

# Введение в эконометрику сетей

Владислав Морозов

27 декабря 2016 г.

- 1** Определения, нотация и мотивация
- 2** Примеры вопросов и три постановки
- 3** Влияние структуры
- 4** Идентификация DGP
- 5** Формирование сетей
- 6** Работа с выборочными данными

## Основные определения

### Определение

*Графом называется пара  $(V, E)$  из множества вершин  $V$  и множества ребер  $E$ .*

Граф представим в виде матрицы смежности **A**:

$$A_{ij} = \begin{cases} 1, & ij \in E \\ 0, & ij \notin E \end{cases} \quad (1)$$

## Плотность и распределение степеней

### Определение

*Плотность: сколько ребер из возможных  $C_n^2$  существует:*

$$\text{density} = \frac{1}{C_n^2} \sum_{i < j} A_{ij} \quad (2)$$

### Определение

*Распределение степеней – CDF:*

$$F_d(x) = \frac{|\{i : d_i \leq x\}|}{n} \quad (3)$$



# Кластеринг и гомофилия

## Определение


*Локальный коэффициент кластеринга показывает, какова вероятность, что два соседа вершины  $i - j$  и  $k$  связаны сами:*

$$c(g) = \frac{\sum_{j < k} A_{ij} A_{ij} A_{jk}}{C_{d_i}^2} \quad (4)$$

*Гомофилия: подобное притягивает подобное.*


- Корреляция в ребрах из-за каких-то личных характеристик
- Не путать со структурной транзитивностью (Graham, 2014): корреляция из-за стимулов к образованию связей





**Blue: Black**  
**Reds: Hispanic**  
**Yellow: White**  
**Pink: Other**  
**Light Blue:**  
**Missing**

“strong friendships”  
cross group links less than half as frequent



<i>Data Source</i>	Average Degree	Density	Clustering	Average Path Length	Number of Networks	Average Number of Nodes
AddHealth	3.361	0.042	0.411	--	14	80.36
China Villages	3.266	0.113	--	2.578	185	28.82
Harvard Dorm	10.830	0.019	0.181	3.260	1	569
Harvard Facebook-Based	7.917	0.003	0.174	4.571	1	2360
Karnataka Villages	17.378	0.089	0.303	2.337	75	213.37
Malawi Villages	6.189	0.061	0.234	3.089	21	133.48
Uganda Village	8.300	0.069	0.230	2.500	1	119

## Эндогенные и экзогенные эффекты

Manski (1993) – два канала социального влияния:

- *Эндогенные* эффекты: влияние исходов других вершин на исход вершины  $i$ . Работают как каналы связи + эффект мультипликатора.

*Пример:* успеваемость  $i$  меняется вместе с успеваемостью его окружения

- *Экзогенные (контекстуальные)* эффекты: влияние характеристик вершины  $i$  на ее исходы.

*Пример:* на успеваемость влияет социоэкономический статус вершины

Проблема: эффекты сложно вычленяются. *Пример:* успеваемость зависит от учителя

## Какие вопросы могут нас интересовать?

- Как жители деревни в Танзании организуют risk-sharing? Какие есть внешние эффекты при этом? (Comola, 2016)
- Как распространяется знание о микрофинансировании? (BDSJ, 2013)
- Как студенты заводят дружбу? (Польдин, Креховец 2014)
- Насколько сильна гомофилия? (Hsieh, Lee 2015)

## Три типа вопросов

Вопрос

Как сетевая структура влияет на социальные исходы?

Вопрос

Какой DGP лежит в основе данных?

Вопрос

Как формируются сети?

## Влияние характеристик сети на исходы

Простой случай:

$$y_i = \alpha + \beta\omega(G) + \varepsilon_i \quad (5)$$

Можно оценивать:

- Network-wide регрессии, если у нас много сетей и есть какие-то общие исходы (распространение информации о МФ у BDSJ (2013))
- Node-level регрессии: влияние индивидуальных сетевых характеристик на какие-то его исходы

## Классическая линейная модель Манского

Manski (1993) предложил классическую линейную модель влияния сетевой структуры на исходы в обществе из  $N$  индивидов:

$$y_i = \alpha + \beta \sum_{j=1}^N A_{ij} y_j + \eta \mathbf{x}_i + \gamma \sum_{j=1}^N A_{ij} \mathbf{x}_j + \varepsilon_i \quad (6)$$

С предпосылкой, что  $E(\varepsilon_i | \mathbf{x}, A) = 0$ .

Если  $1/\beta$  не собственное значение  $A$ , то записывается в следующей форме (Manski Reduced Form):

$$\mathbf{y} = \alpha(\mathbf{I} - \beta A)^{-1} \mathbf{1} + (\mathbf{I} - \beta A)^{-1} (\eta \mathbf{I} + \gamma A) \mathbf{x} + (\mathbf{I} - \beta A)^{-1} \boldsymbol{\varepsilon} \quad (7)$$

## Можно ли оценить коэффициенты?

### Теорема

Если  $|\beta| < 1$ ,  $\eta\beta + \gamma \neq 0$ ,  $A_{ij} = (N - 1)^{-1}$  для  $i \neq j$ , а  $A_{ii} = 0$ , то  $(\alpha, \beta, \eta, \gamma)$  не определяются однозначно.

