



# Σύνθετα Δίκτυα

**com+plex: with+ -fold (having parts)**

Διδάσκων –  
Δημήτριος Κατσαρός

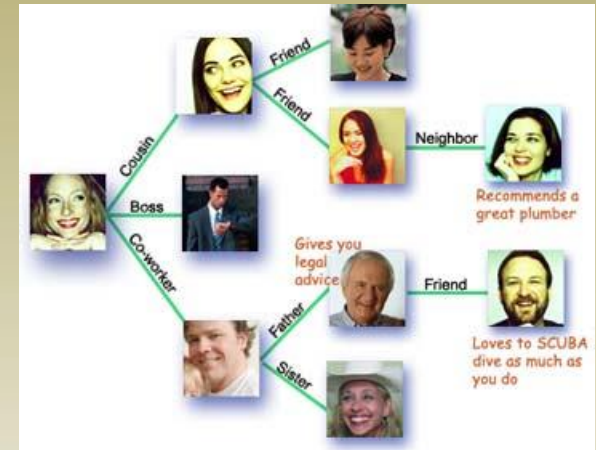


Influence maximization


Μεγιστοποίηση επιρροής

# Κοινωνικά δίκτυα και διάδοση επιρροής

- Τα κοινωνικά δίκτυα διαδραματίζουν θεμελιώδη ρόλο ως μέσα για τη διάδοση της ΕΠΙΡΡΟΗΣ μεταξύ των μελών ΤΟΥΣ
  - Γνώμες, ιδέες, πληροφορίες, καινοτομία ...



- Το direct marketing εκμεταλλεύεται το “word-of-mouth” για να αυξήσει σημαντικά τα ωφέλη (Gmail, Tupperware popularization, Microsoft Origami ...)





# Διατύπωση του προβλήματος

- Δίνεται
  - Ένας περιορισμένος προϋπολογισμός  $B$  για αρχική διαφήμιση (π.χ., δωρεάν δείγματα του προϊόντος)
  - Εκτιμήσεις για την επιρροή μεταξύ των ατόμων
- Στόχος
  - Κινητοποίηση ενός μεγάλου καταρράκτη επιρροής (π.χ., περεταίρω υιοθέτηση του προϊόντος)
- Ερώτηση
  - Σε ποιο υποσύνολο  $B$  των ατόμων να στοχεύσουμε;
- Εφαρμογές πέραν του marketing προϊόντων
  - Διάδοση καινοτομιών
  - Ανίχνευση ιστοριών σε blogs



# Τι χρειαζόμαστε

- Μοντέλα επιρροής στα κοινωνικά δίκτυα
- Δεδομένα για τέτοια δίκτυα (για να εκτιμήσουμε την δια-προσωπική επιρροή)
- Επινόηση αλγορίθμου για τη διάδοση της επιρροής



# Μοντέλα επιρροής

- Τα πρώτα μαθηματικά μοντέλα
  - [Schelling '70/'78, Granovetter '78]
- Μετέπειτα, αρκετές εργασίες:
  - [Rogers '95, Valente '95, Wasserman/Faust '94]
- Δυο βασικές ομάδες μοντέλων διάχυσης: **threshold** και **cascade**
- Γενική θεώρηση:
  - Το κοινωνικό δίκτυο αναπαρίσταται ως γράφημα
  - Οι κόμβοι ξεκινούν είτε ως active είτε ως inactive
  - Ένας active κόμβος node μπορεί να εκκινήσει activation των γειτονικών κόμβων
  - Υπόθεση : οι active κόμβοι ποτέ δεν γίνονται deactivate



