

Lintner, Tomáš

**Siete vo vzdelávaní : možnosti využitia analýzy sociálnych sietí v pedagogickom výskume**

*Studia paedagogica*. 2020, vol. 25, iss. 3, pp. [153]-185

ISSN 1803-7437 (print); ISSN 2336-4521 (online)

Stable URL (DOI): <https://doi.org/10.5817/SP2020-3-6>

Stable URL (handle): <https://hdl.handle.net/11222.digilib/142862>

Access Date: 30. 11. 2024

Version: 20220831

Terms of use: Digital Library of the Faculty of Arts, Masaryk University provides access to digitized documents strictly for personal use, unless otherwise specified.

# SIETE VO VZDELÁVANÍ: MOŽNOSTI VYUŽITIA ANALÝZY SOCIÁLNYCH SIETÍ V PEDAGOGICKOM VÝZKUME

## NETWORKS IN EDUCATION: MAKING USE OF SOCIAL NETWORK ANALYSIS IN EDUCATIONAL RESEARCH

TOMÁŠ LINTNER

### Abstrakt

*Analýza sociálnych sietí si svojim širokým využitím nachádza miesto v množstve vedeckých odborov. V pedagogickom výskume má potenciál odhaliť a preskúmať doteraz neznáme usporiadania vzťahov medzi aktérmi vo vzdelávaní. Tento článok poskytuje úvod do problematiky, technik a využitia analýzy sociálnych sietí v pedagogickom výskume. V prvom rade predstavuje základnú terminológiu a koncepty analýzy sociálnych sietí. Na príklade malej siete ilustruje základné sieťové výpočty tak na úrovni jednotlivých aktérov, ako na úrovni celej siete. Článok ďalej poskytuje stručný prehľad štúdií z pedagogického výskumu, v ktorých bola analýza sociálnych sietí využitá. Hlavná časť článku na príklade fiktívnej triedy a piatich výskumných otázok ukazuje možnosti analýzy sociálnych sietí v pedagogickom výskume od základnej prierezovej analýzy po dynamickú inferenčnú analýzu. Krok za krokom sú predstavené rôzne metódy s následnou interpretáciou ich výsledkov. Okrem výpočtov centralít, klastrovacieho koeficientu a prepojenosti siete sú v príkladoch predstavené aj permutačné testy pri testovaní významnosti za využitia sieťových dát, ERGM (exponential random graph models) a STERGM (separable temporal exponential graph models). V neposlednom rade sú prediskutované problémy spojené s využitím analýzy sociálnych sietí.*

### Kľúčové slová

*SNA, analýza sociálnych sietí, komplexné siete, metodológia v pedagogickom výskume, modely sociálnych sietí, ERGM*

### Abstract

*With its wide range of applications, social network analysis has found its place in a number of scientific fields. In educational research, social network analysis has the potential to uncover and investigate yet unknown configurations of relationships among actors in education. This paper provides an introduction to the issues, techniques, and applications of social network analysis in educational research. It first surveys the basic*

*terminology and concepts in social network analysis. Using the example of a small network, it demonstrates basic network calculations at the level of both the individual actors and the network as a whole. Furthermore, the paper provides a brief overview of studies in the field of educational research that have employed social network analysis. Using the example of a fictional classroom and five research questions, the main part of the paper demonstrates the application of social network analysis in educational research ranging from cross-sectional descriptive analysis to dynamic inferential analysis. Step by step, it introduces a range of methods and interprets their results. In addition to centrality, clustering, and connectedness measures, the example contains permutation tests used for significance testing with network data, exponential random graph models (ERGM), and separable temporal exponential graph models (STERGM). Finally, the paper discusses challenges related to the application of social network analysis.*

### Keywords

*social network analysis, SNA, complex networks, methodology in educational research, social network models, ERGM*

## Úvod


Zatiaľ čo v prírodných vedách panuje široký konsenzus, že skúmané fenomény vieme vedeckými metódami odmerať, vzťahy medzi nimi modelovať, naše modely experimentálne overiť a dostať sa tak k objektívnej pravde, v sociálnych vedách sa ujala škála epistemologických pozícií, ktoré viac alebo menej spochybňujú možnosti sociálnych vied realisticky popísať fenomény sociálneho sveta. Jednou z najčastejších výhrad je fakt, že sociálne fenomény sú tak komplexné a navzájom prepojené, že odmerať a popísať všetky ich súčasti je prakticky nemožné. Čo však sociálne vedy robiť môžu a robiť by mali, je využiť dostupné prostriedky a prinášať nové zistenia, ktoré ak aj nebudú odrážať objektívnu pravdu, budú sa k nej aspoň približovať (Radford, 2008). Analýza sociálnych sietí (social network analysis – SNA) má potenciál takýmto prostriedkom byť a na množstvo fenoménov sociálneho sveta priňať nový – realistickejší pohľad. SNA prináša možnosti pojať prepojenosť sociálneho sveta a preklenúť hranice medzi správaním jednotlivcov, správaním skupín a správaním spoločnosti tým, že berie v úvahu nielen existenciu a typ vzťahov medzi jednotlivcami, ale celú štruktúru vzťahov a polohu jednotlivcov v týchto štruktúrach (Borgatti et al., 2009).

