


Zgostitveni algoritmi in zagotavljanje integritete (istovetnosti) digitalnih dokazov



Matej Kovačič

(CC) 2012

Delo je izdano pod Creative Commons licenco: "Priznanje avtorstva-Nekomercialno-Deljenje pod enakimi pogoji 2.5 Slovenija". Celotno pravno besedilo licence je dostopno na spletni strani: <http://creativecommons.org/licenses/by-nc-ša/2.5/si/legalcode>, ali na poštnem naslovu: Inštitut za intelektualno lastnino, Čufarjeva ulica 17, 1000 Ljubljana.


Slike: (CC) OpenClipArt.org, Matej Kovačič (osebni arhiv) in navedeni avtorji (C).

Forenzični zaseg podatkov

- Cilj forenzičnega zasega je zagotoviti, da bodo zajeti podatki ohranili integriteto (istovetnost) in s tem **dokazno vrednost** na sodišču.
 - Vprašanje lastništva podatkov.
 - Vprašanje zasebnosti (tudi na delovnem mestu).
 - Varstvo osebnih podatkov.
 - Varstvo tajnih podatkov.
 - Odločba ustavnega sodišča Up-106/05 -> ZKP-J.
 - **Zagotavljanje integritete zajetih podatkov.**
 - Varstvo zajetih podatkov.

Integriteta / istovetnost digitalnih podatkov

- Istovetnost podatkov na celotnem nosilcu podatkov (disk, USB ključek,...) - vključuje tudi tim. “prazen prostor”.
- Istovetnost podatkov na particiji (razdelku) - vključuje tudi tim. “prazen prostor”.
- Istovetnost vsebine (in metapodatkov) datoteke – ne pa tudi imena datoteke.
- Kopiranje slike (ang. *image*) nosilca podatkov ali razdelka.



Nosilci podatkov, razdelki, datotečni sistemi...

- Nosilec podatkov (disk,...)

- Disk0, Disk1,...
- /dev/hda, /dev/sda

- Razdelki (particije):

- C:, D:,...
- /dev/hda1, /dev/sda1

- posamezen nosilec podatkov lahko vsebuje en sam razdelek;
- posamezen nosilec podatkov je lahko razdeljen na več razdelkov;
- posamezen razdelek se lahko razteza čez več nosilec podatkov;

- Datotečni sistem:

- FAT, NTFS, ext3, ext4, ReiserFS, zfs...

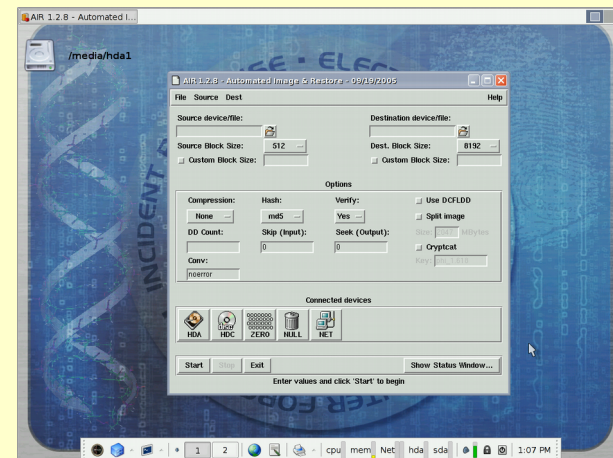
- Skriti deli diskov:

- Host Protected Area, definiran s ATA-4 standardom leta 1998.
- Device Configuration Overlay, definiran s ATA-6 standardom leta 2002.



Postopek forenzičnega kopiranja nosilca podatkov ali razdelka

- Priklop nosilca podatkov v posebno napravo ali prilagojen računalnik (strojno onemogočanje pisanja s posebnimi kabli ali vmesniki).
- Delna rešitev: uporaba živega CD-ja, ki ne priklaplja swap razdelka (npr. Helix forenzični živi CD).
- Razdelka **ne priklapljamo v sistem**, pač pa kopiramo sliko razdelka (*image*) in **kasneje** forenzično obdelamo to sliko.



AIR Imager – programski zaseg podatkov



Forensic Bridge, vir in avtorstvo: Tableau.com

Zakaj? Zato.

datotečni sistem	bralni način	pisalni način
FAT16	✓	✓
FAT32	✓	✓
NTFS	✓	*
ext2	✓	*
ext3	✓	*
ReiserFS	*	*

✓ - do spremembe ne pride

* - do spremembe pride!

Pri datotečnem sistemu NTFS pride do spremembe šele ko podatke preberemo iz za pisanje priključenega diska.

Zgostitveni algoritmi

- Zgostitveni algoritmi (ang. *hash algorithms*, včasih tudi *hash values*, *hash codes*, *hash sums*, *checksums*, *message digests* ali *fingerprints*): poljubno dolg niz znakov preslikajo v število fiksne dolžine.
- Izračunajo tim. prstni odtis (ang. *fingerprint*) oz. kontrolno vsoto (*hash*) tega niza znakov, kar je osnova za digitalni podpis oziroma za **zagotovilo, da so podatki ohranili integriteto.**

Zgostitveni algoritmi

- Primeri zgostitvenih algoritmov: MD5, SHA-1, SHA-0, SHA-1, SHA-256, SHA-512, WHIRLPOOL...

- MD5:

75222cee3990e39e9fb48fa7ca6a733b

- SHA-1:

1f149834675ab2ae6d076ee3cbaa9158b6864ee1

- SHA-256:

3226338fb2c35ca40d39de77a0735779b1c0886f39a3762de2b502901567d39e



e9a23cbc455158951716b440c3d165e0



c7931bbead86523571b02d5cf795a79d

Zgostitveni algoritmi

- Zgostitveni algoritmi morajo biti:
 - enosmerni (iz kontrolne vsote ni mogoče nazaj izračunati originalnih podatkov),
 - (v praksi) ne sme priti do kolizije (ne smeta obstajati dva različna niza podatkov, ki bi vrnila isto kontrolno vsoto; to je sicer odvisno od bitnosti hasha).
- Dobri zgostitveni algoritmi imajo tim. “avalanche efekt” - če se vhod malenkost spremeni, se bo izhod drastično spremenil.