# Linear Threshold Model

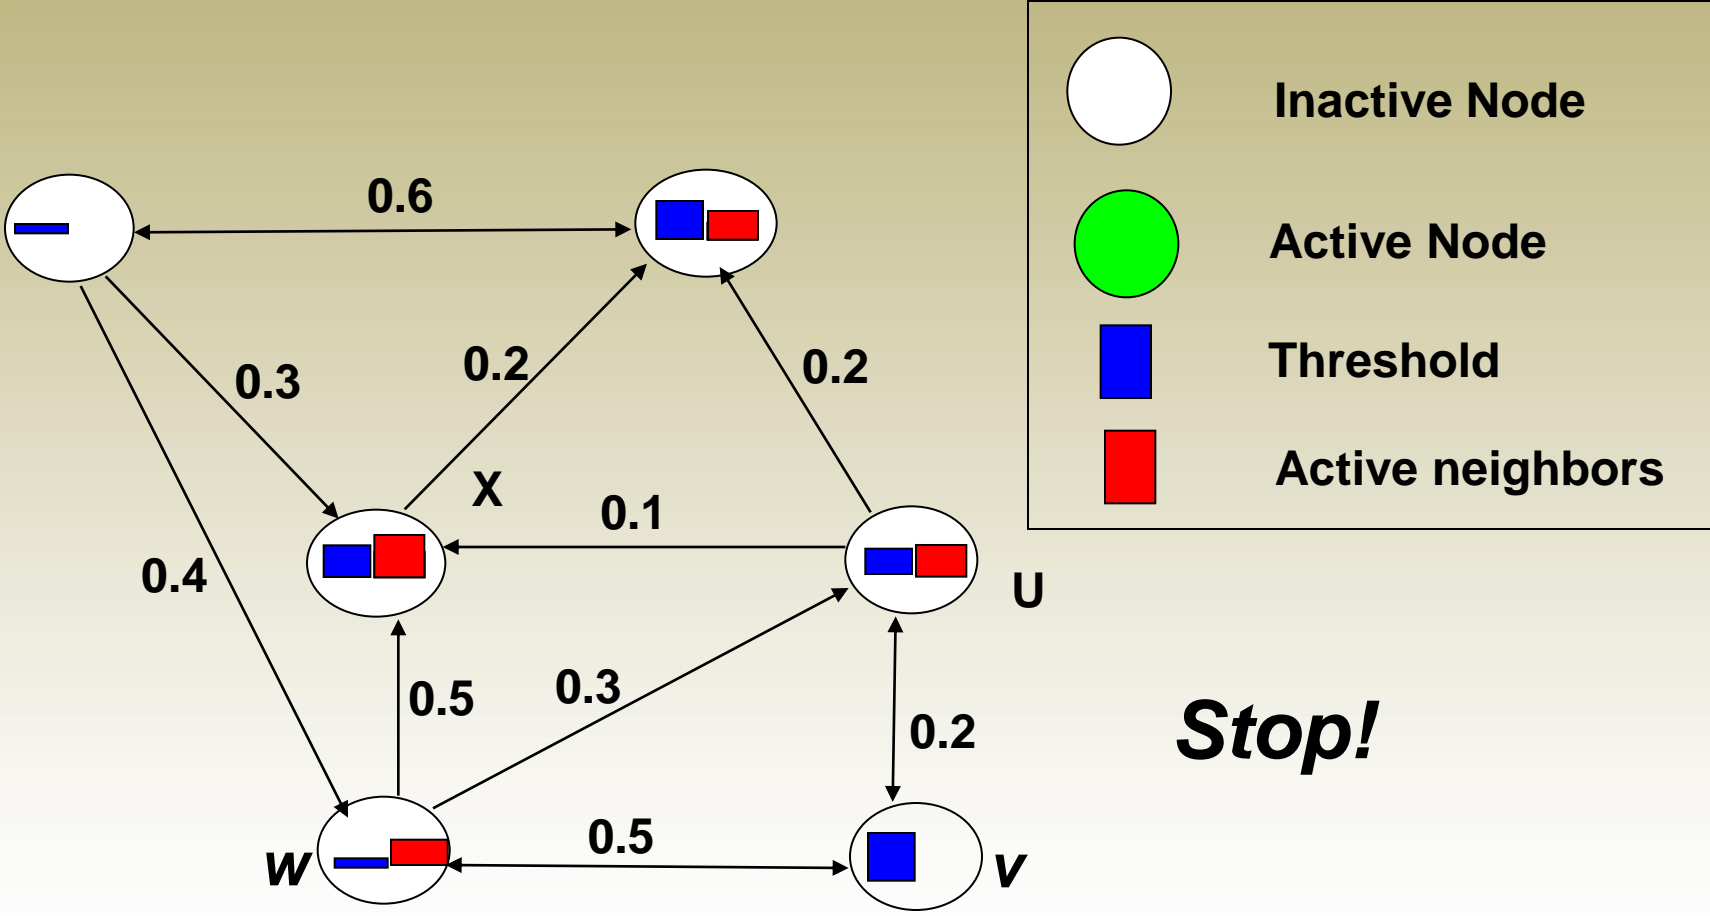
- Ένας κόμβος  $v$  έχει τυχαίο κατώφλι  $\theta_v \sim U[0, 1]$
- Ένας κόμβος  $v$  υφίσταται επιρροή από κάθε γείτονα  $w$  σύμφωνα με το *weight*  $b_{vw}$  τέτοιο ώστε

