, cria-se uma representação do mesmo e, através dessa representação, monta-se uma nova estrutura que funcione Exatamente como a primeira, mas que não seja meramente uma cópia dela.

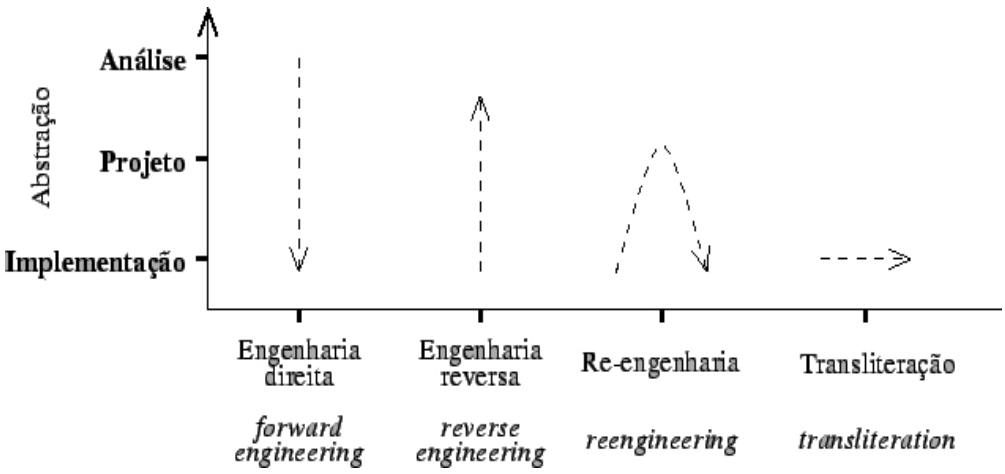

Definição de engenharia reversa de software

A engenharia reversa de software consiste em analisar um determinado sistema para criar representações do próprio em um nível mais alto de abstração.
Também pode ser encarada como *"Voltar atrás no ciclo de desenvolvimento do software"*.

Na prática, existem dois tipos de engenharia reversa de software:

- No primeiro caso, o código-fonte já está disponível, mas os aspectos mais globais, talvez documentação escassa ou não válida, têm que ser descobertos.

- No segundo caso o código-fonte do software não está disponível, e todos os esforços para descobrir uma possível fonte do código para o software são considerados como engenharia reversa.

OBS: As pessoas que trabalham com engenharia reversa de software estão mais familiarizadas com o segundo caso, chegando até a desconsiderar o primeiro.

2. TÉCNICAS DE ENGENHARIA REVERSA SEM O CÓDIGO-FONTE

Engenharia reversa de software pode ser efetuada por vários métodos.Três grupos principais da engenharia de software são:

- **Análise de fluxo de dados:** Análise através da observação da troca de informações que envolvem "analisadores de bus" e "pacotes de sniffers" por exemplo, para "ouvir" dentro do bus de um computador ou uma conecção de rede, revelando o tráfico de dados "escondidos". O comportamento dos dados no bus ou na rede podem então ser analisados para produzir uma nova implementação do software que imita o mesmo comportamento. Isto é especialmente utilizado na engenharia reversa de drivers de dispositivos.

- **Desassemblar:** Usando um desassembler, conseguimos obter a linguagem de máquina diretamente do programa. Este código é lido e entendido nos seus próprios termos, apenas com a ajuda de "mneminics" da linguagem de máquina. Isto funciona em qualquer programa de computador, mas pode levar um bom tempo, especialmente para alguém que não esteja acostumado ao código de máquina.

- **Decompilação:** Neste método utiliza-se um decompilador, um programa que tenta recriar o código-fonte em uma linguagem de alto nível, tendo disponível apenas o código de máquina.

3. TÉCNICAS DE ENGENHARIA REVERSA COM O CÓDIGO-FONTE

Extração das Informações

O primeiro trabalho que se deve fazer é coletar informações sobre o sistema a ser estudado. As atividades da engenharia reversa se fazem sobre essas informações extraídas, mais do que sobre o próprio sistema.

As informações podem ser extraídas de várias fontes: o código fonte, a execução, os dados (por exemplo, em banco de dados), a "documentação", ou outras fontes.

Código (análise estática)

A primeira fonte, o código, é a mais usada. A análise do código é chamada também de análise estática (por oposição à análise dinâmica que é a execução do sistema).

