



## KÖZÖSSÉGI HÁLÓZATOK PRIVÁTSZFÉRÁT ÉRINTŐ KÉRDÉSEI

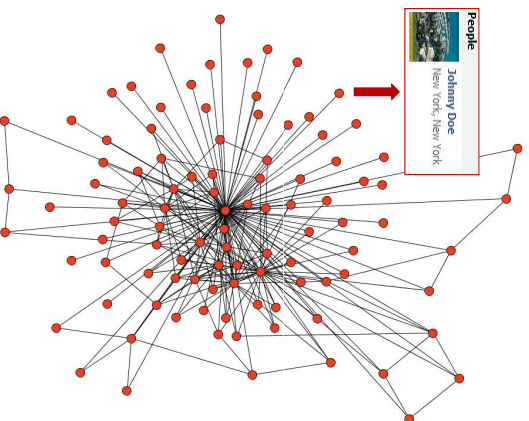
Privátszférát Erősítő Technológiák

Gulyás Gábor György  
Óraadó  
BME Híradástechnikai Tanszék  
gulyasg@hit.bme.hu

2011. május 3.,  
Budapest

## BME Bevezető

- Mi az a közösségi háló?
- Egy szolgáltatás mögötti gráf jellegű struktúra
- Csomópontok = felhasználók
- Élek = kapcsolatok, interakció
- Mik jellemzik ezeket?
- Önkéntes adatszolgáltatás
- Érzékeny (és személyes) adatok, meta-információk megosztása




## Lehet-e általánosítani?

- Mi tartozhat még ide? Példái:
  - Azonnali üzenetküldés (partnerlista, konferenciák)
  - Csevegő szolgáltatások (szobák látogatottságai)
  - Torrent hálózatok (letöltési kapcsolatok)
  - Mobil telefónia (híváslista, telefonkönyv, sms küldés)
  - E-mail kommunikáció (küldés, fogadás)
- Bármilyen szolgáltatás, ami alapjául egy kapcsolati hálózatot tudunk találni.
  - Kapcsolat: azonosítás, leíró információk (profil), interakcióra lehetőség nyílik

## BME Szereplők és lehetőségeik, céljaik

	Lehetőségek	Célok
<b>Felhasználó</b>	(Szolgáltatástól függő, de általában nem sok)	<ul style="list-style-type: none"> <li>▪ Adatok feletti rendelkezés</li> <li>▪ Hozzáférés szabályozás</li> </ul>
<b>Szolgáltató</b>	<ul style="list-style-type: none"> <li>▪ Mindent lát, bármire képes</li> <li>▪ Teljes adatbázis, hálózati struktúra</li> </ul>	<ul style="list-style-type: none"> <li>▪ Értékek az adatok exportálásához, eladásához vezethetnek:                             <ul style="list-style-type: none"> <li>○ Anyagi haszon előteremtése</li> <li>○ Együttműködési harmadik féllel</li> <li>○ Szolgáltatás üzleti értékének növelése, márkanev építése</li> </ul> </li> <li>▪ Állapot, tevékenység kompromittálása</li> <li>▪ Profitok közötti kapcsolat megmutatása</li> <li>▪ Egyéni adatagyűjtő akciók</li> </ul>
<b>Többi felhasználó</b>	<ul style="list-style-type: none"> <li>▪ Nyilvános kapcsolatok listázása</li> <li>▪ Publikus események megfigyelése</li> <li>▪ Új regisztrációk készítése</li> <li>▪ Új kapcsolatok létesítése</li> </ul>	<ul style="list-style-type: none"> <li>▪ Profilozás</li> <li>▪ Megfigyelés</li> </ul>
<b>Harmadik fél</b>	<ul style="list-style-type: none"> <li>▪ Publikus adatok, mint kiegészítő források</li> <li>▪ Anonimizált adatbázis exportok</li> <li>▪ Kis mértékű beavatkozások (id. többi felhasználó)</li> </ul>	<ul style="list-style-type: none"> <li>▪ Személyre szabott szolgáltatások:                             <ul style="list-style-type: none"> <li>○ Hirdetések</li> <li>○ Dinamikus árak</li> </ul> </li> </ul>



## AZ ADATAINK MI VAGYUNK?

(Kép forrása: Szabad adatok, védett adatok 2 borító)


## Mi van egy profilon?

- Személynév vagy egyéb megnevezés
  - Becenevek, felhasználónévek
  - Elérhetőségek
    - E-mail, telefon, ...
    - IM: MSN, Skype, ...
    - SN: Facebook, Twitter, ...
  - Egyéb jellemzők
    - Születésnap
    - Munkahelyek
    - ...
- Többé-kevésbé egyediek
Ezek mind egyediek!
Önmagukban nem egyediek!