Насколько эта проблема общая?

## Теорема об идентификации

Bramouille, Djebbari и Fortin (2009) дают теорему:

### Теорема

Если  $\eta\beta + \gamma \neq 0$  и  $I$ ,  $A$  и  $A^2$  линейно независимы, то существуют оценки для  $(\alpha, \beta, \eta, \gamma)$ .

Насколько это жесткое условие?

Blume, Brock, Durlauf и Jayaraman (2015):

### Теорема

Если  $\sum_{j=1}^N A_{ij} = 1$  и  $A_{ii} = 0$ , и  $I$ ,  $A$  и  $A^2$  линейно зависимы, то  $A$  – блочно-диагональная матрица с блоками одного размера  $N_t$ , а все ненулевые элементы имеют вид  $(N_t - 1)^{-1}$ .

## А если мы не знаем $A$ ?

Manresa (2014) рассматривает регрессию (с панельными данными):

$$y_{i,t} = \alpha + \beta \sum_i \frac{A_{ij}}{d_i} x_{j,t} + \delta x_{i,t} + \varepsilon_{i,t} \quad (8)$$

В случае разреженной сети pooled LASSO (Tibshirani, 1996; Meinshausen and Yu, 2009) может получить оценки для коэффициентов и матрицы.

Если есть какая-то ненаблюдаемая гетерогенность, то требуются наблюдения в «достаточном» числе периодов. Graham (2014) выводит оценки для этого числа.

## Возможные нелинейности

Два основных канала:

- Нелинейные формы влияния:

$$y_i = f \left( \sum_{j=1}^N A_{ij} y_j, x_i, \sum_{j=1}^N A_{ij} x_j \right) \quad (9)$$

- Нелинейная реакция на исходы других участников (например,  $\min_{A_{ij} \neq 0} y_j$ )

## Оценка нелинейных форм

### Теорема

Если  $A_{ij} = (N - 1)^{-1}$  для  $i \neq j$ , а  $A_{ii} = 0$ , то невозможно однозначно оценить  $f$ .

Blume, Brock, Durlauf, Ioannides (2011) – хороший обзор случаев, когда оценка возможна: бинарный и множественный выбор особенно хорошо оцениваются

Tincani (2015) – пример нелинейного агрегирования исходов других участников на примере успеваемости в Перу.

# Модели формирования сетей

Несколько основных классов:

- *Conditional edge independence*: агенты формируют связи только на основе своих атрибутов и шоков
- *Higher order dependence*:
  - ERGM
  - SERGM
  - SUGM
  - Strong homophily

## О проблемах с информацией

В оценке параметров могут возникать существенные проблемы из-за недостатка информации. Два крайних случая:

- В модели Эрдеша-Реньи все ребра генерируются независимо друг от друга.  $N$  эффективных наблюдений
- С другой стороны: все ребра могут быть полностью коррелированы: одно эффективное наблюдение

Нетривиальная проблема.


## Модель Эрдеша-Реньи

Все ребра независимо друг от друга возникают с вероятностью  $p$ .


Свойства:

- $E(d_i) = (N - 1)p$ ;
- Нет кластеринга
- Не отражает гомофилию


Если данные только по одной сети, мы оценивает  $p$  как число, хотя оно может быть функцией. Не можем различать между плотными и разреженными сетями.




(A) Nodes



(B) Radii



(C) Links



(D) Network

## Preferential Attachment и гибридные модели


Jackson, Rogers (2007) предлагают простой в оценке гибридной модели Эрдеша-Реньи и модель с preferential attachment (Barabasi, Albert 2001):

$$F(d) = 1 - \left( \frac{m + \alpha mx}{d + \alpha mx} \right)^x \quad (10)$$


- $x = 2/(1 - \alpha)$
- $m$  – число связей, формируемых каждый период в модели ВА
- $\alpha$  – пропорция связей, формируемых равномерно случайно в периоде

Оценивается  $m$ , потом минимизируется расстояние между фактическим распределением и теоретическим, чтобы найти  $\alpha$ .


### Small World Citations




### Prison Inmate Friendships




### Ham Radio



### High School Romance





## Блочные модели

Блочные модели (Comola and Fafchamps, 2013) – обобщение модели Эрдеша-Реньи на случай, когда характеристики агентов влияют на вероятности.


Можно пытаться изучать связи вида:

$$\log \frac{p_{ij}}{1 - p_{ij}} = \beta_i x_i + \beta_j x_j + \beta_{ij} |x_i - x_j| \quad (11)$$

В итоге это записывается в модель:

$$P(g|\mathbf{x}) = \prod_{i < j} p(x_i, x_j)^{A_{ij}} (1 - p(x_i, x_j))^{1 - A_{ij}} \quad (12)$$

Что, если мы не наблюдаем все характеристики и блоки или есть гетерогенность на индивидуальном уровне?