Uporaba

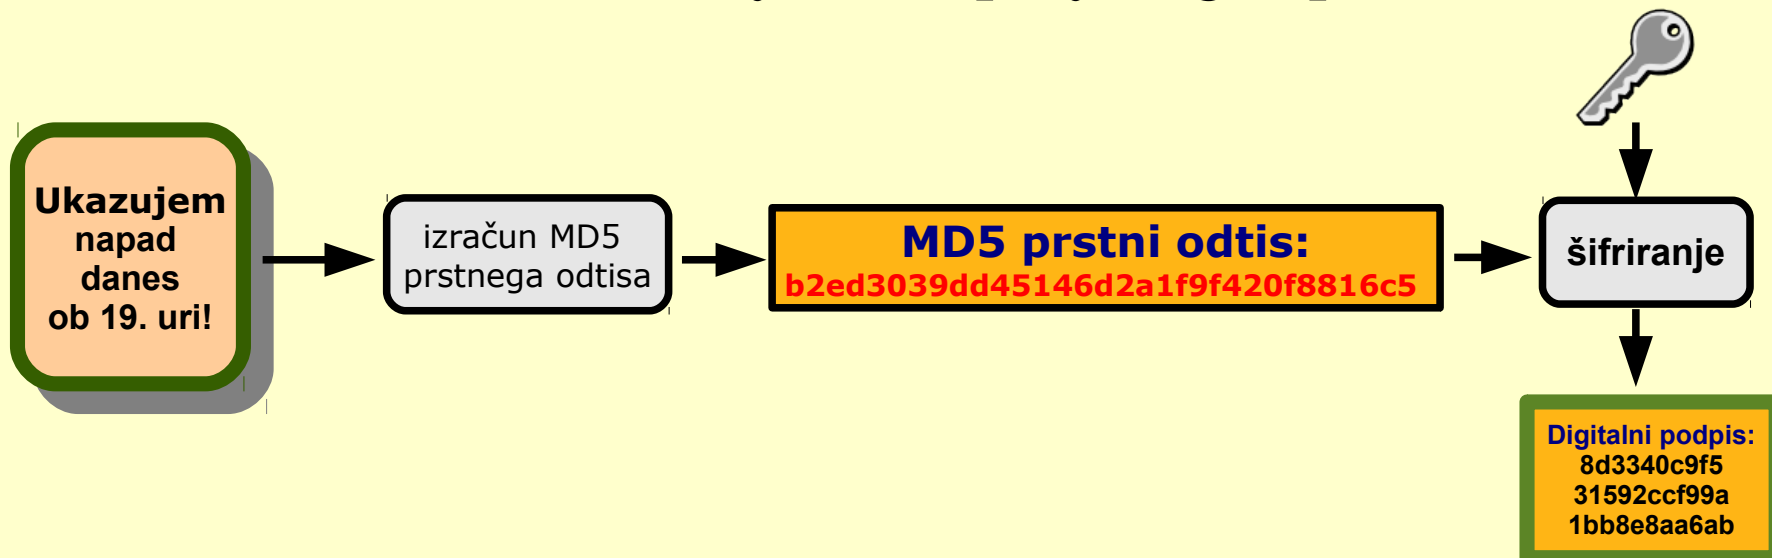
- Za zaščito gesel (hramba v hash obliki);
- kot pseudonaključni generator števil, pri generiranju naključnih imen datotek (npr. http://www.dnevnik.si/uploads/image_cache/305d4e28924252f4251b2baadb6dbc6a.jpeg);
- za preverjanje integritete pri prenosu datotek (npr. v P2P omrežjih);
- za preverjanje integritete arhivskih datotek (tim. *checksum*; npr. orodje Tripwire);
- pri implementaciji digitalnega podpisa, časovnega žigosanja, overovitvi certifikatov s strani CA;

Uporaba

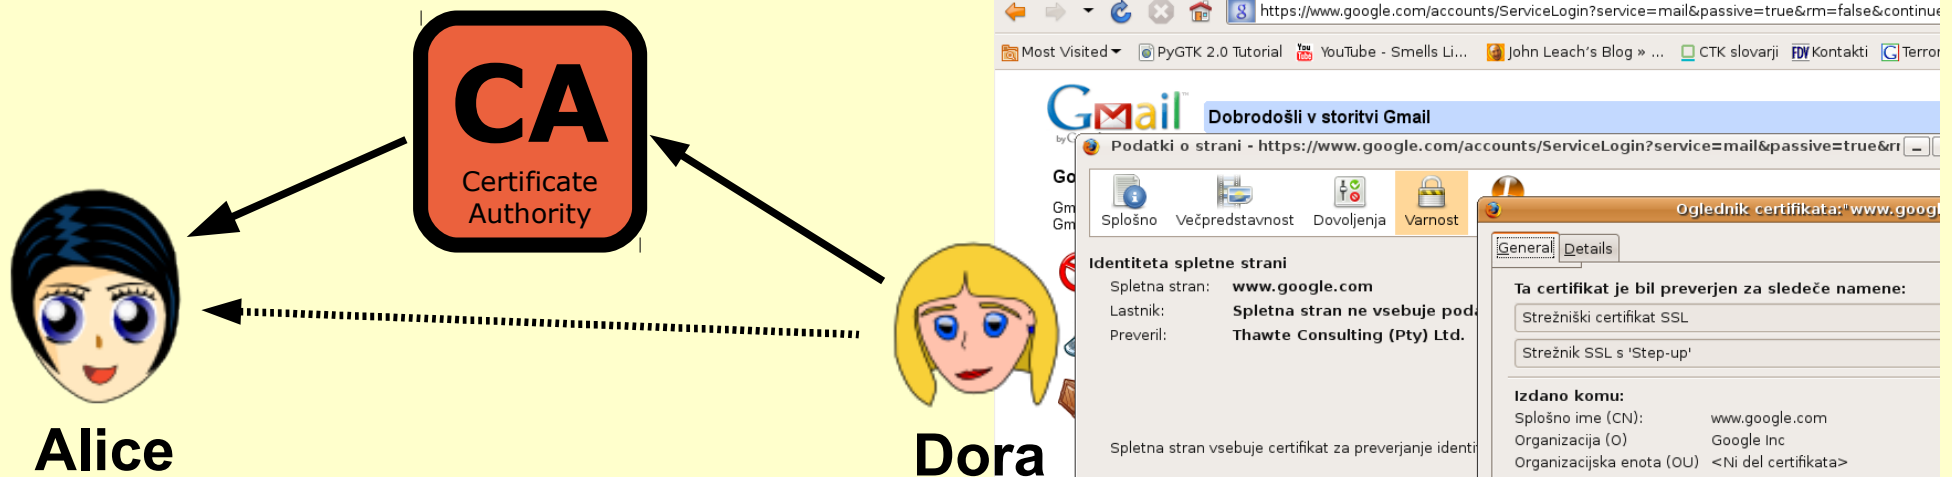
- za digitalno podpisovanje datotek, npr. gonilnikov;
- za zagotavljanje integritete podatkov pri digitalni forenziki;
- za prepoznavanje datotek (npr. pri antivirusnem programju, znanih “slabih” in znanih “dobrih” datotek v digitalni forenziki: , NSRL hash set (*National Software Reference Library*), HashKeeper,...).

Digitalni podpis

- Digitalni podpis zagotavlja integriteto sporočila (da se vsebina sporočila ni spremenila med prenosom). Pošiljatelj kontrolno vsoto sporočila zašifrira s svojim šifrirnim ključem.
- Prejemnik kontrolno vsoto dešifrira ter jo primerja s kontrolno vsoto dejansko prejetega sporočila.




Overovitev ključev (PKI – Public Key Infrastructure)