Sieť je v analýze sociálnych sietí štruktúra pozostávajúca z aktérov a väzbami medzi aktérmi (obrázok 1). Vzhľadom na to, že sociálne procesy sú spôsoby, akými jednotlivci, skupiny a inštitúcie interagujú; spôsoby, akými väzby medzi aktérmi vznikajú a zanikajú (Shibutani, 2000), tieto procesy sú zo svojej podstaty zakorenené v sociálnych štruktúrach, ktoré sa koncept sociálnych sietí snaží uchopiť a poskytnúť výskumný rámec pre ich analýzu (Scott, 2017). Koncept sociálnych sietí bol začlenený do teórie sociálneho kapitálu (Lin, 2017) či teórie sociálnej kontroly (Daldal, 2014) a najmä vďaka

technologickému vývoju umožňujúcemu komplexné štatistické analýzy za posledných päťdesiat rokov rádozo vzrástol záujem o analýzu sociálnych sietí ako aj publikované štúdie s jej využitím (Knoke & Yang, 2020; Wasserman & Faust, 2019).

V kontexte pedagogického výskumu môže sieť reprezentovať širokú škálu akérov a väzieb medzi nimi. Od najmenších sociálnych štruktúr vo vzdelávaní vo forme žiakov, učiteľov, rodičov a vzťahov medzi nimi, po makro-štruktúry na úrovni škôl, krajín či vzdelávacích politík. SNA má v pedagogickom výskume potenciál rozšíriť doterajšie poznanie tým, že umožňuje skúmať, merať a testovať, ako sú aktéri vo vzdelávaní a vzťahy medzi nimi usporiadané.

Tento článok je úvodom do problematiky analýzy sociálnych sietí v pedagogických vedách. Článok si kladie za cieľ predstaviť analýzu sociálnych sietí, uviesť príklady jej využitia v existujúcom pedagogickom výskume a na sérii praktických príkladov ilustrovat' jej možnosti. Nejedná sa o článok zachádzajúci do detailov špecifikácie jednotlivých modelov, o manuál analytických softvérov ani o vyčerpávajúcu prehľadovú štúdiu využitia analýzy sociálnych sietí. Článok ničmenej intenzívne odkazuje tak na teoretické štúdie, ktoré dali metódam používaným v tomto článku podobu, ako aj na praktické manuály pre užívateľov jednotlivých softvérov či príklady dobrej praxe. Napriek tomu, že článok sa zameriava na využitie analýzy sociálnych sietí v pedagogickom výskume, metódy preberané v článku sú aplikovateľné pre široké spektrum sociovedného výskumu.



Obrázok 1

*Ilustrácia siete – kruhy znázorňujú aktérov, čiary väzby medzi aktérmi*

## Základy analýzy sociálnych sietí

Analýza sociálnych sietí (*social network analysis* – SNA) je súhrn metód založených na teórii grafov, algebry a priestorových analýz (Scott, 2012). SNA umožňuje nahliadať na sociálne štruktúry a komplexné vzťahy tak, aby verne reflektovali reálnu podobu sociálnych sietí vo svete (Wasserman & Faust, 2019). Súčasná podoba SNA je ovplyvnená práve štrukturálnym prístupom v sociologickom výskume, ktorý stavia úlohu sociálnych štruktúr a ich vplyv na aktérov v spoločnosti do popredia záujmu. Napriek tomu, že stavia na princípoch Morenovej sociometrie (Moreno, 1934) a Whiteovej relačnej sociológie (White, 2008), pridáva k nim princípy využitia systematického zberu empirických dát a využitia matematických modelov na skúmanie štrukturálnych procesov (Freeman, 2004). SNA otvára možnosti sociálne štruktúry vierohodne merať, vysvetľovať spôsoby, ako vznikli, a vysvetľovať ich vplyv na jednotlivých aktérov v rámci sociálnych sietí (Knoke & Yang, 2020). Súčasná podoba SNA so širokou škálou softvérov umožňuje tak deskriptívne a exploratórne analýzy, ako aj inferenčné siet'ové modely, spolu so širokými možnosťami zobrazovania sociálnych sietí.