Ela permite extrair as informações mais básicas do sistema:

- Quais são os componentes básicos do sistema: arquivos, rotinas, tipos, variáveis, classes, etc;
- Relações de definição conectam um componente com seu conteúdo (onde ele se encontra);
- Relações de referência conectam um componente com aqueles que o usam (se uma rotina A chamar uma outra rotina B. A depende de B porque uma modificação na definição de B pode ter conseqüências sobre a execução de A).

Ferramentas para fazer essa análise são chamadas de "parser". O "parsing" é a primeira etapa da compilação do código fonte. Para fazer isso, é preciso conhecer a sintaxe da linguagem de programação usada.

Dependendo das necessidades, pode-se usar parsers específicos que vão procurar só um tipo particular de informação. Por exemplo, num programa Pascal, podemos extrair o nome de todas as funções definidas.

Trace de execução (análise dinâmica)

A análise estática pode extrair muitas informações de um programa, mas nem todas. Por exemplo, qual parte de uma instrução IF é realmente usada pode depender dos dados com que o programa foi chamado. Para descobrir esse tipo de informação, precisamos da análise dinâmica, que consiste em executar o programa e monitorar os valores das variáveis, quais funções são chamadas, etc.

Dados

Os bancos de dados podem ser usados como fonte de informação para ajudar na engenharia reversa de um sistema. Mas a engenharia reversa de dados é também um trabalho específico que pode ser feito independentemente de qualquer sistema que possa manipular esses dados. Por exemplo, poderíamos querer converter um velho banco de dados sobre um "main frame" para um banco de dados relacional e distribuído sobre vários PCs.

Documentação

Chamamos de documentação tudo o que não está usado pelo computador para fazer funcionar o sistema, mas se destina aos engenheiros que usam o código: relatórios, comentários no código, diagramas da análise ou do projeto, etc.

Como ela se destina aos seres humanos ela é de difícil de analisar automaticamente. A abordagem mais usada é usar as palavras da documentação. Isso pode permitir extrair os conceitos importantes do domínio de aplicação do sistema. Esta abordagem está baseada sobre a suposição que os conceitos importantes aparecem com mais freqüência na documentação.

Outras fontes de informação

Finalmente, é possível usar outras fontes de informação. Por exemplo, para definir sub-sistemas, poderíamos procurar quem escreveu cada porção do código. É razoável pensar que se duas partes do código foram desenvolvidas pela mesma pessoa elas tem maior probabilidade de pertencer ao mesmo sub-sistema

Tratamento dos Fatos

Essas são algumas das principais atividades envolvidas na engenharia reversa. Essas atividades usam as informações que foram extraídas do sistema. Podemos resumir o objetivo geral dessas atividades da seguinte forma: elas tentam abstrair informações de mais alto nível de abstração dos fatos do sistema. O que quer dizer que elas vão eliminar os inumeráveis detalhes. O problema é decidir nessa massa de informações o que é importante ou não.

Anomalias no código

Num software legado, o código pode conter várias anomalias, como partes do programa que nunca podem ser executadas (código morto) e trechos de código que foram copiados e levemente modificados. Essas anomalias complicam o código inutilmente, fazendo ele mais longo do que deveria ser e multiplicando as coisas que um programador tem que estudar e entender.

Para resolver esse problema podemos deletar o código morto, e no caso dos clones podemos modificar o código para suprimir-los ou então comentar o código dizendo que existem clones.

Encapsulamento

O encapsulamento é mais uma técnica de re-engenharia do que de engenharia reversa. Em vez de reestruturar um sistema, ela propõe esconder o velho código dentro de uma nova camada.

"Slicing"

"Slicing" (fatiar) é uma técnica de decomposição do código de acordo com a utilização das variáveis. O slicing de uma parte do código consiste em extrair dela todas as instruções que têm uma influência sobre o valor de uma variável definida a um ponto definido do código.

Isso pode ajudar na localização de um bug (erro no valor da variável), limitando a pesquisa nas únicas instruções realmente necessárias.

(Re-)Modularização

A (re-)modularização é a decomposição de um conjunto de componentes de software em sub-partes (os módulos). Em engenharia de software, normalmente, se espera que os módulos tenham uma forte coesão interna e um pequeno acoplamento com o exterior.

Essa atividade de agrupar arquivos em sub-sistema não é trivial. Um sistema legado pode ser composto de milhares de arquivos, em várias linguagens de programação (por exemplo: uma linguagem procedural, assembler, dados e alguns "scripts" para compilações e execuções).