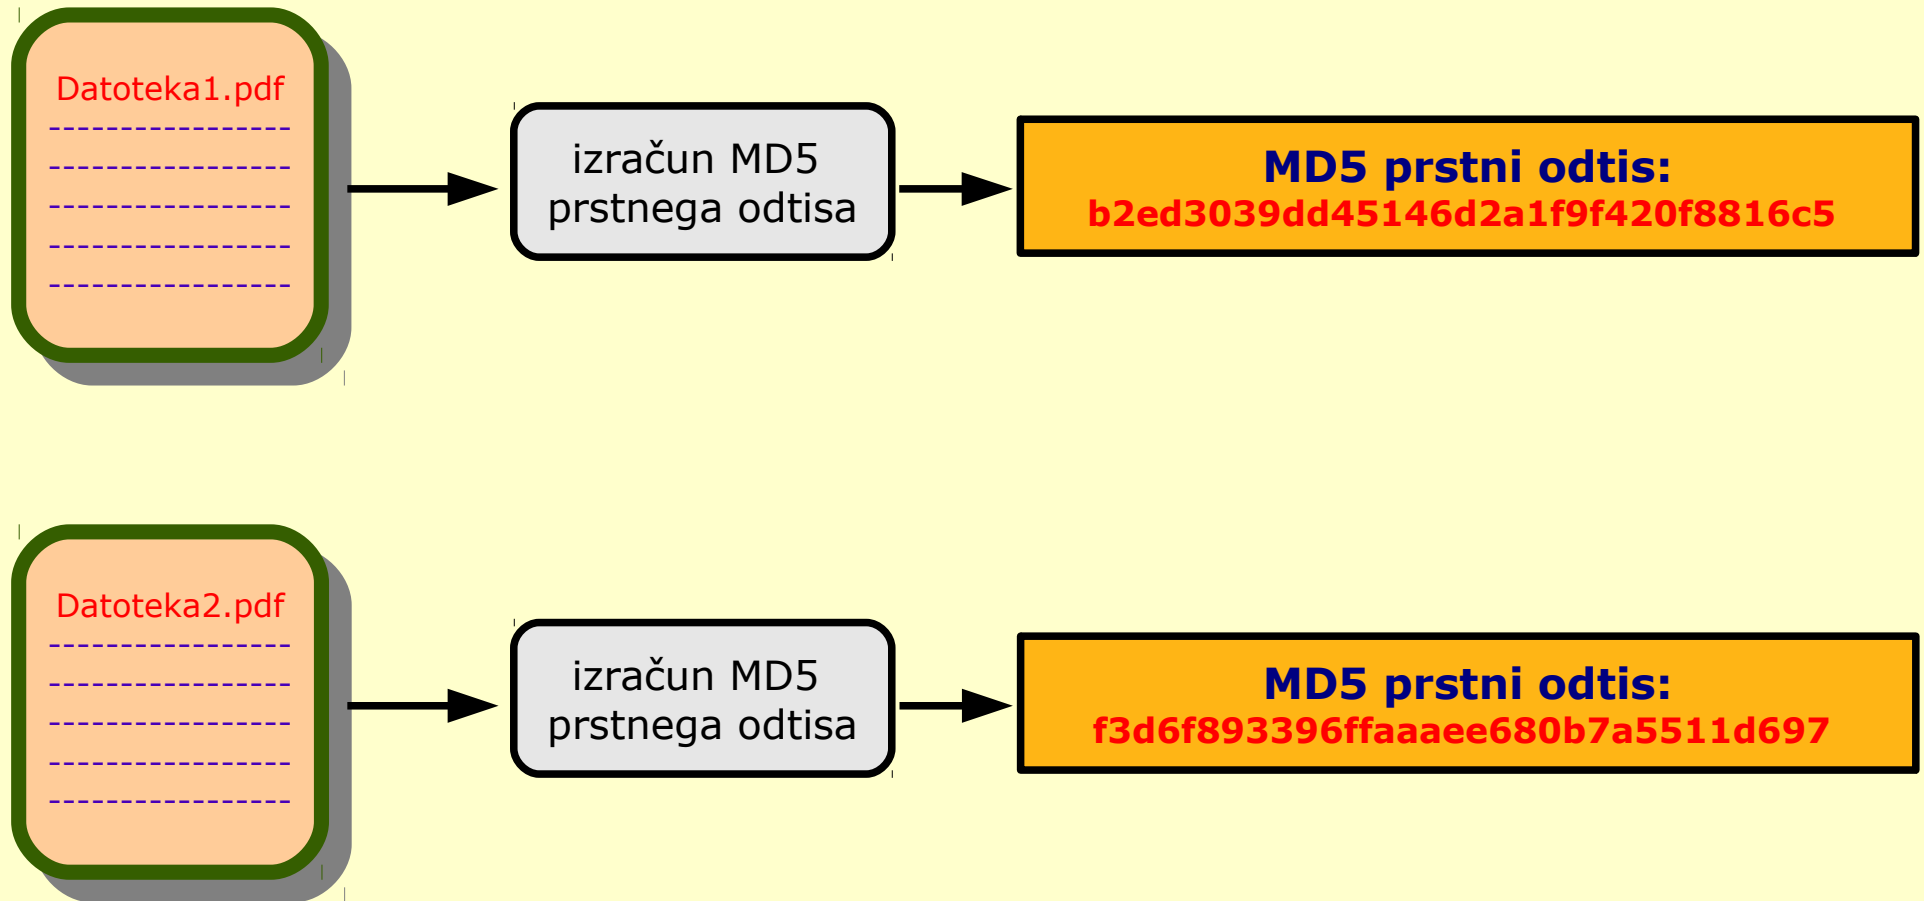
- CA je preveril identiteto in nato digitalno podpisal njen ključ.
- Dora zaupa, da ključ res pripada Alice, ker zaupa CA.

Časovno žigosanje

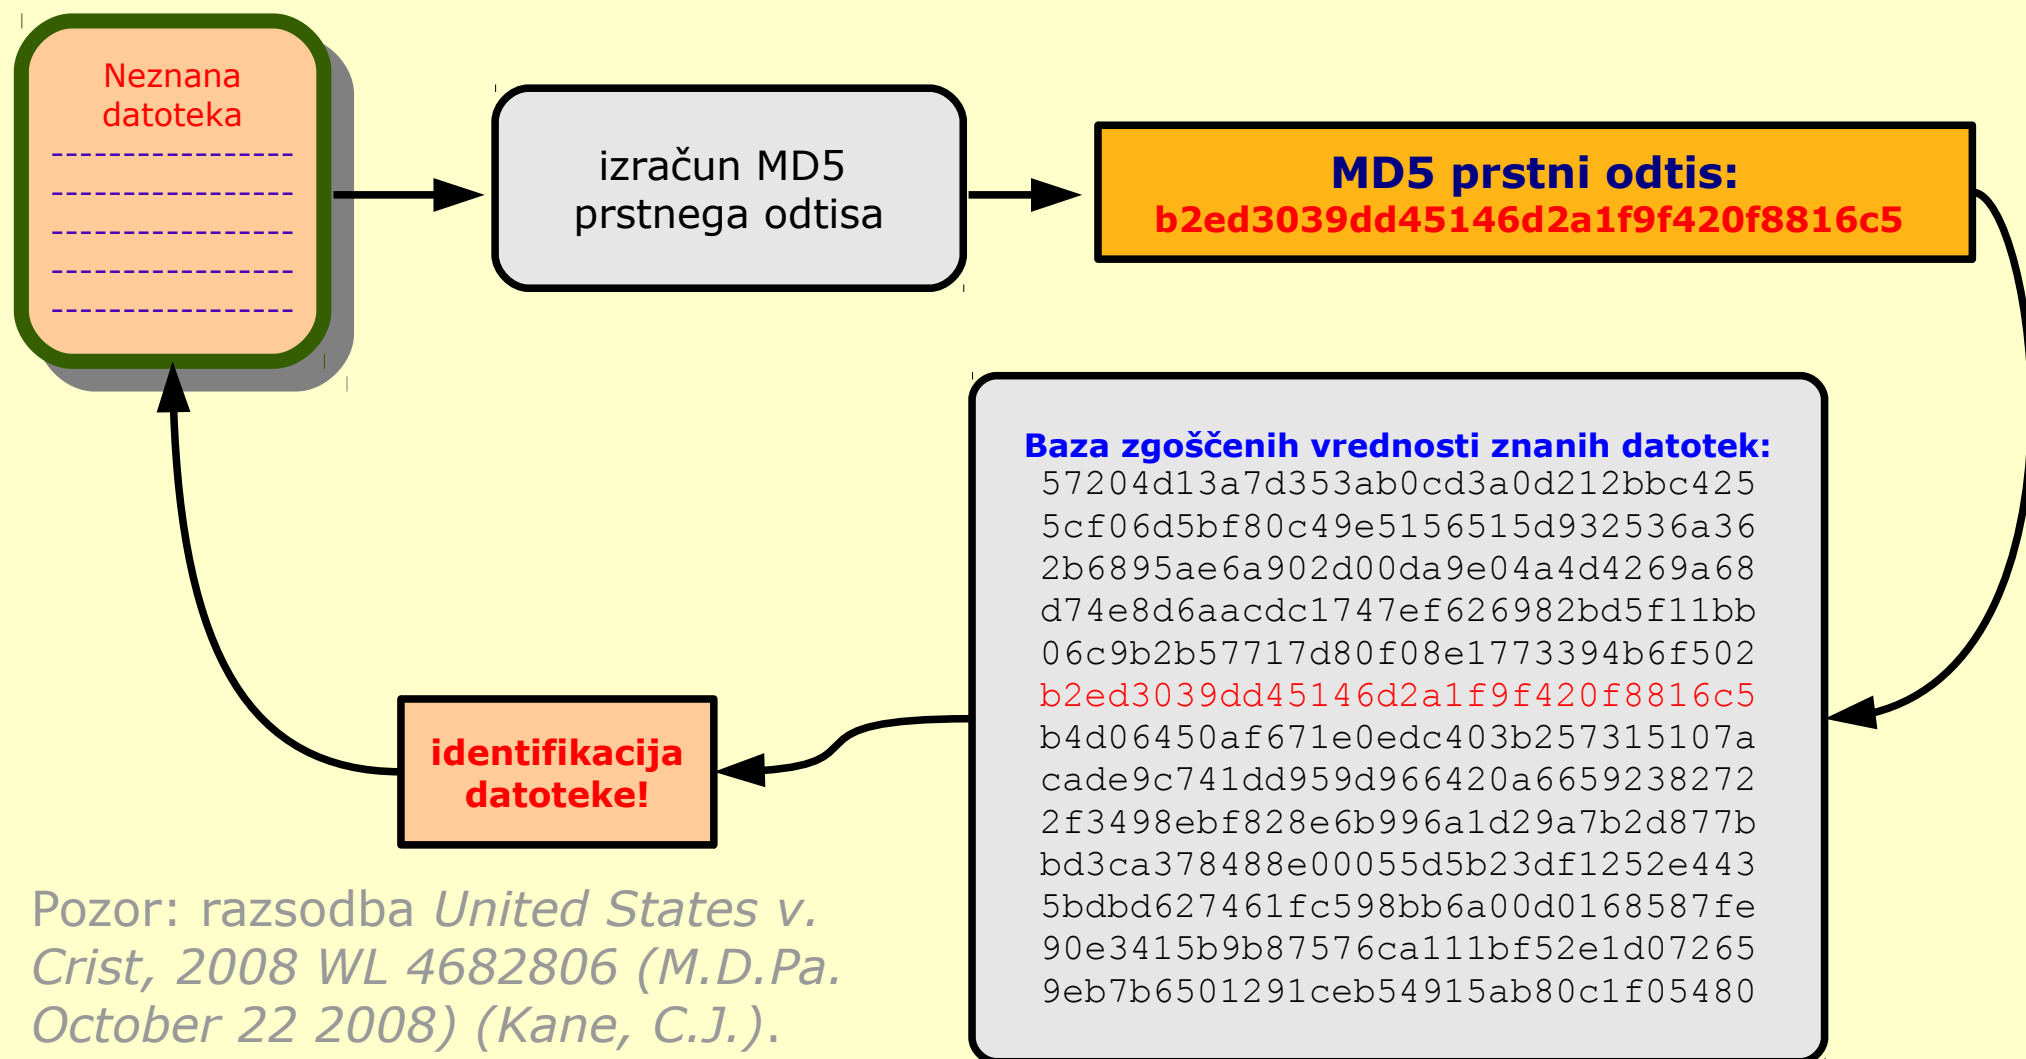
- TSA - *Time Stamping Authority*, poseben zaupanja vreden strežnik, ki kontrolni vsoti dokumenta doda podatek o času nastanka in nato oba podatka digitalno podpiše.
- Časovno žigosanje omogoča preverjanje časa nastanka (oz. žigosanja) danega dokumenta, časovnega žiga pa ne more spremeniti niti lastnik dokumenta.
- OpenTSA.