Hlavnými prvkami SNA sú vrcholy reprezentujúce aktérov v sociálnej sieti a hrany reprezentujúce vzťahy medzi aktérmi. Spojenia môžu byť orientované (*directed*), v prípade, že záleží na smere spojenia – napríklad vrchol N1 môže prechovávať sympatie k vrcholu N2, vrchol N2 už ale nie k vrcholu N1; alebo neorientované (*undirected*), v prípade, že na smere spojenia nezáleží, sociálna sieť reprezentuje iba existenciu vzájomného spojenia. Okrem samotných vrcholov a hrán sú v SNA často dôležité aj vlastnosti (*attributes*) jednotlivých vrcholov a hrán. Vlastnosti vrcholov môžu byť tak kategorické – napríklad pohlavie aktérov, ako numerické – napríklad vek aktérov. V prípade, že sa jedná o vlastnosti hrán, rozlišujeme medzi hranami binárnymi – hrana buď existuje, alebo nie, a váženými – hrana má okrem svojej existencie ďalšie vlastnosti, ktoré môžu byť tak numerické – napríklad počet hodín, ktorý spolu dvaja aktéri strávili, ako kategorické – napríklad typ vzťahu medzi aktérmi.

$\begin{pmatrix} 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{pmatrix}$	<pre>[[1,2], [1,3], [2,1], [2,3], [3,1], [3,2], [3,4], [4,3], [4,5], [5,4], [5,6], [5,7], [7,5], [7,6], [8,7], [9]]</pre>
---	---

Obrázok 2

*Matica susednosti (vľavo) a zoznam hrán (vpravo) siete X1*

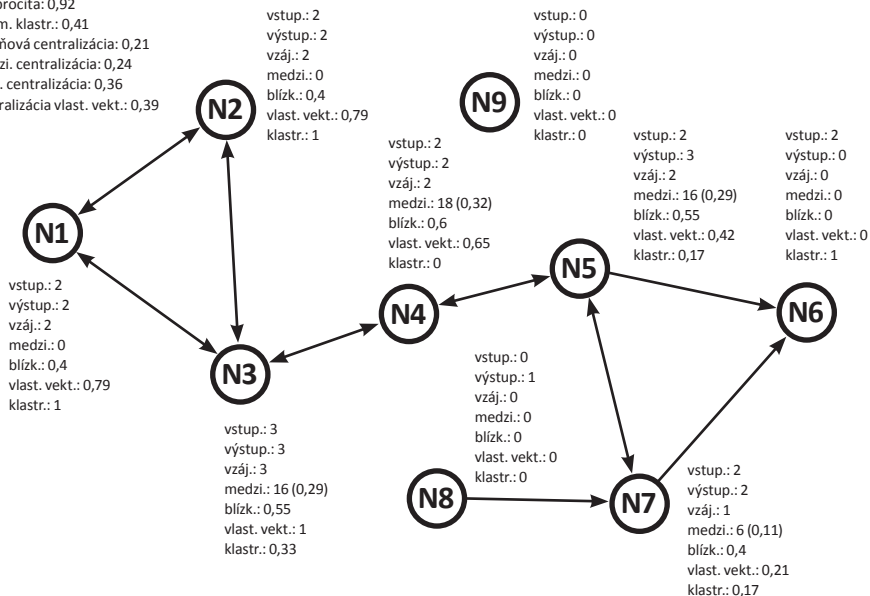
Sociálna sieť je v SNA reprezentovaná maticou susednosti (*adjacency matrix*) alebo zoznamom hrán (*edge list*). Matica susednosti zobrazuje vzťahy medzi aktérmi siete v dvojdimenznom rozložení, zatiaľ čo zoznam hrán zobrazuje zoznam vzťahov medzi aktérmi siete. Väčšina SNA softvérov vie spracovať dáta z oboch typov reprezentácií a rozdiel je iba vo forme zdrojových dát. Zatiaľ čo matica susednosti vie byť intuitívnejšia a sama o sebe prezradiť základnú štruktúru siete, zoznam hrán vie byť užitočnejší pri sieťach s veľkým počtom vrcholov, kde by matica susednosti nadobudla neprakticky veľké rozmery<sup>1</sup>. Obrázok 2 zobrazuje maticu susednosti 9 x 9 orientovanej siete, kde hodnota 1 reprezentuje prítomnosť a hodnota 0 neprítomnosť vzťahu spolu so zoznamom hrán tej istej siete, kde pri sebe uvedené vrcholy majú medzi sebou hranu.

