




unCaptcha

A LOW-RESOURCE DEFEAT OF RECAPTCHA'S ÁUDIO CHALLENGE

ALUNO: PATRIK BEDIN SCHETTERT

O que é CAPTCHA?


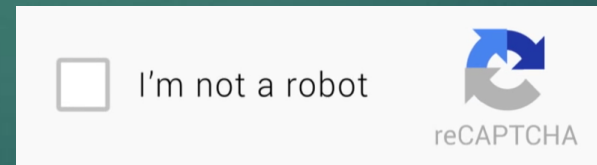


O que é CAPTCHA?

- ▶ Completely Automated Public Turing tests to tell Computers and Humans Apart
- ▶ Sistema de segurança utilizado para proteger contra criação de contas automatizada e abuso de serviço
- ▶ Funciona a partir de desafios lançados ao usuário(fácil para humanos mas difícil para computadores)
- ▶ Bots e Sybil attacks
- ▶ Plataformas exigem a resolução de um captcha para criação de registro.
- ▶ Burlar sistemas de captchas pode teoricamente permitir o controle de fluxo de informações em massa
- ▶ Devido a sua importância, esse sistema tem sido alvo de ataques por anos

Tipos de CAPTCHA


- ▶ Texto retorcido (2009- 2014)
 - ▶ Utilizados até hoje
 - ▶ Provados serem inseguros (98% de eficácia na resolução)
- ▶ Imagem (2014 – atualmente)
 - ▶ Em substituição aos de texto retorcido



Tipos de CAPTCHA

▶ Audio

- ▶ Especialmente desenvolvido para usuários com algum tipo de deficiência visual
- ▶ Diferentes narradores, dizendo letras ou dígitos em intervalos randômicos, a velocidades variáveis, geralmente com sotaque ou distorção adicionada.



Tentativas de burlar áudio CAPTCHA

- ▶ Geralmente, ataques a áudio captchas são realizados por meio de modelos de aprendizado de máquina treinados para identificar as palavras faladas (alta utilização de recursos e tempo)
- ▶ Serviços de reconhecimento de voz, como Sphinx ou Google Speech Recognition (não são precisos o suficiente para resolver os captchas).
- ▶ unCaptcha – sistema automatizado de ataque ao Google reCaptcha 2017, utilizando serviços públicos de reconhecimento de voz e realizando mapeamento fonético para aumentar a precisão.

Ataques já realizados

- ▶ Kochanski et al. Investigou a segurança dos captchas e concluiu que os humanos tem grande superioridade no reconhecimento de áudio captchas, se comparados a sistemas de reconhecimento de voz automáticos, quando ruído é adicionado ao dígitos
- ▶ Primeiras tentativas (burlas Google e Yahoo) – tática de resolver em duas fases
 - ▶ Primeiramente são extraídos porções que contém os dígitos
 - ▶ Em sequencia cada digito é classificado individualmente por algoritmos de aprendizado de máquina previamente treinados

Ataques já realizados

- ▶ Decaptcha eBay (2012) – análise dos picos de energia do áudio para separação de dígitos
 - ▶ Utilizava algoritmo de aprendizado supervisionado e um grande banco de dados de captchas do eBay
 - ▶ Acurácia de 75%
 - ▶ São necessários muitos recursos computacionais(núcleos, largura de banda, endereços IP, etc...). 10% de sucesso em baixo/médio disponibilidade de recursos
- ▶ Defcon group reCaptcha (2012)
 - ▶ Rede neural local treinada
 - ▶ Acurácia de 99%
 - ▶ Google atualizou o sistema trocando palavras para dígitos, adicionando ruído e variando o número de dígitos (61% de acurácia)
 - ▶ Limitação era o fato de precisar de gigabytes de dados para o treinamento
 - ▶ 2016 uma nova abordagem utilizava o próprio reconhecimento de voz do google para resolver os captchas.
 - ▶ 2017 atualização recaptcha adicionou mais dígitos (10) e ruído de fundo em cada dígito, inviabilizando o método anterior.

Modelo de ameaça

- ▶ A maioria das tentativas de ataque consideram que o atacante possui bastante recurso
- ▶ Várias tentativas são efetuadas para um numero pequeno de acertos
- ▶ Isso em grande escala pode ser utilizado para abusar de serviços
- ▶ A acurácia suficiente para um ataque depende do numero de recursos
 - ▶ 1/10000 é suficiente para atacantes com muitos recursos
 - ▶ Para poucos recursos é considerado uma acurácia superior a 50%
 - ▶ unCaptcha considera apenas um computador, um IP, pouca memoria RAM e dados de treinamento limitados.