Para agrupar os componentes são utilizados algoritmos que "medem as distancias" entre os componentes com base em informações extraídas do sistema.

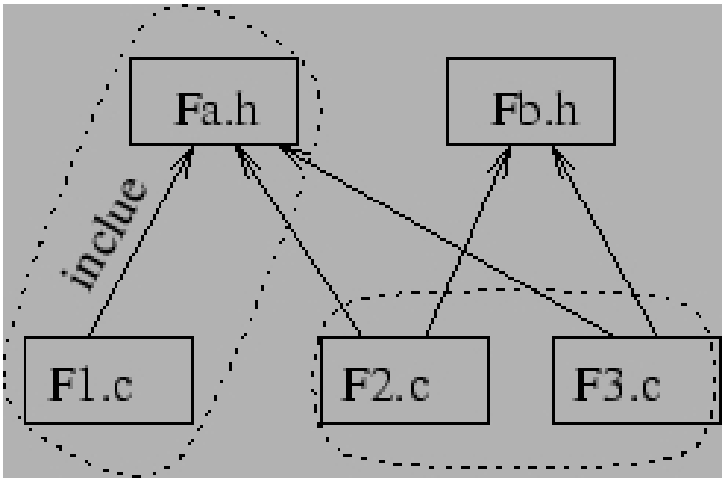

Definição de módulos a partir de informações de inclusão entre arquivos.

Porém eles apresentam dois problemas principais:

- O resultado pode ser difícil de entender;
- Não há nada mágico neles. Eles agrupam todos os componentes segundo algumas restrições. Se as restrições forem erradas, o resultado também será.

O resultado desta técnica é globalmente bom. Mas sempre há detalhes errados em alguns módulos. Esses algoritmos são bons quando existem muitos componentes para tratar e como uma primeira abordagem para desbravar o sistema.

Reconhecimento de Clichés

Um "clichê" é um padrão que descreve uma maneira geral de implementar um conceito de programação. A atividade de reconhecimento de clichês trabalha com um banco de clichês e procura esses clichês no código. A idéia é que um clichê é implementado com várias linhas de código. Reconhecer um clichê pode simplificar o código porque isso vai substituir um só conceito a essas linhas.

O reconhecimento de clichê sofre de várias dificuldades:

- Construção do banco de clichês;
- Dualidade, precisão e cobertura (a descrição do clichê deve ser geral porém corre-se o risco de ocorrerem falso-positivos);
- Tempo de execução;
- Clichês deslocalizados ou interligados (podem existir outras instruções entre as que implementam o clichê ou dois clichês cujas instruções estão misturadas).

4. ASPECTOS LEGAIS

Leis e Acordos

A engenharia reversa pode também gerar problemas de legalidade, como uma empresa querendo criar uma cópia de um produto que vende bem. No entanto a questão legal depende das leis de cada país. E, mesmo assim, ainda existem países que não possuem leis específicas sobre o assunto.

Uma das leis mais conhecidas é o "Digital Millenium Copyright Act" dos Estados Unidos, aprovado em 1998 que, entre várias medidas para proteger direitos autorais na informática, também faz restrições em relação à engenharia reversa. Só é permitida para fins de analisar compatibilidade com outros softwares e/ou hardware.

Na União Européia, o "EU Copyright Directive", de 2001, é similar ao "Digital Millenium Copyright Acts", porém não é tão restritiva. Só são feitas restrições caso o objetivo final da engenharia reversa seja a cópia de algum programa ou quebra de patente com objetivo de lucro. Caso seja pra fins acadêmicos ou de compatibilidade, à princípio não existem restrições.

Na suíça, a lei a respeito do assunto é bastante curiosa e, de certo modo, polemica. A Lei Suíça de Concorrência Desleal de 1986 exige dos competidores a realização de investimentos em engenharia reversa mesmo quando a tecnologia não seja secreta. Os tribunais suíços, porém, têm rejeitado ou limitado severamente a aplicação de tal norma, pela inexistência de prazo e limites.

No Japão, a Lei Japonesa de Concorrência Desleal de 1993 proíbe a imitação servil, mesmo no caso de produtos não patenteados, nem protegidos por direitos autorais. A lei japonesa impõe limites claros à aplicação da norma de apropriação ilícita: o "lead time" vigora apenas por três anos; não se protegem as idéias e os conceitos técnicos; e ressalva-se o caso de modificações ou aperfeiçoamento técnico efetuado pelo competidor com base no item copiado; a necessidade de padronização e compatibilização de produtos e o uso de elementos de caráter estritamente funcional. Ou seja, a proibição de imitação não impede o progresso técnico, ressalva o domínio das patentes para proteger idéias e conceitos, e o interesse social na padronização e compatibilização industrial.