Identifikacija datotek

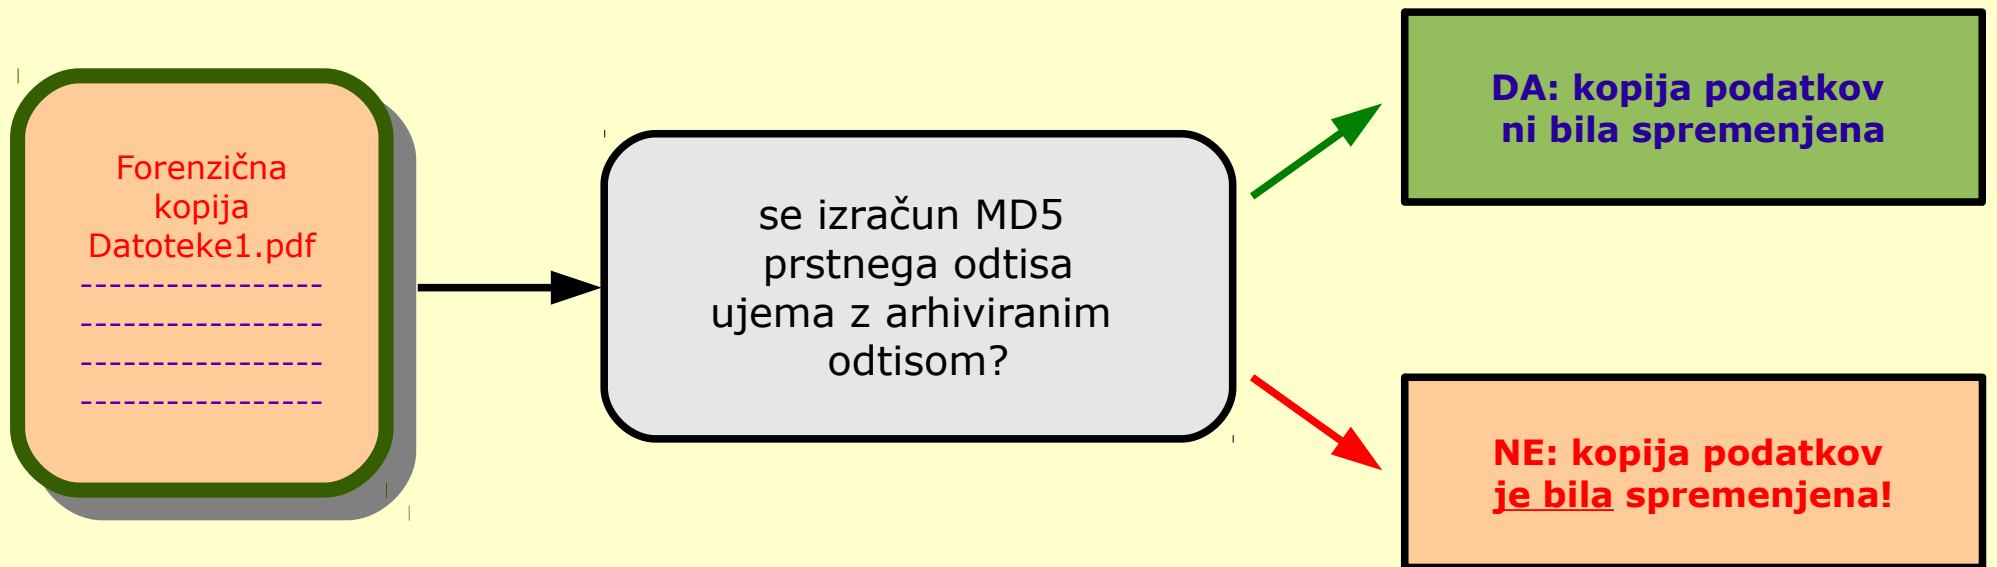


Identifikacija datotek



Pozor: rzsodba *United States v. Crist*, 2008 WL 4682806 (M.D.Pa. October 22 2008) (Kane, C.J.).

Zagotavljanje integritete podatkov



Enosmernost?

Mavrične table in predizračunane tabele zgoščenih vrednosti

The image shows two browser windows. The left window displays a list of MD5 hashes from a Pastebin post. The right window shows an MD5 decoder interface with the word 'wright' entered in the input field. A red arrow indicates the flow of information from the hash list to the decoder.