## Mi van egy profilon? (2)

- Nem szöveges, multimédiás tartalmak
    - Képek
    - Zenék
    - Videók
  - Meta-információk
    - Kapcsolatok
    - Csoport tagságok
    - ...
- Nehézén feldolgozhatóak!
Kicsit bonyolult a helyzet, de kezelhető


## Mik azok az anonimítási halmazok?




## Mik azok az anonimitási halmazok? (2)




## Mik azok az anonimitási halmazok? (4)

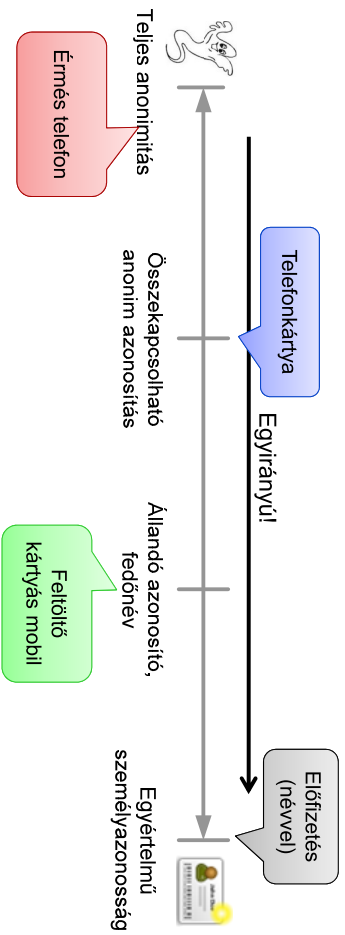


## Mik azok az anonimitási halmazok? (3)




## Mik azok az anonimitási halmazok? (5)





(Forrás: Goldberg, 2000)



## MIT ÁRUL EL RÓLUNK A PROFILUNK?

BME  
**Azonosíthatóság és anonimitási halmazok**

- S: anonimitási halmaz



BME  
**Egyedi azonosítók**

- Személynevek
  - Általában egyediek, de ha nem, a többivel könnyen kombinálható...
- Elérhetőségek
  - Használjuk eltérő elérhetőségeket
  - Második telefonszám, eldobható e-mail cím, stb.
- Más is elérhető minket
  - Pl. fényképeink az online albumokban

## Felhasználónévek, becenevek

- Felhasználónévek, becenevek
- Többé-kevésbé egyediek, de sokszor elérhetőek
- Két adatbázisban a leghatékonyabb kapocs

### Megleppő statisztika:

A felhasználónévek 30%-a független csak a személynévtől!  
(10 millió Google és eBay felhasználónév alapján.)

- Mekkora valószínűséggel van két név mögött ugyanaz a személy?

(Forrás: Perito et al., 2011)

Közösségi hálózatok privátszférát érintő kérdései

© Gulács Gábor György, Híradástechnikai Tanszék  
Budapesti Műszaki és Gazdaságtudományi Egyetem


17

## Felhasználónévek, becenevek (2)

- Módszer
  - Valószínűségi (Markov-lánc alapú) modell
  - Nyelvi jellemzők figyelembe vételével

gulyas.gabor vs. guly.asgabor

- Ellenőrzés
  - Egy 20 000 valós felhasználónévet tartalmazó adatbázison



Közösségi hálózatok privátszférát érintő kérdései

© Gulács Gábor György, Híradástechnikai Tanszék  
Budapesti Műszaki és Gazdaságtudományi Egyetem

18

## Egyéb jellemzők

- Több jellemző figyelembe vételével az anonimitási halmaz mérete jelentősen csökken

{irányítósorszám, nem, születési dátum}

- Egy 1990-es felmérés szerint az USA állampolgárainak 87%-át egyedileg azonosította\*

(\* Forrás: Sweeney, 2000)


Közösségi hálózatok privátszférát érintő kérdései

© Gulács Gábor György, Híradástechnikai Tanszék  
Budapesti Műszaki és Gazdaságtudományi Egyetem

19

## Egyéb jellemzők (2)

- Nem kell nekünk feltenni: ismerőseinknek elég!
- A jellemzők megittipelhettek\*
  - MIT Facebook tagjait vizsgálták (kb. 2500 fő)



- 10 főről más forrásból tudták, de nem vallotta be homoszexuális beállítottságát

- Az ismerőseik attribútumai szerint mind sikerült megtalálni

(\* Forrás: Jernigan & Mistré, 2009)

Közösségi hálózatok privátszférát érintő kérdései

© Gulács Gábor György, Híradástechnikai Tanszék  
Budapesti Műszaki és Gazdaságtudományi Egyetem

20

# Mi a megoldás?

- Felhasználói tudatosság
- Minden egyre inkább publikussá és valós időben kereshetővé válik
- Vannak titkosításra alkalmas programok\*
- A titkosítás értelmezhetetlen szövegbe rejtí az információt (Van, ahol ezért törlés jár, pl. Facebook.)
- Pl.