Funcionamento do reCaptcha

- ▶ Trabalha utilizando uma engine de análise de riscos
- ▶ Utiliza o conceito de “nível de suspeita” determinado por meio de interações do usuário (cliques de botão e digitação).
- ▶ noCaptcha reCaptcha – quando o sistema é confiante que o usuário é humano
- ▶ Os desafios são nivelados de acordo com a suspeita do usuário.
- ▶ A suspeita é avaliada a partir do histórico de interação com serviços do Google.
- ▶ Harder challenge – 10 dígitos ou vários desafios com imagem.
- ▶ Google mantém em segredo como o sistema funciona.
- ▶ Roda em de forma criptografada, em uma VM isolada, utilizando JS e uma linguagem de bytecode única.

Funcionamento do reCaptcha


- ▶ O bytecode tem acesso as variáveis JS do seu próprio interpretador
- ▶ A chave decriptografia é alterada em diversos pontos durante a própria execução
- ▶ Um disassembler e descompilador foi desenvolvido e determinou que o captcha verifica a presença de:
 - ▶ Plugins válidos
 - ▶ String de user-agente válida
 - ▶ Resolução de tela válida
 - ▶ Tempo de execução
 - ▶ Teclado
 - ▶ Fuso horário
 - ▶ Cookies do servidor
 - ▶ Ações de toque no frame do captcha
 - ▶ Numero de cliques
 - ▶ Funções do navegador e regras de CSS
 - ▶ Propriedades de renderização do canvas

Funcionamento do reCaptcha

- ▶ Em 2016 Sivakorn et al. Explorou fraquezas do sistema de captcha por imagem da Google.
- ▶ Foi descoberto que os tracking cookies da Google executavam um papel fundamental na defesa do captcha
- ▶ O sistema é ciente de todas as vezes que o usuário interage com um serviço do Google.
- ▶ Utilizando dessa informação, um sistema automatizado navegando por 9 dias por diferentes serviços do Google conseguiu enganar o sistemas de risco do captcha.
- ▶ Cada cookie pode completar automaticamente apenas 8 captchas por dia
- ▶ Tentativa de identificar bot antes do captcha. Problema com o desafio de áudio.

unCaptcha - Etapas

- ▶ Obter a amostra de áudio
- ▶ Segmentar o áudio partes menores (dígitos)
- ▶ Analisar cada segmento de áudio
- ▶ Inserir a solução do captcha




Adquirindo audio

- ▶ reCaptcha utiliza múltiplas heurísticas para distinguir humanos de bots (navegador, headless browser, checagem de javascript, etc)
- ▶ Entre elas esta a verificação de movimentos de mouse e teclado “inorgânicos” (alta velocidade, linha reta)
- ▶ Passos realizados no site Reddit:
 - ▶ Selenium (software de automação do navegador
 - ▶ unCaptcha procura um proxy HTTP para mascarar a conexão (Gather Proxy)
 - ▶ Navega até a pagina de cadastro, digita os dados com valores randômicos e espaço de tempo variável entre cada tecla.
 - ▶ Localiza o botão “Im not a robot” e clica nele
 - ▶ Bot modifica para “Audio challenge”, faz o download do arquivo de áudio, e clica no botão de play para simular um usuário.


Pre-processamento

- ▶ Segmentação do áudio em partes menores
- ▶ reCaptcha possui distorções no áudio de cada segmento
- ▶ Isso facilita a separação dos dígitos
- ▶ unCaptcha simplesmente divide o áudio em períodos de silêncio utilizando análise de amplitude.




Analizando o audio

- ▶ Faz uso de ferramentas de reconhecimento de voz online existentes, com adição de mapeamento fonético e *essembling*.
- ▶ Serviços de conhecimento de voz
 - ▶ unCaptcha faz upload de cada dígito para um conjunto de serviços de reconhecimento de voz(Google Cloud, Bing Speech Recognition, IBM Bluemix, Google Speech API, Wit-AI e Sphinx.
 - ▶ Cada um dos serviços retorna um candidato de texto transcrito.
 - ▶ Problema com confusão entre palavras e dígitos.