No Brasil, não existe uma lei específica sobre Engenharia Reversa. Apesar disso, quando ocorre engenharia reversa, costuma-se proceder de duas maneiras: caso a engenharia reversa não tenha como objetivo a pirataria ou infração de algum direito autoral, não é considerado crime; porém caso contrário, a Lei de Software e também de Direitos Autorais protege seus autores.

Alguns Casos Famosos

Apesar dessas leis, os problemas legais relacionados à engenharia reversa são bastante comuns e difíceis de serem resolvidos.

Na Noruega (um dos países que permitem engenharia reversa) Jon Johansen, um jovem de 16 anos, desenvolveu um programa capaz de fazer um computador com Linux exibir um filme em DVD.

O que Jon e alguns colaboradores fizeram foi descobrir que uma das empresas, a Xing Technologies, subsidiária da RealNetworks, não mantinha chaves criptografadas. Eles entraram no site da empresa, pegaram as chaves e simplesmente olharam como elas funcionavam. É como uma espécie de quebra-cabeças, onde o que precisa ser feito é estabelecer correlações entre símbolos. A chave criptográfica do DVD tem a extensão de cinco bytes, o que torna a matemática envolvida nisso bem simples. Como as outras chaves das empresas concorrentes também são parecidas, ele ainda adivinhou algumas chaves diferentes das da Xing. Isso faz com que o Decoded-CSS, nome dado ao seu programa, possa rastrear uma chave adequada entre algumas que ele entende, ou seja, mesmo que os discos de DVD daqui para frente não possuam a chave Xing, o programa ainda funcionará.

Ele foi acusado de "facilitar a pirataria". Segundo os advogados que o acusam, Jon teria criado um software que permite aos usuários fazer e distribuir cópias digitais de filmes em DVD. Seu programa permitiria que o arquivo que contém o filme fosse copiado por um microcomputador caseiro. Jon está sendo processado por autoridades norueguesas do DOEC (Departamento Norueguês de Crimes Econômicos) e pela MPAA (Motion Pictures Association of America), entidade que representa as sete maiores distribuidoras de filmes nos EUA: Universal City Studios lnc, Paramount Pictures Corporation, Metro-Goldwin-Mayer Studios lnc, Tristar Pictures lnc, Columbia Pictures lnc, Time Warner Entertainment Co., Disney Enterprises lnc. e Twentieth Century Fox Film Co.

O caso Lotus Development Corp. vs. Borland International foi uma disputa judicial entre duas empresas produtoras de Software. A Lotus produzia o Lotus 1-2-3, e a Borland, o Quattro Pro. A Borland produziu seu programa de computador com a interface idêntica ao da Lotus, de maneira que os usuários da Lotus 1-2-3 pudessem usar o Quattro Pro sem dificuldades. A Lotus entrou com ação em face da Borland por infração de Copyright. Grande parte da controvérsia foi a respeito da possibilidade de se proteger pelo direto do autor a mera interface do programa. Por fim a decisão final achou "absurdo" sugerir que "se alguém faz uso de vários programas diferentes, seja forçado a aprender como efetuar cada a mesma operação de maneiras diferentes em cada programa utilizado". A corte decidiu que, se uma empresa atinge um monopólio, por conseqüência a maioria do mercado fica bem adaptada à interface de seu programa. Desse modo, é justo que um competidor utilize a mesma interface como meio de concorrência.

5. Bibliografia

Nicolas Anquetil Homepage

http://www.ucb.br/ucbtic/mgcti/paginapessoalprof/Nicolas/Disciplinas/RevEng/index.html

Wikipedia

www.wikipedia.org

DVD e Linux: liberdade na era digital

http://www.comciencia.br/reportagens/softliv/softliv1.html

Limitações ao direito do autor na lei brasileira, cópia privada e engenharia reversa de software

http://www.direitonet.com.br/artigos/x/19/08/1908/

Implementing the EU Copyright Directive

www.fipr.org/copyright/guide/eucd-guide.pdf

The Digital Milllenium Copyright Act of 1998

www.copyright.gov/legislation/dmca.pdf