Johnny Doe

[crypt:keyid=mk:keyid algo=AES-CBC-IND5 length=69] UZFsdGkX.197Gb  
dnyv8Pc7Ryo/RQ sS0mdrFbOwJ+9 dg69eeUJgmWlq w1CmD6/C  
about a minute ago · Like · Comment


(\* Forrás: Paulik et al., 2010)

# Mi a megoldás? (2)

- Használhatunk szteganográfiát is\*
- Hozzunk létre egy értelmesnek tűnő állprofiilt



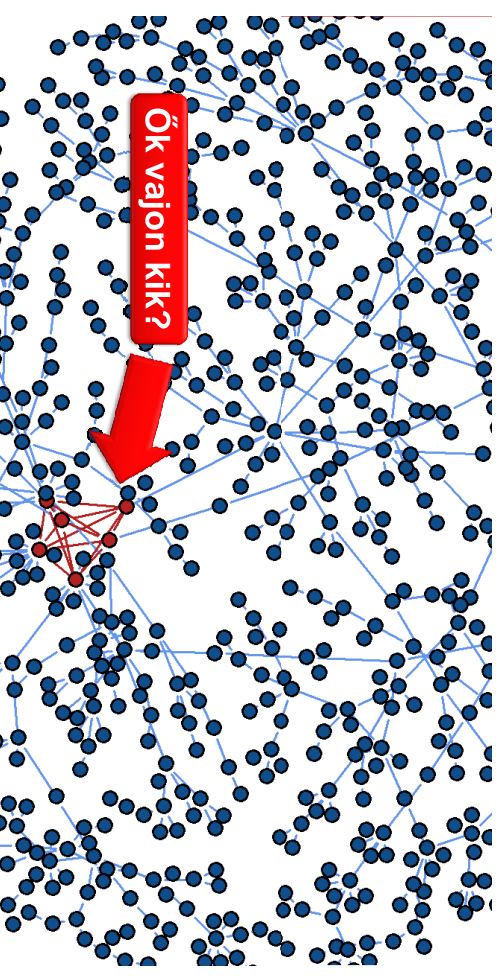
(\* Forrás: Besenyei et al., 2011)

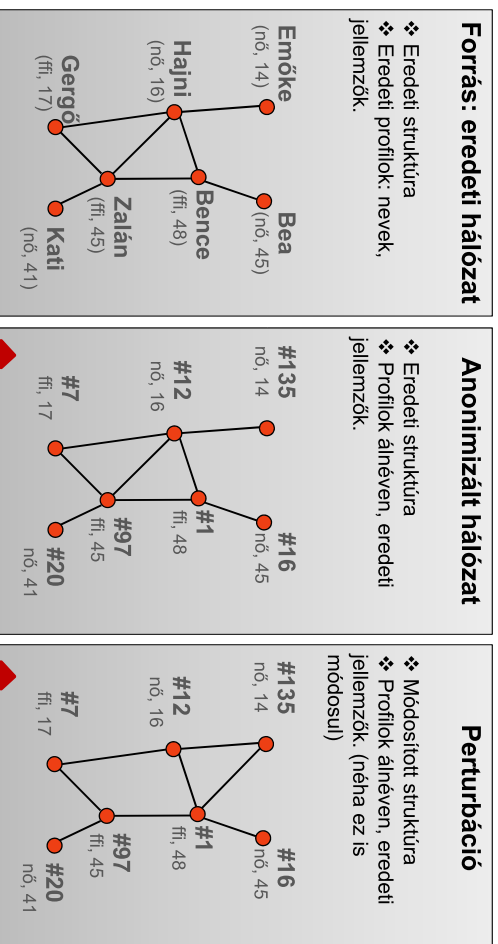


## A KAPCSOLATRENDSZERÜNKBEN IS BENNE VAGYUNK?




## Információ a kapcsolatrendszerben





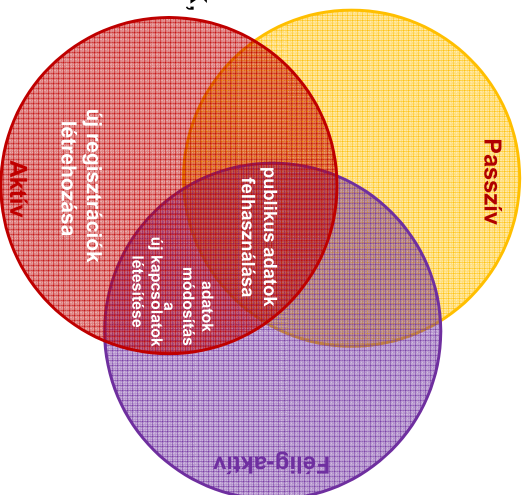
Közösségi hálózatok privátszférát érintő kérdései

© Gyújas Gábor György, Hírdéstechnikai Tanszék Budapesti Műszaki és Gazdaságtudományi Egyetem




(Forrás: Backstrom et al., 2007)