Mapeamento fonético

- ▶ Duas camadas : homófonos e quase-homófonos
 - ▶ Homófonos
 - ▶ Camada utilizada para mapear erros comuns dos sistemas de reconhecimento de voz para seus respectivos dígitos numéricos.
Exemplo: to/too -> 2 for/fore -> 4.
 - ▶ Além disso, geralmente os dígitos são escritos por extenso, tendo sido mapeados os 10 dígitos para sua forma numérica
Exemplo: four ao invés de 4




Mapeamento fonético

- ▶ Duas camadas : homófonos e quase-homófonos
 - ▶ Quase-homófonos
 - ▶ Camada utilizada para corrigir erros afetados pela distorção, sotaque acentuado e pequenos segmentos de áudio
 - ▶ Mapeamento baseado em heurística
 - ▶ Foram adicionados manualmente 36 quase-homófonos, resultando em uma acurácia maior que 50%
 - Exemplo: free -> 3 sex -> 6 mine -> 9.
 - ▶ Adicionadas correspondências parciais
 - Palavras terminadas em "icks" -> 6; "ee" -> 3;
 - ▶ Ao todo compreende 129 homófonos, quase-homófonos e correspondências parciais
 - ▶ Utilizado análise estatística para melhorar a identificação de outros mapeamentos
 - ▶ "you know" -> 0 (melhorou a taxa de sucesso em 0.6%)



Essembling

- ▶ Cada candidato a resposta recebe um voto com determinado peso. A resposta com maior peso vence.
- ▶ Esse peso é atribuído de duas formas:
 - ▶ De acordo com o serviço de reconhecimento de fala(alguns são mais precisos do que outros)
 - ▶ Baseado na similaridade fonética de palavras específicas
 - ▶ Exemplos: "fine" -> 5 ou 9; "brain" -> 9; "we" -> "3"; "they've" -> 8
 - ▶ Too ou for -> 2 ou 4
- ▶ Essas alterações aumentaram a acurácia para mais de 65%



Precisão por dígito

Service	Per-digit Accuracy		Captcha Success
	Base	+ Mapping	
Google Cloud	55.55%	55.81%	2.61%
Wit	48.01%	64.45%	8.06%
Bing	44.12%	66.65%	10.39%
IBM	31.62%	62.67%	6.50%
Google	21.25%	28.10%	0.01%
Sphinx	6.64%	31.88%	0.02%


Precisão antes e depois de realizar o mapeamento fonético (desafio de 10 dígitos).

Benefícios do “ensembling”

<i>N</i>	Best Ensemble of <i>N</i> Services	Per-digit Accuracy	Captcha Success
1	Google Cloud	55.81%	2.19%
2	Bing + IBM	82.87%	47.26%
3	+ Google Cloud	88.25%	66.96%
4	+ Wit	91.36%	78.12%
5	+ Sphinx	91.93%	80.09%
6	+ Google	91.99%	80.31%
	+ “X” $\mapsto$ “6”	93.41%	85.15%


Benefício de considerar vários serviços de reconhecimento de voz, após efetuado o mapeamento fonético.

Desempenho do unCaptcha




Distribuição dos dígitos recebidos pelo reCaptcha(praticamente uniforme).

Precisão do número “6”



(a) Without mapping unknowns to “6”.



(b) With mapping unknowns to “6”.

- Considerar todos os números não classificados “X” como 6 aumento a precisão de 91.99% para 93.41%
- Além disso, a taxa de sucesso aumentou de 80.31% para 85.15%
- Uma fraqueza identificada é o fato de poder solicitar quantos desafios quiser, até obter maior confiança na solução.

Matriz de confusão com “essembly” de 6 serviços e mapeamento fonético

Velocidade de resolução

- ▶ De forma serial – em média 22.24 segundos
- ▶ De forma paralela- cerca de 5.42 segundos (desvio padrão 1.25seg)
- ▶ A duração do áudio do captcha dura em média 19.13 segundos(desvio padrão de 2.39seg)
- ▶ Foi permitido inserir a solução antes mesmo de ouvir a mensagem.
- ▶ unCaptcha resolve em média com 28.3% do tempo que um humano levaria para solucionar.

Tempo de resposta dos serviços



Service	API Limits
Google	60 minutes/month
Google Cloud	60 minutes/month
Bing	5,000 queries/month
IBM	1,000 minutes/month
Sphinx	None
Wit	None

Limites de uso para usuário Free

- ▶ Em média 2.95 segundos(desvio padrão de 1.99seg).
- ▶ Depois de ultrapassar o limite o usuário deve entrar com uma nova conta ou pagar.
- ▶ Ironicamente, a criação de contas é protegida por um reCaptcha contra registro por bots.