MD5 DECODER

md5 match found for 43461e4a5ed08128beeadc3e3590e950:

wright

new query:

enter your md5 hash here:

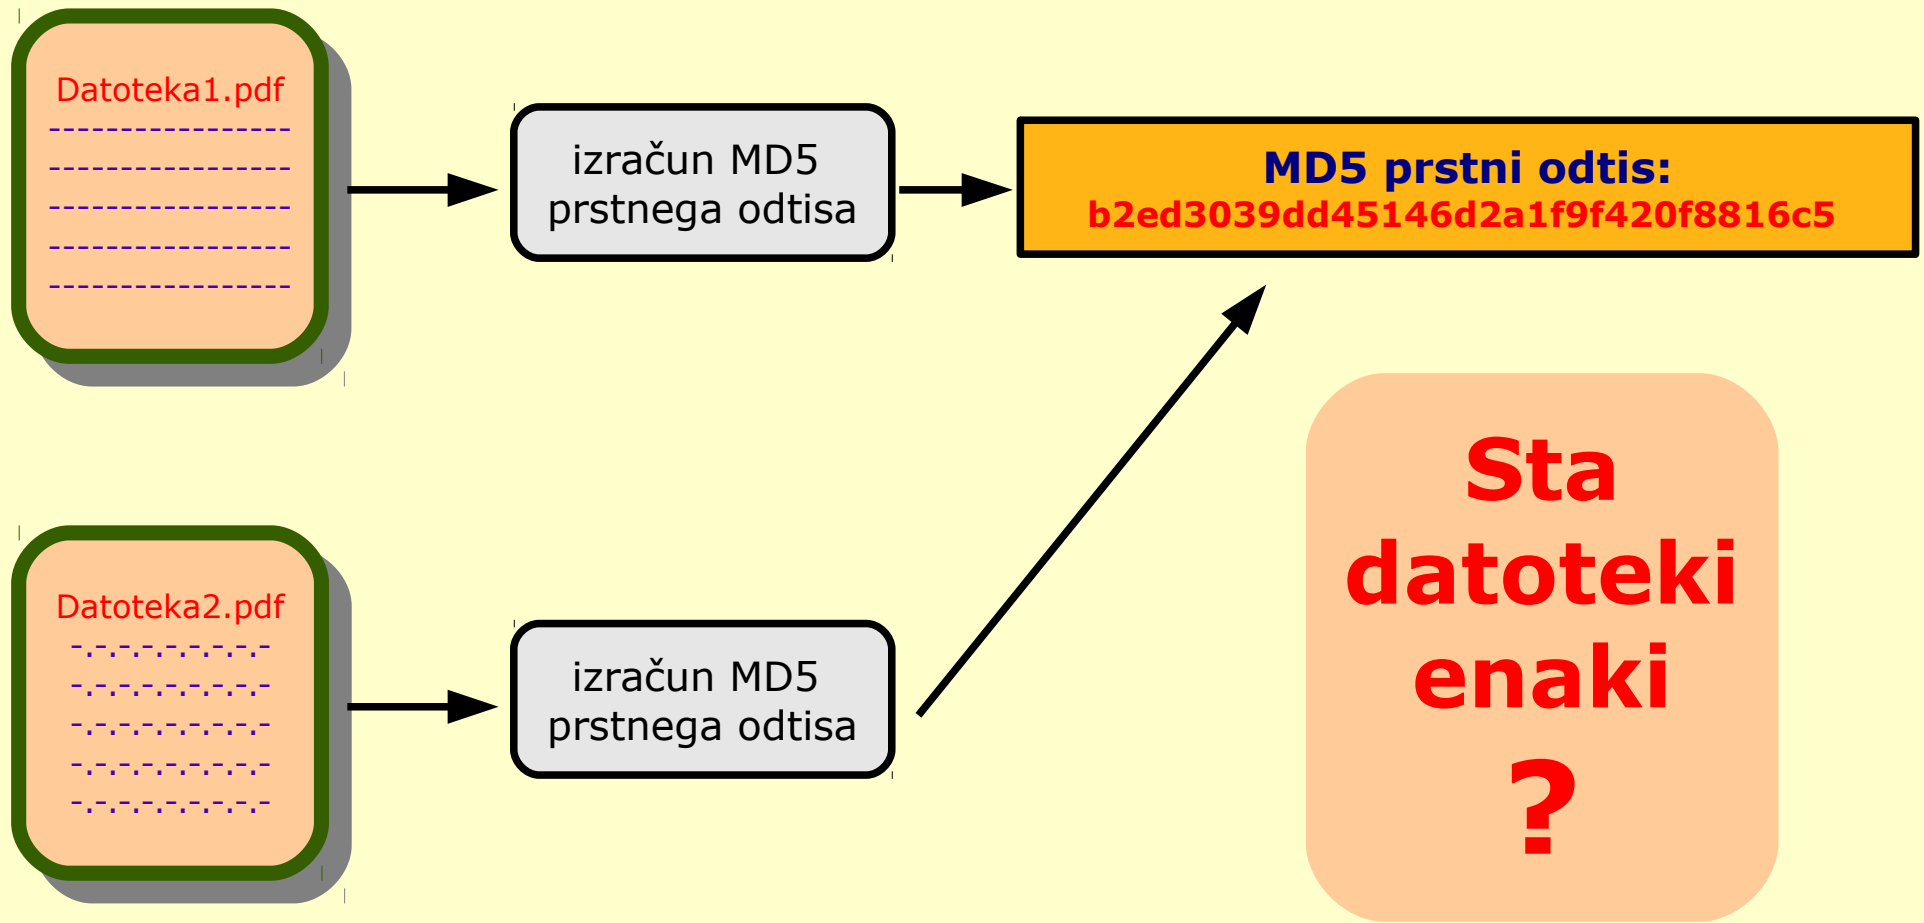
DECODE MD5

Apache

Problem kolizije

*Ne smeta obstajati dva različna niza znakov,
ki bi vrnila isto kontrolno vsoto,
sicer nastopi tim. kolizija.*