- Egy anonimizált, de többlet-információt tartalmazó hálóban keresünk
  - többlet információ: rejtett kapcsolatok, jellemzők, stb.
  - hozzáférhetnek kutatók, üzleti partnerek, stb.
- A cél 1 vagy több felhasználó újraazonosítása




Közösségi hálózatok privátszférát érintő kérdései

© Gyújas Gábor György, Hírdéstechnikai Tanszék Budapesti Műszaki és Gazdaságtudományi Egyetem

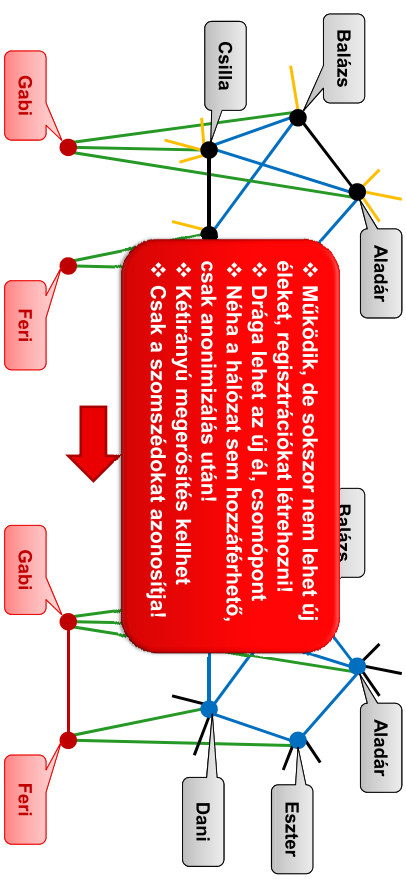


(Forrás: Backstrom et al., 2007)

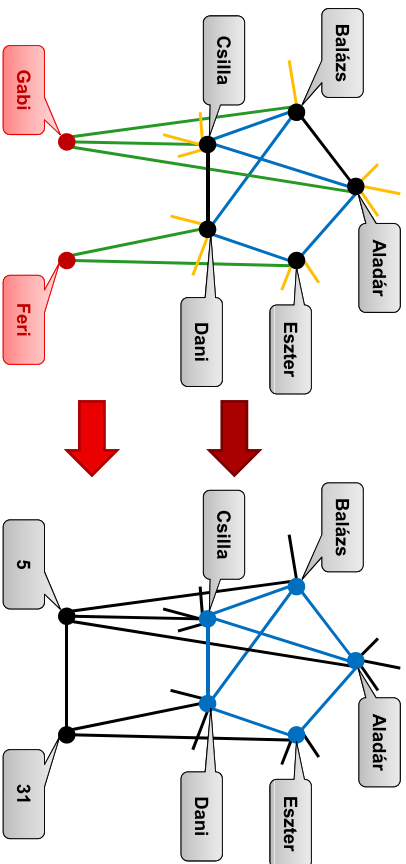
# Félig-aktív és aktív támadás



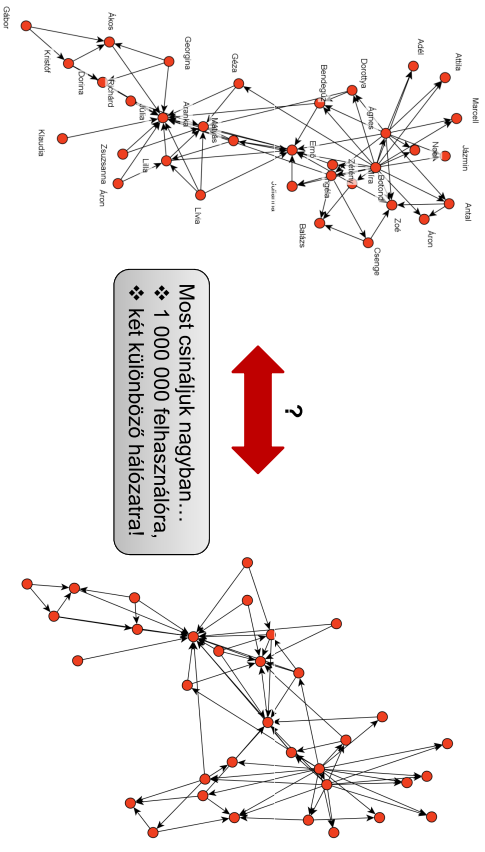
# Félig-aktív és aktív támadás (3)



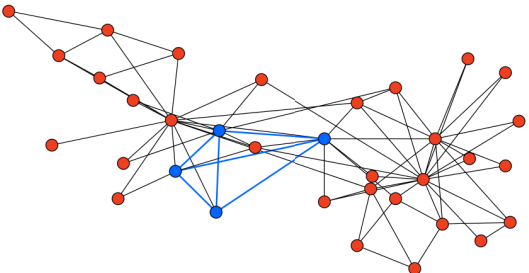
# Félig-aktív és aktív támadás (2)