$$\sum_{w \text{ neighbor of } v} b_{v,w} \leq 1$$

- Ένας κόμβος  $v$  γίνεται active όταν τουλάχιστον (weighted)  $\theta_v$  κλάσμα των γειτόνων είναι active

$$\sum_{w \text{ active neighbor of } v} b_{v,w} \geq \theta_v$$

# Παράδειγμα



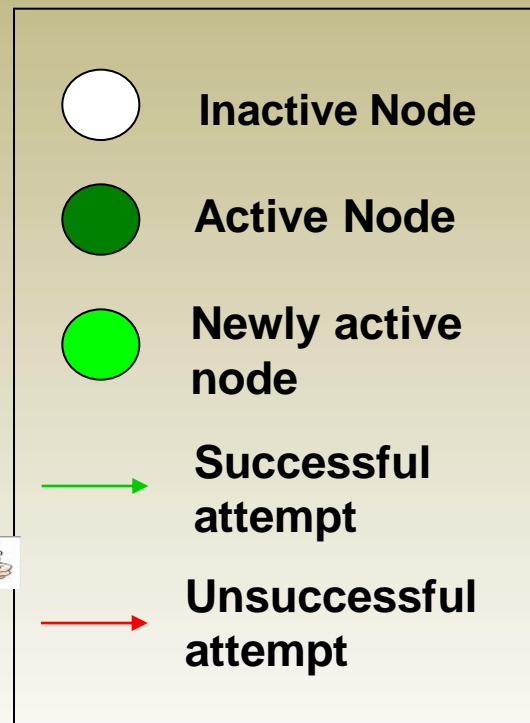





# Independent Cascade Model

- Όταν ο κόμβος  $v$  γίνεται active, έχει ΜΙΑ ΜΟΝΟ (**single**) ευκαιρία να ενεργοποιήσει (activating) κάθε ΤΩΡΑ inactive γείτονα  $w$
- Η προσπάθεια activation επιτυγχάνει με πιθανότητα  $p_{vw}$

# Παράδειγμα



**Stop!**



# Το πρόβλημα μεγιστοποίησης επιρροής

- Επιρροή (influence) του συνόλου κόμβων  $S$ :  $f(S)$ 
  - **expected** αριθμός των active κόμβων στο τέλος, εάν το σύνολο  $S$  είναι το αρχικό active σύνολο
- Πρόβλημα:
  - Δεδομένης μια παραμέτρου  $k$  (budget), βρες ένα  $k$ -node set  $S$  που να μεγιστοποιεί το  $f(S)$
  - Constrained optimization problem με το  $f(S)$  ως την αντικειμενική συνάρτηση




# Set functions και energy functions

any set function  
with  $|V| = n$ .


... is a function on  
binary vectors!

$$F : 2^V \rightarrow \mathbb{R}$$

$$f : \{0, 1\}^n \rightarrow \mathbb{R}$$




$\hat{=}$



binary labeling problems = subset selection problems!