## ERG модели

Пусть теперь вероятности образования ребер явным образом коррелированы и зависят от возможных структур на графе.

Пример:

$$p = f(L, T) \quad (13)$$

Традиционно выражается как:

$$P_{\beta}(g) = \frac{\exp(\beta \cdot S(g))}{\sum_{g'} \exp(\beta \cdot S(g'))} \quad (14)$$

## Чем хороши ERGM?

### Теорема (Теорема Хаммерсли-Клиффорда)

Любая сеть может быть выражена через ERGM, если подобрать правильный набор статистик  $S$ .

- К  $S$  можно отнести произвольные статистики для графа и вершин
- ERGM дают фантастическую гибкость для подбора параметров

## Как оценивают ERGM?

Есть два основных подхода:

- В теории: метод максимального правдоподобия. На практике не используется, потому что знаменатель не может быть реалистично вычислен прямо
- Вариационные принципы (пример у Chatterjee, Diaconis (2013))
- MCMC: имплементация в пакете `statnet` в R


## Проблемы с оценкой ERGM

Очень существенные проблемы в оценке таких моделей:


- Краевые вырожденности цепи (Snijders, 2002): бимодальные или полимодальные распределения, резкие скачки параметров
- Экспоненциальное время для сходимости во многих регионах, полиномиальное время только в регионах, где ребра почти независимы (что делает применение ERGM совершенно бессмысленным)

Пример симуляции:  $n = 50$ ,  $t = 1000$ , 20 изолированных, 10 треугольников, 45 ребер


# ERGM Parameter Estimate



# ERGM Parameter Estimate



# ERGM Parameter Estimate



# SERGM

Чтобы сократить размерность, схлопываем все «одинаковые» графы. Получаются статистические ERG модели:

$$P_{\beta} = \frac{N(s) \exp(\beta \cdot S)}{\sum_{s'} N(s') \exp(\beta \cdot S)} \quad (15)$$

Суммирование идет уже по классам.

А хватит ли нам информации? Chandrasekhar и Jackson (2014) дают условия, при которых с ростом  $n$  оценки ММП сходятся к истинным значениям.

# SUGM


Идет генерация по подграфам: треугольники, потом звезды, потом одиночные ребра. Интуиция: агенты постепенно организуют некие связи разных форм, образуя в итоге сеть.

Главная проблема: наблюдаем только итоговую сеть. Если она плотная, почти невозможно оценить адекватно параметры. Большая часть наблюдаемых экономических сетей разреженная (Chandrasekhar (2015) дает оценки для этого).


Секвенциальная оценка параметров: выбрать структуру, найти все образцы, оценить логит-модель для нее, убрать все такие структуры. Повторять, пока не останется пустая сеть.



(A)  $n$  nodes




(B) Triangles form



(C) Links form




(D) Network




(E)  $n$  nodes



(F) Triangles form



(G) Links form



(H) Network

## Эконометрическая версия connections game

Самая простая возможная игра стратегического формирования сети. Jackson, Wolinsky (1996):

$$U_i(g) = \sum_{j \in 1, \dots, n, j \neq i} \delta^{d(i,j;g)-1} (1 + \varepsilon_{ij}) - |N_i(g)| \quad (16)$$

### Вопрос

Как оценить параметры?

Выбрать solution concept: обычно pairwise stability (Jackson, Wolinsky, 1996). Miyauchi (2016) работает с симуляциями, чтобы найти максимально «подходящие параметры».

## Проблема смещенности данных

В случае использования выборочных данных мы начинаем терять структуру и каналы влияния. Даже если оценки состоятельные, они становятся все более смещенными со снижением sampling rate.


Полное изучение проблемы – Chandrasekhar, Lewis (2015)

Рассматриваем регрессию исходов на характеристики сети:


$$y_r = w_r \beta_0 + \varepsilon_r \quad (17)$$

Если есть ошибка измерения, то имеем регрессор  $\tilde{w}$ :


$$\text{plim} \hat{\beta} = \beta_0 \frac{\text{Cov}(\tilde{w}, w)}{\text{Var}(\tilde{w})} \quad (18)$$




(A) Graph  $G$




(B) Sampled nodes  $S$




(C) Induced subgraph



(D) Highlights links used in star subgraph



(E) Star subgraph



(F) Star subgraph

## Два способа коррекции

Chandrasekhar, Lewis (2015) предлагают два способа для преодоления проблемы:

- Аналитическая коррекция: для каждой характеристики сети надо подбирать отдельную коррекцию. Минус в том, что приходится строить новые сложные статистики для каждой статистики заново.
- Двухшаговая графическая реконструкция: универсальный способ.
  - 1 Оценить по данным распределение, из которого извлечены сети
  - 2 На основе этих теоретических данных оценить

# Введение в эконометрику сетей

Владислав Морозов

27 декабря 2016 г.