# Passzív támadás





- Alapötlet:
    - Egy másik közösségi hálózat publikus adatainak, mint kiegészítő információforrásnak alkalmazása
    - Csak a strukturális információk figyelembe vétele
    - Fokszám
    - Közös szomszédok száma
    - $f_{err}=1\pm\varepsilon$  hibafaktor
  - Az algoritmus fázisai:
    - Kiindulási mag keresése: 4-es klikkek újra azonosítása
    - Terjedési fázis: a beazonosított klikktől az azonosítás folytatása
- 

(Forrás: Narayanan & Shmatikov, 2009)

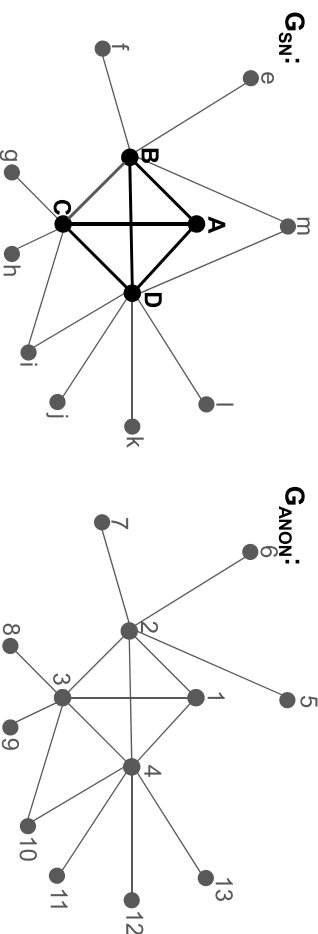


**Közös szomszédok:**

$G_{SN}$	$N(v_i, v_j)$	$G_{ANON}$	$N(v_i, v_j)$	$d_{err}$
A,B	2	1,2	2	1
A,C	2	1,3	2	1
A,D	2	1,4	2	1
B,C	2	2,3	2	1
B,D	3	2,4	2	0,667
C,D	3	3,4	3	1

$$0,65 < d_{err}(B,D);(2,4) = 0,667 < 1,35 \checkmark$$

( $\varepsilon=35\%$ )




Csomópontok fokszáma:

$v_i$	$d(v_i)$	$v_j$	$d(v_j)$	$d_{err}$
A	3	1	3	1
B	6	2	6	1
C	6	3	6	1
D	8	4	7	0,875

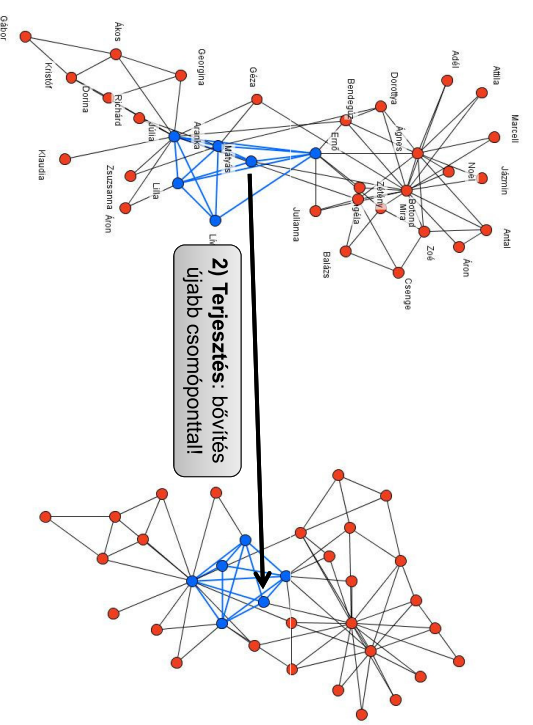
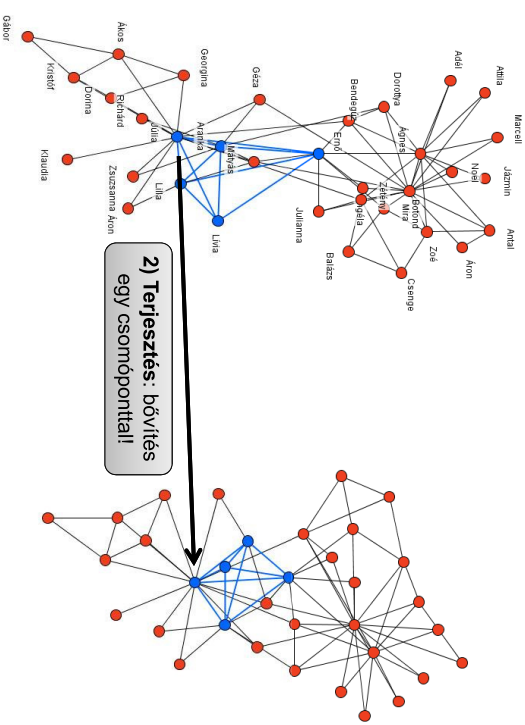
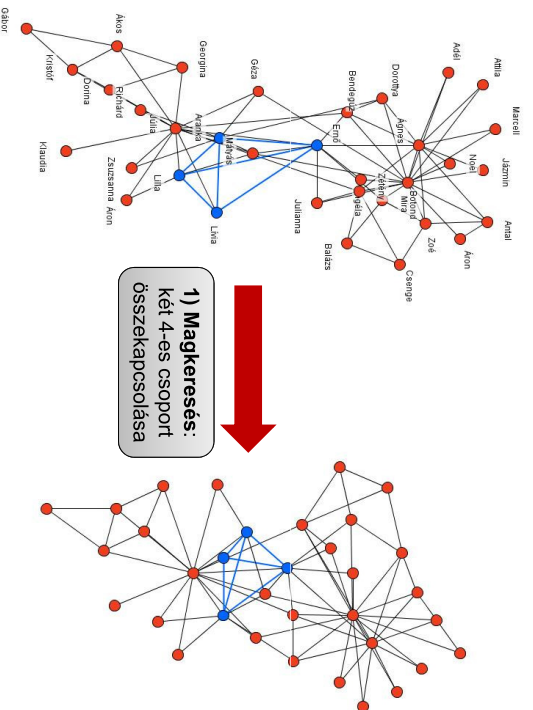
$$0,65 < d_{err}(D,4) = 0,875 < 1,35 \checkmark$$