# Influential υποσύνολα



$$F(S) = \text{spread}$$

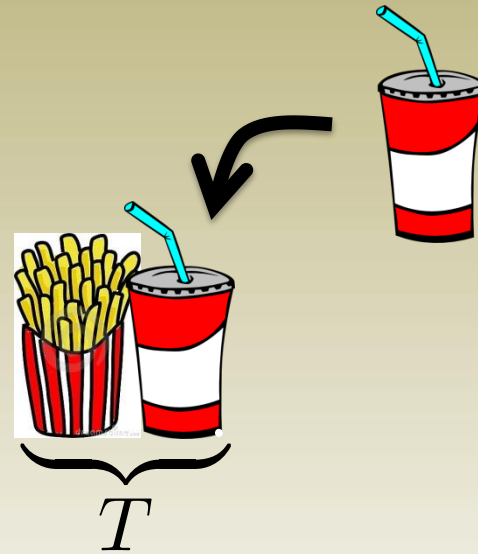
# Submodularity

$$S \subseteq T$$



$$F(S \cup s) - F(S)$$

extra cost:  
one drink




$$F(T \cup s) - F(T)$$

extra cost:  
free refill ☺

diminishing marginal costs

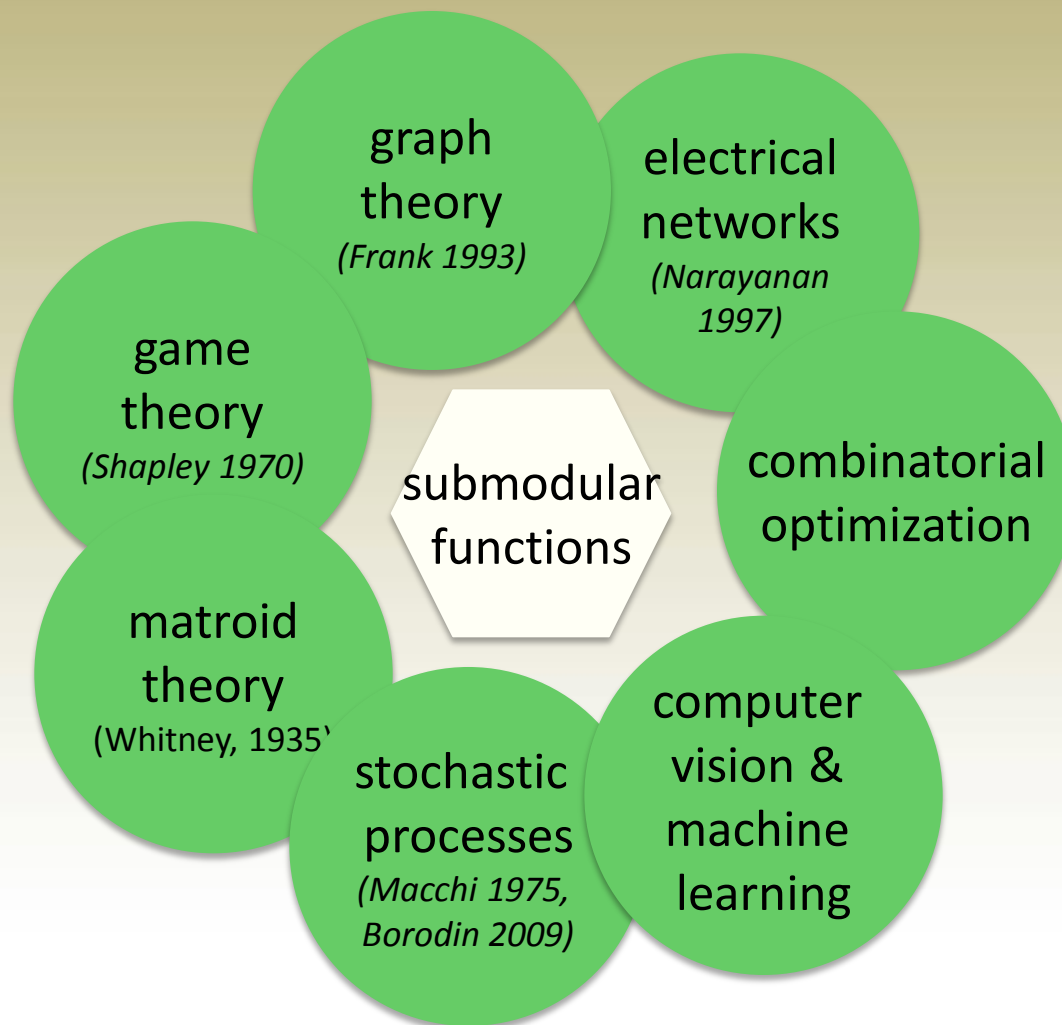
# Η μεγάλη εικόνα



*G. Choquet*



*J. Edmonds*




*L.S. Shapley*



*L. Lovász*

# Παραδείγματα




sensing:

$F(S)$  = information gained from locations  $S$




# Παράδειγμα: cover

$$F(S) = \left| \bigcup_{v \in S} \text{area}(v) \right|$$



$$F(A \cup v) - F(A)$$




$$F(B \cup v) - F(B)$$

$\geq$



# Μεγιστοποίηση επιρροής


$F(S)$  = expected # infected nodes




$$F(S \cup s) - F(S) \geq F(T \cup s) - F(T)$$

# Submodular set functions

- **Diminishing gains:** for all  $A \subseteq B$



+• e




+• e


$$F(\underline{A \cup e}) - F(A) \geq F(B \cup e) - \underline{F(B)}$$

- **Union-Intersection:** for all

$$S, T \subseteq \mathcal{V}$$



$$\underline{F(S)} + \underline{F(T)} \geq F(S \cup T) + F(S \cap T)$$



## $f(S)$ : Ιδιότητες

- Μη αρνητική (προφανώς)
- Μονότονη:  $f(S + v) \geq f(S)$
- Submodular:
  - Έστω  $N$  ένα πεπερασμένο σύνολο
  - Μια set συνάρτηση  $f : 2^N \mapsto \mathfrak{R}$  είναι submodular *iff*

$$\forall S \subset T \subset N, \forall v \in N \setminus T,$$