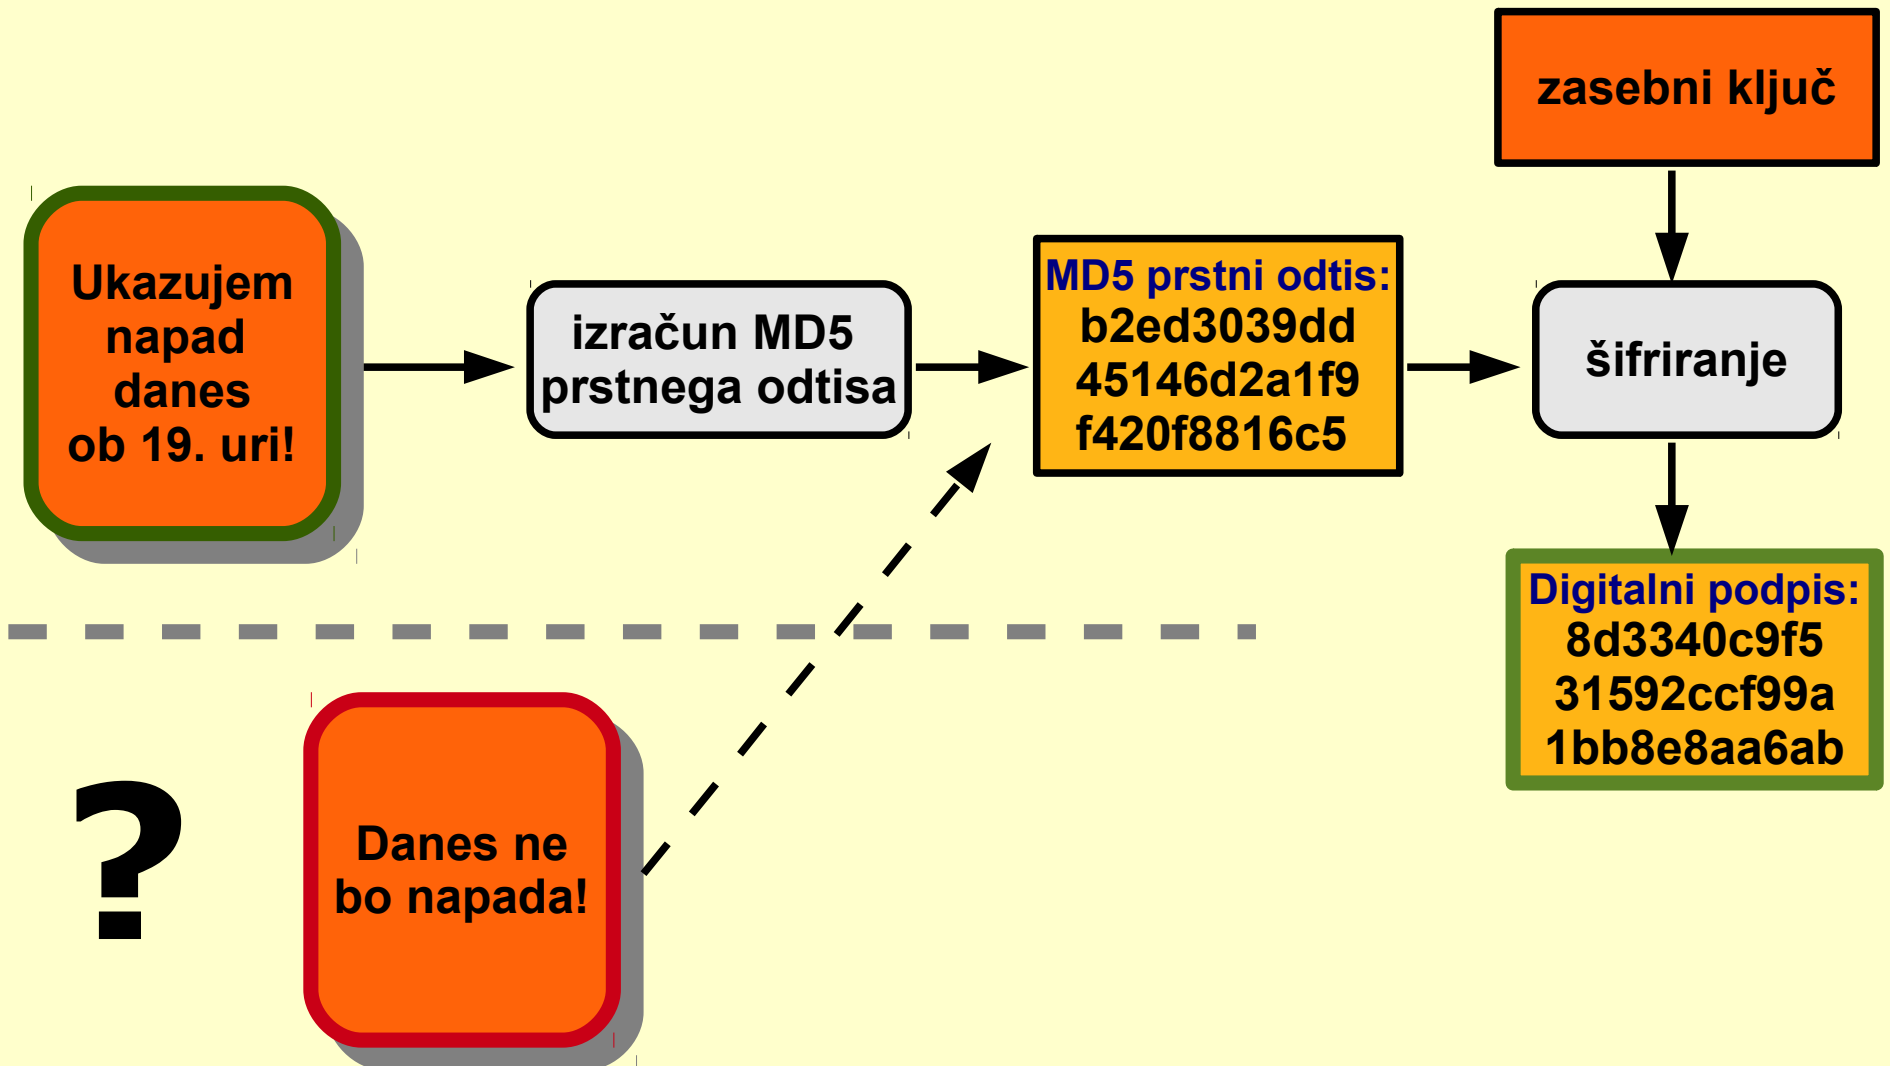
Problem kolizije



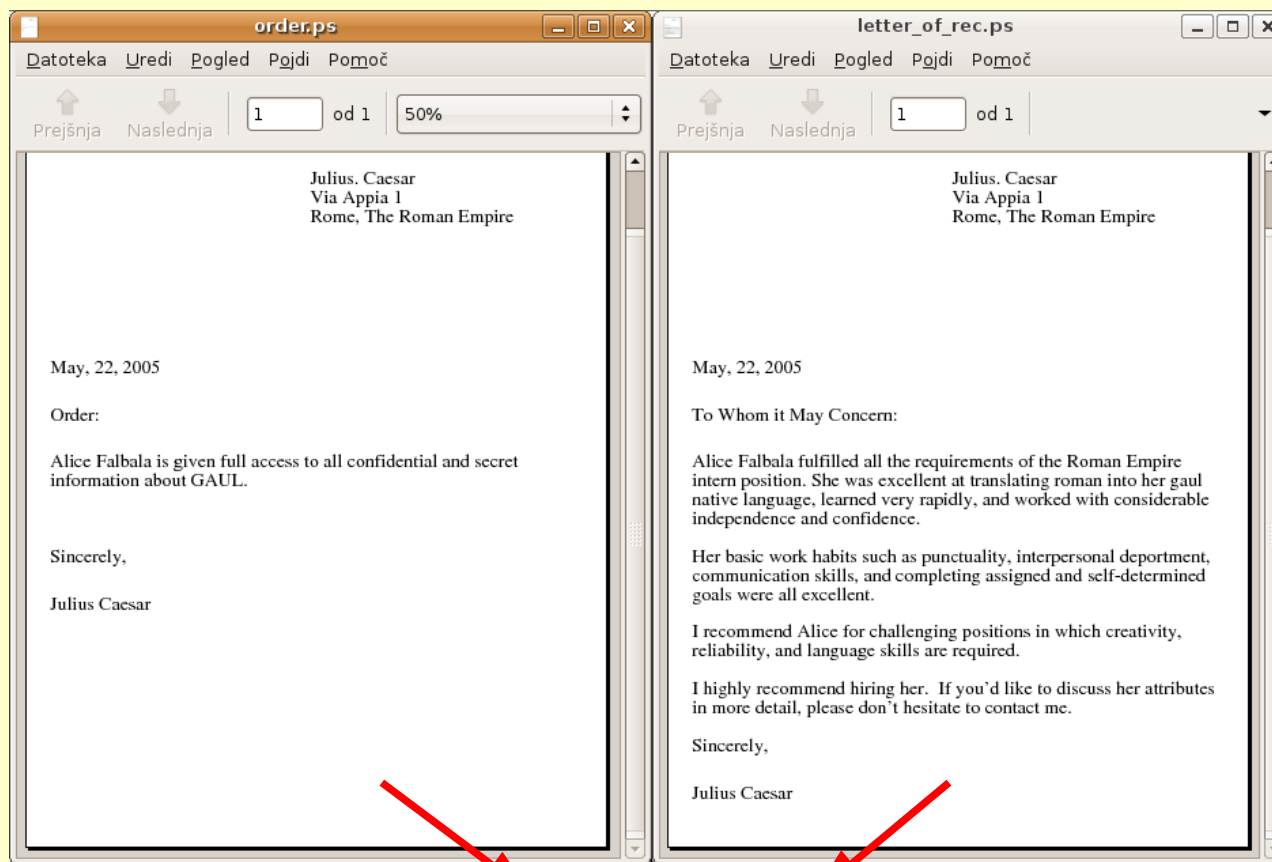
Kolizijski napadi na MD5

- MD5 se je v preteklosti uporabljal pri overjanju digitalnih potrdil, še vedno pa se uporablja pri zagotavljanju integritete podatkov v digitalni forenziki. Razvili so ga leta 1991.
- Leta 1993 sta Den Boer in Bosselaers našla prvo "psevdo-kolizijo".
- Leta 1996 je Dobbertin našel kolizijo v kompresijski funkciji od MD5.
- Leta 2004 so zagnali distribuirani projekt MD5CRK, Xiaoyun Wang, Dengguo Feng, Xuejia Lai in Hongbo Yu so pokazali, da je napad na MD5 mogoče izvesti v eni uri (na IBM p690 računalniški gruči).
- Leta 2005 so Arjen Lenstra, Xiaoyun Wang in Benne de Weger prikazali izdelavo dveh X.509 certifikatov z različnimi javnimi ključi in isto MD5 zgoščeno vrednostjo.
- Leta 2006 je Vlastimil Klima objavil algoritem, ki je zmožgal poiskati kolizijo na prenosniku v eni minuti.
- Danes so znani napadi, ki omogočajo izračun kolizije na podlagi dveh poljubnih nizov vhodnih podatkov v nekaj urah.

Kolizija in digitalni podpis




MD5 kolizija in digitalni podpis



MD5: 5421a523481fdc6a2a1c832e72c7b8a5

Vir: Magnus Daum in Stefan Lucks: The Story of Alice and her Boss: Hash Functions and the Blind Passenger Attack (Eurocrypt 2005, http://th.informatik.uni-mannheim.de/People/lucks/HashCollisions/rump_ec05.pdf).


MD5 kolizija in digitalni podpis



V primeru MD5 kolizije gre za podobno situacijo, kot če bi imeli dve različni osebi z isto DNK!

MD5 kolizija in digitalni certifikati

- Alexander Sotirov, Marc Stevens, Jacob Appelbaum, Arjen Lenstra, David Molnar, Dag Arne Osvik, Benne de Weger, 2008.
- *“The most computationally intensive part of our method required about 3 days of work with over 200 game consoles, which is equivalent to 32 years of computing on a typical desktop computer.”*
- Napad zahteva 1 do 2 dneva na gruči 200 PS 3 igralnih konzol, oziroma 8000 računalnikov z enojedrnim procesorjem, oziroma 20.000 USD na Amazon EC2.



MD5 in prepoznavna / digitalno podpisovanje datotek

```
matej@kovacic-m:~/Desktop$ md5sum hello.exe  
cdc47d670159eef60916ca03a9d4a007 hello.exe
```

```
matej@kovacic-m:~/Desktop$ wine hello.exe  
Hello, world!  
(press enter to quit)q
```

```
matej@kovacic-m:~/Desktop$ md5sum erase.exe  
cdc47d670159eef60916ca03a9d4a007 erase.exe
```

```
matej@kovacic-m:~/Desktop$ wine erase.exe  
This program is evil!!!  
Erasing hard drive...1Gb...2Gb... just kidding!  
Nothing was erased.  
(press enter to quit)q
```

[DEMO: dve exe datoteki]

- Didier Stevens je leta 2009 pokazal kako je mogoče dva različna programa podpisati z enakim Authenticode digitalnim podpisom -> digitalno podpisovanje zlonamernih gonilnikov...
- Bitdefender in napačna prepoznavna virusov marca 2010...

Viri: Peter Selinger, 2006, <http://www.mscs.dal.ca/~selinger/md5collision/>,

Didier Stevens, 2009, <http://blog.didierstevens.com/2009/01/17/playing-with-authenticode-and-md5-collisions/>

Problem MD5 kolizije v računalniški forenziki