( $\varepsilon=35\%$ )




- A magot  $\varepsilon=35\%$  mellett sikerült megtalálni ( $f_{err}=1\pm\varepsilon$ )
- A gyakorlatban
  - A gráfok és így az algoritmus is robusztusabbak (nagyobb fokszám, több közös szomszéd)
  - Meg is jelenhetnek élek (anonimizálás, más kapcsolatrendszer)
  - Sokkal kisebb  $\varepsilon$  is elég
  - A túl nagy  $\varepsilon$  miatt sok téves találat lehet

- Rekurzív algoritmus
  - Az újracímkezett halmazt bővíti
  - Eleinte ez a mag
- Lépései a  $G_{SN}=(V_{SN}, E_{SN})$ ,  $G_{ANON}=(V_{ANON}, E_{ANON})$  gráfokon
  1. Válasszunk egy  $v_i \in V_{SN}$  csomópontot, aki nincs újracímkezve, de vannak már beazonosított kapcsolatai:  $\{v_1, \dots, v_k\} \in V_{SN}$ 
    - a. Válasszuk ki a páriáikat:  $\{v_1, \dots, v_k\} \in V_{ANON}$
    - b. Vegyük az azonosítatlan szomszédjaikat:  $\{v_{u_1}, \dots, v_{u_m}\} \in V_{ANON}$
    - c. Minden csomópont kapjon annyi pontot, ahány azonosított szomszédja van:  $\{s_{u_1}, \dots, s_{u_m}\}$
  2. Ha van szignifikáns eredmény  $\{s_{u_1}, \dots, s_{u_m}\}$ -ben, akkor válasszuk a legmagasabb pontszámút  $v_i$  páriájának




## Passzív támogatás hatékonysága

- Két valódi hálózat között kerestek átfedést
  - Forrás: Flickr (3,3m felh., 53m kapcsolat)
  - Cél: Twitter (224e felh., 8,5m kapcsolat)
- Eredmények:



## Mi az identitás szeparáció?



## Alapkonceptió

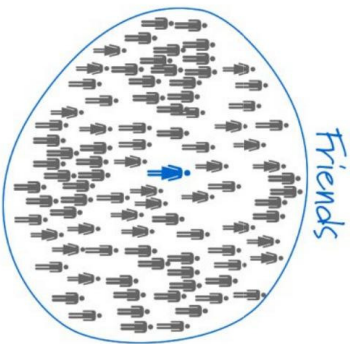
- Szerep alapú identitásmenedzsment
    - Más helyzetekben más információ számít
    - Köthetők: partnerhez, szerepkörhöz
    - Időtartam: hosszú távú, tranzakcióhoz kötött
  - A privátszféra oldaláról
    - Akár ellentmondó információk megosztása
    - Látszólag összeköthetetlen, független identitások
    - Teljes anonimitás lehetősége
- ➔ Közösség/csoport alapú modellezés!



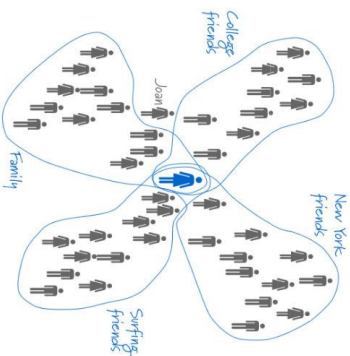
## IDENTITÁSMENEDZSMENT: A JÖVŐ MEGOLDÁSA?