Estimativa do tamanho da biblioteca



- ▶ Durante os teste, foi verificado um numero significativo de dígitos.
- ▶ Se a biblioteca de dígitos for pequena, o atacante pode baixar todos os possíveis dígitos, classifica-los e automaticamente comparar com os dígitos de um captcha não resolvido.
- ▶ Para estimar o número de duplicações foram analisados os coeficientes mel-cepstrais do sinal (MFCC).
- ▶ Foi estimado que o Google armazera aproximadamente 3600 arquivos por dígito, selecionamento de forma aleatória cada um na geração do captcha
- ▶ Ao todo estima-se que a biblioteca possua 36500 dígitos.

Digit	Duplication Rate (%)	
0	40 / 408	(9.80%)
1	56 / 456	(12.28%)
2	65 / 442	(14.71%)
3	49 / 463	(10.58%)
4	68 / 468	(14.53%)
5	66 / 463	(14.25%)
6	58 / 452	(12.83%)
7	67 / 466	(14.38%)
8	51 / 482	(10.58%)
9	62 / 490	(12.65%)
Total	582 / 4590	(12.68%)

Ataque offline

- ▶ Sistemas de reconhecimento poderiam reconhecer os cliques de áudio do captcha e recusar-se ou transcrever de forma errada.
- ▶ O atacante poderia, antes de fazer upload, alterar o áudio com distorção ou filtro para que não fosse reconhecido como áudio de captcha
- ▶ Solução local se considerar internet limitada ou defesa desse tipo de serviço.
- ▶ Utilizou-se MFCC para comparação entre os segmentos de sons dos dígitos.
- ▶ Para reconhecer um som, os MFCCs são computados para um determinado som e para uma pequena biblioteca de “sons de exemplo”.
- ▶ Utilizando Dynamic Time Warping(DTW) são comparados os coeficientes da amostra com o do banco de dados.

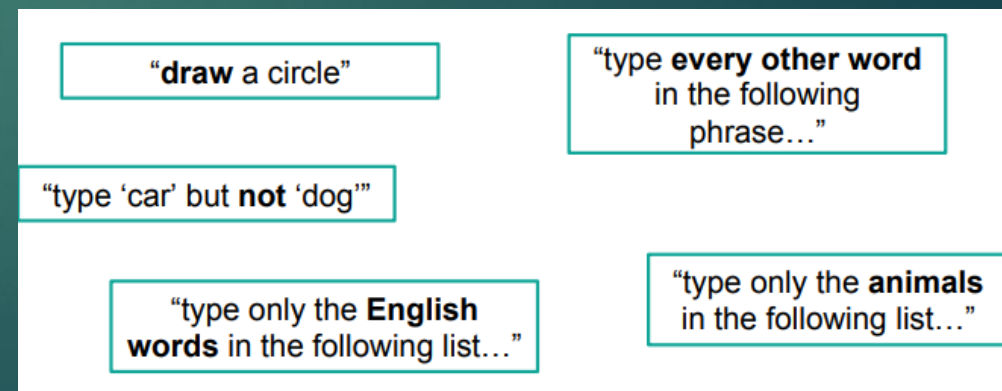


Ataque offline



- São selecionados exemplos de controle de captchas resolvidos manualmente.
- Foram testados conjuntos de 5 a 250 exemplos de cada dígito.
- Com 250 exemplos foi alcançada uma taxa de sucesso de 51%
- O tempo de resolução é de 29.26 seg(4 segundos mais lentos que o ataque online)

Melhorias possíveis

- ▶ Utilizar não apenas dígitos nos áudios do captcha, mas também palavras. Apenas 10 elementos torna fácil até para algoritmos de reconhecimento off-line decifrarem.
- ▶ Adicionar distorção – pode tornar a segmentação mais difícil, porém precisa ser quieto para que não atrapalhe o reconhecimento do usuário(pode ser contornado com filtros passa-baixa)
- ▶ Utilizar frases conhecidas para que humanos decifrem pelo contexto(pode ser quebrada pelo avanço de redes neurais)
- ▶ Instruções por áudio como “digite uma palavra, “mova o mouse para cima”, “escreva essa palavra e não essa outra”. Adiciona uma camada ao desafio.



Conclusão

- ▶ 450 captchas foram solucionados com 85% de precisão
- ▶ Foi relativamente fácil quebrar o áudio captcha, utilizando-se de poucos recursos.
- ▶ Isso implica que as centenas de serviços que utilizando o Google reCaptch estão vulneráveis a criação de contas por bots e ao abuso de serviço.