- Računalniška forenzika je proces identificiranja, zavarovanja, analiziranja in predstavljanja dokazov v elektronski obliki na način, ki je zakonsko sprejemljiv. To je postopek, ki se od običajnega, strogo tehničnega pregleda nosilcev dokaznega gradiva v elektronski obliki razlikuje v tem, da so na ta način pridobljeni dokazi **veljavni** na sodišču.
- Cilj forenzičnega zasega je zagotoviti, da bodo zajeti podatki ohranili integriteto in s tem dokazno vrednost na sodišču.
- Ključno je torej zagotavljanje integritete podatkov, s čimer se prepreči podtikanje ali nepooblaščno brisanje dokazov.

Problem MD5 kolizije v računalniški forenziki

Problem kolizije ne vpliva (bistveno) na forenzične tehnike prepoznavne znanih datotek,...

... povsem drugače pa je pri **zagotavljanju integritete podatkov.**

Izračun kolizije nad spremenjenimi podatki

IHV	<i>real certificate</i>	<i>rogue CA certificate</i>
IHV0	0123456789ABCDEFEDCBA9876543210	0123456789ABCDEFEDCBA9876543210
IHV1	058484A77F07A36382AAECF2DFE207A2	713F764E78B5C9B03F8878F7A440551B
IHV2	D52743425C3DAC23A9E62C6C9670622E	2AC9681DDB3B72D29A1422A515C9E4F4
IHV3	7789E58E3B45621A3E46A64CA9D7AC3A	104DD09F9F651E554C528578AC1F6885
IHV4	CDA2CB5673D3D32092C7F1EF80CE5729	15ADC95447929A2AC0EACF9E618E14EB
IHV5	F08E24604482508B959A0B5762207A3F	D6D6E59C0BDB1F701CB04C29A0573EA0
IHV6	A83EA6CCCC50B41A4BFADBC6D856B338	3AAB0CE98F1E9B2AC270A5A2C60FF605
IHV7	0B42EAAB4258AACA8C30BDB8192A1BC0	DE3CCC11526732CA0FD8B9F5992A7673
IHV8	D21CED8CC56726B6BF2AE4A93D742C3A	D21CED8CCE3D7EB4C82ADCA94674243A
IHV9	DC1EDBFFF3C3E9E7BCEB3F9E2D0705BD	DC1EDBFFF49941E8BDEB379E2E07FDBC
IHV10	F0D655805A71A74EF8A6A630D11977D8	F0D655805A479F4EF8A69E30D1196FD8
IHV11	9808B5471E7130CC5A30A2ABF2BE4B4D	9808B5471E7130CC5A30A2ABF2BE4B4D
IHV12	AA1F57B21A8732130CB0CAEF4BB9C746	AA1F57B21A8732130CB0CAEF4BB9C746
IHV13	151754FA2FCC5914E72B71B4300B6485	151754FA2FCC5914E72B71B4300B6485
IHV14	271EECDC4DAC9E9C471C34C833917E26	271EECDC4DAC9E9C471C34C833917E26
IHV15	9ED7B966BD815C141B899DC64B528564	9ED7B966BD815C141B899DC64B528564
MD5	9ED7B966BD815C141B899DC64B528564	9ED7B966BD815C141B899DC64B528564

Vir: Alexander Sotirov, Marc Stevens, Jacob Appelbaum, Arjen Lenstra, David Molnar, Dag Arne Osvik, Benne de Weger, 2008, <http://www.win.tue.nl/hashclash/rogue-ca/>.

Cena?

*“The expected complexity of the birthdaying step is estimated at 2^{49} MD5 compression function calls. Estimating the complexity of the near-collision block construction is hard, but it turned out to be a small fraction of the birthdaying complexity. **Based on our observations we find it reasonable to estimate the overall expected complexity of finding a chosen-prefix collision for MD5 at about 2^{50} MD5 compression function calls.** For the example we constructed, however, we had some additional requirements and also were rather unlucky in the birthdaying step, leading to about 2^{52} MD5 compression function calls.”*

Marc Stevens, Arjen Lenstra in Benne de Weger, 2007,
Chosen-prefix Collisions for MD5 and Colliding X.509 Certificates for Different Identities,
<<http://www.win.tue.nl/hashclash/EC07v2.0.pdf>>.