## Az élet igazolta: egyébként is szeparálunk!

### ONLINE



### OFFLINE




(Forrás: <http://www.slideshare.net/padday/the-real-life-social-network-v2>)

Közösségi hálózatok privátszférát érintő  
© Gulács Gábor György, Híradástechnikai Tanszék  
Budapesti Műszaki és Gazdaságtudományi Egyetem

45

## Védi a kapcsolattrendszerünket? (2)

Alap modell, hibavalószínűségek a passzív támadás esetén egy felhasználóra 2 új identitás esetén:




Közösségi hálózatok privátszférát érintő

© Gulács Gábor György, Híradástechnikai Tanszék  
Budapesti Műszaki és Gazdaságtudományi Egyetem

47

## Védi a kapcsolattrendszerünket?

- Ismeretlen felhasználói viselkedés
- Modellezzük valószínűségi alapokon
- Létező identitások „darabolása”
- Ezen belül is többféle modell lehetőséges
- Modellek megadása az identitás szeparáció szerint
- Az identitások kapcsolatai között lehet átfedés?
- Elvesszhetnek az élek?
- Az élek besorolása független?




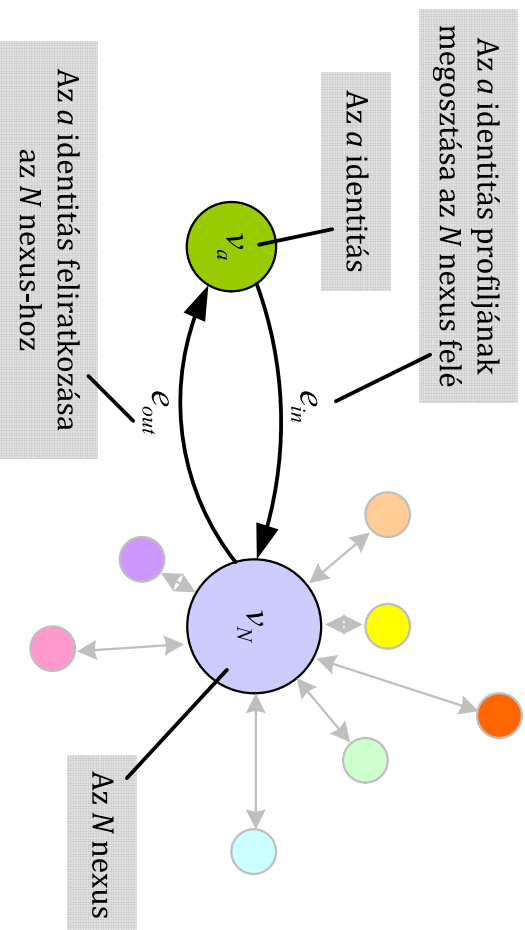
Közösségi hálózatok privátszférát érintő  
kérdések

© Gulács Gábor György, Híradástechnikai Tanszék  
Budapesti Műszaki és Gazdaságtudományi Egyetem

46

## IDENTITÁS SZEPARÁCIÓ KÖZÖSSÉGI HÁLÓKBAN: NEXUS-IDENTITY NETWORKS






BME  
Reguláris vs. több identitásos közösségi háló

Reguláris


- Kapcsolat orientált struktúra
  - Egy felhasználó egy identitással van jelen (egy felhasználó egy csomópont)
  - Pontos beazonosíthatóság
- Közösség orientált struktúra
  - Egy felhasználó több identitás által reprezentált (egy felhasználó „több csomópontból áll”)
  - Pontos beazonosíthatóság
  - Anonimitás
    - Teljes anonimitás
    - Összeköthetetlen identitások

1. Teljes anonimitás
  - Azonosító nélkül
2. Összekapcsolható anonim azonosítás
  - Rövid távon használt azonosító
  - Lokális, adott névtérben egyedi azonosító
  - Tetszőlegesen lecserélhető
  - Párhuzamosan több használható
3. Állandó azonosító
  - Hosszú távon használt azonosító
  - Globális névtérben egyedi azonosító