$$f(S + v) - f(S) \geq f(T + v) - f(T)$$

(diminishing returns)



## Τα άσχημα νέα

- Για μια submodular συνάρτηση  $f$ , εάν η  $f$  παίρνει μόνο μη-αρνητική τιμή, και είναι μονότονη, η εύρεση ενός συνόλου  $k$  στοιχείων, του  $S$ , για το οποίο το  $f(S)$  βελτιστοποιείται είναι ένα πρόβλημα βελτιστοποίησης NP-hard
- Είναι NP-hard για να προσδιοριστεί το βέλτιστο για τη μεγιστοποίηση της επιρροής και για το independent cascade model και για το linear threshold model



# Τα καλά νέα

- Μπορούμε να χρησιμοποιήσουμε κάποιον άπληστο αλγόριθμο!
  - Εκκίνηση με ένα κενό σύνολο  $S$
  - Για  $k$  επαναλήψεις:
    - Προσθέστε τον κόμβο  $v$  στο  $S$  που μεγιστοποιεί το  $f(S + v) - f(S)$
- Πόσο καλό (κακό) είναι αυτό?
  - Θεώρημα: Ο άπληστος αλγόριθμος είναι μια  $(1 - 1/e)$  προσέγγιση
  - Το προκύπτον σύνολο  $S$  activates τουλάχιστον  $(1 - 1/e) > 63\%$  του αριθμού των κόμβων που θα μπορούσε να ενεργοποιήσει οποιοδήποτε σύνολο  $S$  μεγέθους  $k$



# Ο άπληστος αλγόριθμος

---

**Algorithm 1** Greedy alg. for influence maximization

---

**Require:**  $G, k, \sigma_m$

**Ensure:** seed set  $S$

1:  $S \leftarrow \emptyset$

2: **while**  $|S| < k$  **do**

3:      $u \leftarrow \arg \max_{w \in V \setminus S} (\sigma_m(S \cup \{w\}) - \sigma_m(S));$

4:      $S \leftarrow S \cup \{u\}$

---