Cena?

- Sotirov et. al.: leta 2008 je napad stal 20.000 USD na Amazon EC2.
 - Od novembra 2010 Amazon EC2 ponuja *Cluster GPU Instances*.
 - Ocena: izračun 150 milijonov MD5 na sekundo, ob kompleksnosti 2^{50} in ceni 2,1 USD na uro: ~4400 USD.
-
- Thomas Roth, 2010, Cracking Passwords In The Cloud: Amazon's New EC2 GPU Instances, <<http://stacksmashing.net/2010/11/15/cracking-in-the-cloud-amazons-new-ec2-gpu-instances/>>.

Problem MD5 kolizije v računalniški forenziki

- Ali so digitalne kopije zaseženih podatkov (npr. slike diskov osumljencev), katerih integriteta temelji na MD5 kontrolnih vsotah še verodostojne?
- Ali preiskovalci za izračunavanje kontrolnih vsot še vedno uporabljajo MD5?
- Kaj pa podatki, ki so bili zaseženi pred leti (sodni postopki se vlečejo)?
- Ali so MD5 kontrolne vsote onkraj razumnega dvoma (ang. *beyond reasonable doubt*)?

Ostali napadi na MD5

- “Preimage napadi” (iskanje izvornega sporočila na podlagi zgoščenih vrednosti – napad na enosmernost funkcije):
 - Yu Sasaki, Kazumaro Aoki (2009-04-16). Finding Preimages in Full MD5 Faster Than Exhaustive Search. Springer Berlin Heidelberg.
<http://www.springerlink.com/content/d7pm142n58853467>.
- Mavrične tabele in predizračunane tabele zgoščenih vrednosti:
 - Online Password Cracking na podlagi predizračunanih vrednosti: <http://www.md5decrypter.co.uk/>
 - razbijanje SHA-1 zgoščenih vrednosti s CUDA-Multiforce (Amazon EC2): dolžina znakov od 1 do 6 v 49 minutah (cena: < 2,1 USD).

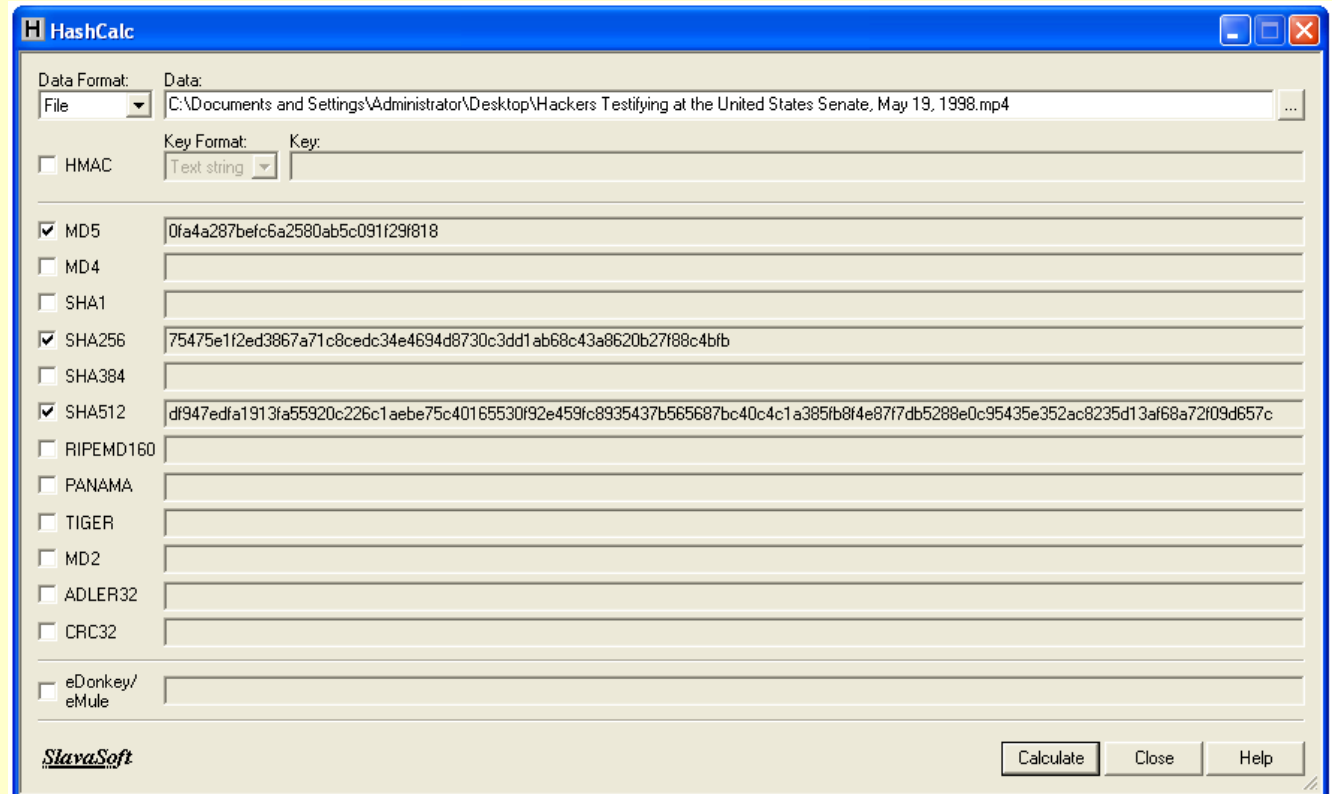


Ostali napadi na MD5

- Velika večina odprtokodnih spletnih aplikacij za shranjevanje gesel v podatkovnih zbirkah še vedno uporablja MD5.
- MySQL in MS-SQL podpirata tudi SHA-1 (160 bits), MySQL celo AES do 256 bits...
- ...vendar pa je problem prehoda iz MD5 na drugo funkcijo, saj gesla ne moremo dekodirati in ponovno zakodirati z novim algoritmom.
 - Rešitev: *SHA-1 over MD5*.
- Za razliko od digitalne forenzike daljši izračun pri preverjanjih gesel ni pomemben, saj je podaljšanje časa za končnega uporabnika neopazno.


Rešitev?

- Uporaba SHA funkcij oziroma uporaba MD5 *in* SHA funkcij za zagotavljanje integritete podatkov.
- Vseeno pa:
 - SHA-0: opuščena zaradi resne pomanjkljivosti kmalu po uvedbi leta 1993;
 - SHA-1: kolizijo so našli leta 2005;
 - SHA-2 (SHA-256 in SHA-512 ter SHA-224 in SHA-384): kolizije še niso našli, a je izračun počasnejši kot pri MD5;
 - SHA-3: trenutno še poteka izbor, ki bo predvidoma končan leta 2012.
- **Večja varnost -> počasnejši izračun.**

Rešitev



Vendar pa...



- SSD diski, ki podpirajo funkcijo TRIM izbrisane podatke nepovratno uničijo - ob tim. hitrem formatiranju podatke uničijo v samo treh minutah, proces uničevanja podatkov pa poteka tudi v primeru, ko je bil disk priključen na blokator pisanja (tim. write blocker).
- V primeru, ko je bil disk priključen na blokator pisanja, pa je bilo po 20 minutah nepovratno uničenih kar 19% izbranih datotek. Pri klasičnih trdih diskih je bilo mogoče obnoviti vse datoteke, ne glede na pretečeni čas.
- Graeme B. Bell in Richard Boddington. 2010. Solid State Drives: The Beginning of the End for Current Practice in Digital Forensic Discovery? V The Journal of Digital Forensics Security and Law. <<http://www.jdfsl.org/subscriptions/JDFSL-V5N3-Bell.pdf>>



vprašanja?



<http://www.Pravokator.si>