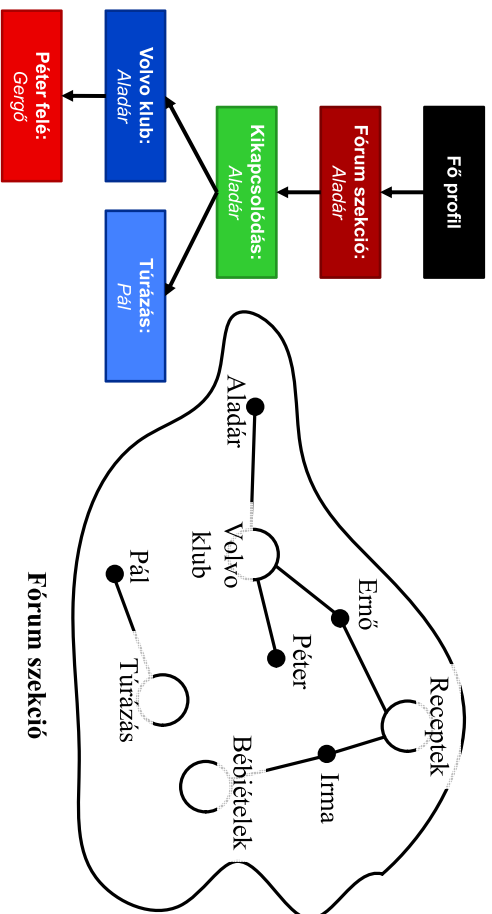


BME  
Profil hierarchia

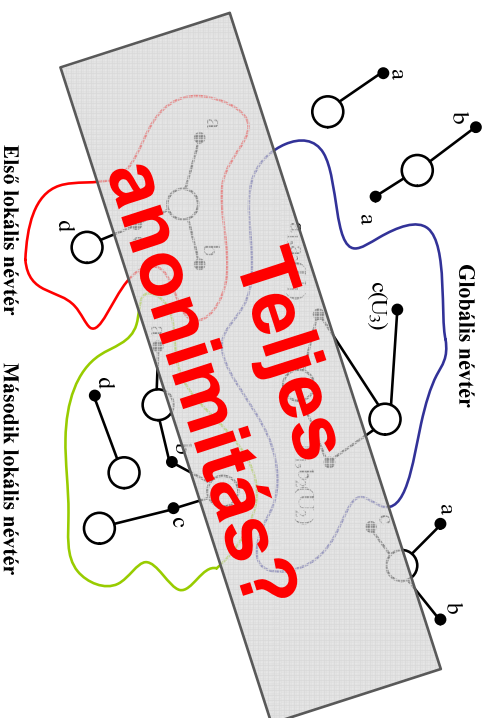
- Fa struktúrájú
  - Globálístól a lokális felé halad
  - Öröklődés
  - Egyre kevesebb információ kerül megosztásra
  - Ellentmondó információk lehetnek az egyes ágakon
- Csak a tulajdonos ismeri
  - (és a szolgáltató)
  - Mások számára összeköthetetlen ágak is lehetnek benne



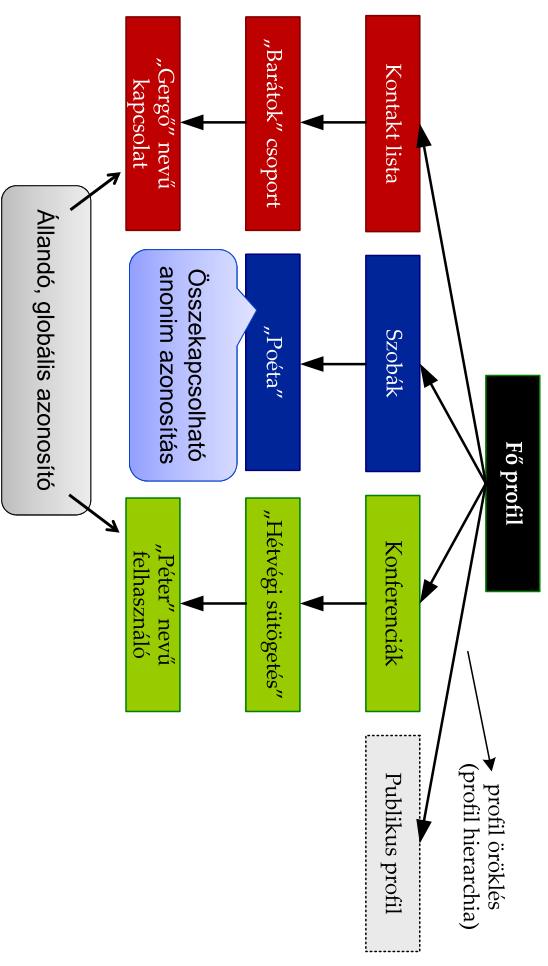
# Hálózat struktúra



# Hálózat struktúra (2)



# Anonim csevegő szolgáltatások



# ÖSSZEFOGLALÁS



## Összefoglalás: mit tehetünk?

- Tudatosság! Tényleg szükségünk van rá?
  - Amit publikáltunk, az már visszavonhatatlanul kint van.
- Számoljunk a trendekkel! Minden egyre inkább...
  - ... publikus
  - ... kereshető
  - ... valós idejű
- Használjunk saját vezérlésű hozzáférés szabályozási alkalmazásokat.
- Identitásszeparáció: ha más néven futunk két helyen: kerüljük az azonos feliratkozást, tevékenységeket, barátokat

## KÖSZÖNÖM A FIGYELMET!

**Gulyás Gábor György**  
gulyasg@hit.bme.hu



Híradástechnikai Tanszék

<http://www.hit.bme.hu>

international  
**PEET**  
portal and blog

<http://pet-portal.eu>