Obrázok 3 zobrazuje orientovanú sieť X1 vytvorenú z predošlej matice susednosti (resp. zoznamu hrán) s 9 vrcholmi N1 až N9, 15 binárnymi hranami, z ktorých 12 tvorí 6 vzájomných hrán a 3 hrany sú jednosmerné ([N8, N7], [N7, N6], [N5, N6]). 8 vrcholov je vzájomne prepojených v jednom komponente (skupina vzájomne prepojených vrcholov) a jeden vrchol (N9) je izolovaný. Predstavme si, že naša sieť reprezentuje 9 ľudí a ich komunikačné kanály. Graf je orientovaný, čo znamená, že nie každá hrana znamená vzájomnú komunikáciu. Zatiaľ čo informácia od N8 sa vie dostať ku každému okrem N9, informácia od N1 sa nedostane ani k N9, ani k N8, keďže N8 informácie neprijíma. Základnými výpočtami štruktúrálnych vlastností siete sa budeme snažiť identifikovať najvplyvnejšie vrcholy, nájsť v rámci siete podskupiny a posúdiť prepojenosť siete.

<sup>1</sup> Scott (2017) a Carrington et al. (2009) do detailov rozoberajú rozdielne prístupy k dátam v SNA vrátane zberu dát.

## ŠTRUKTURÁLNE VLASTNOSTI SIETE

hustota: 0,21  
 priemer: 5  
 reciprocita: 0,92  
 priem. klastr.: 0,41  
 stupňová centralizácia: 0,21  
 medzi. centralizácia: 0,24  
 blížk. centralizácia: 0,36  
 centralizácia vlast. vekt.: 0,39



Obrázok 3

Zobrazenie siete X1 so základnými štrukturálnymi premennými

Položme si otázku: kto je v sieti najvplyvnejší? Kto vie najviac ovplyvniť tok informácií? Ak by sme nevideli štruktúru siete, odpoveď by pravdepodobne znela N3, keďže šíri a rovnako tak prijíma informácie od najväčšieho počtu ľudí ( $n = 3$ ). Keď sa však na štruktúru siete pozrieme, uvidíme, že v závislosti toho, ako koncept vplyvu uchopíme, N4 má potenciál byť nemenej vplyvný než N3, a to napriek tomu, že má o jednu vzájomnú väzbu menej. Jedným z kľúčových konceptov SNA je výpočet centrality vrcholov. Výpočty centralít sa snažia odhaliť relatívny vplyv vrcholov v sieti na základe ich polohy v sieti (Bonachich, 1987; Borgatti, 2005). Existujú desiatky výpočtov centralít a každá z nich koncept vplyvu berie inak. Neexistuje jeden výpočet centrality, ktorý jednoznačne odpovie na otázku, ktoré vrcholy sú v sieti najvplyvnejšie. Každá z centralít meria niečo iné, preto je prospešné vziať do úvahy rôzne výpočty centralít a je na výskumníkovi, aké závery z hodnôt centralít urobí. Hodnoty centralít počítame vždy pre jeden komponent, všetky nasledujúce príklady sú preto počítané pre komponent s 8 vrcholmi bez izolovaného vrcholu<sup>2</sup>.

<sup>2</sup> Pre teoretický základ výpočtu centralít pozri Friedkin (1991), pre detailný prehľad výpočtov centralít a ich aplikácie pozri Landherr et al. (2010) a Valente et al. (2008).

Najjednoduchším a najzákladnejším výpočtom centrality je *stupeň* (*degree centrality*), ktorý meria počet väzieb vrcholu. V prípade orientovaných sietí sa jedná o *vstupný stupeň* (*in-degree*) s počtom hrán, ktoré smerujú k danému vrcholu, a *výstupný stupeň* (*out-degree*) s počtom hrán, ktoré smerujú od daného vrcholu. Výpočet centrality na základe hodnoty stupňa je založený na myšlienke, že vyšší počet väzieb umožňuje väčšie možnosti priamo ovplyvňovať ostatných aktérov, prípadne získať priamo informácie od väčšieho množstva aktérov. V sieti *X1* má najväčšiu hodnotu vstupného stupňa vrchol N3 (3), ktorý má zároveň spolu s vrcholom N5 najväčšiu hodnotu výstupného stupňa (3).

Iným typom centrality je *medziľahlosť* (*betweenness centrality*), ktorá meria počet najkratších ciest (*geodesic paths*), ktoré cez daný vrchol prechádzajú od všetkých ostatných vrcholov ku všetkým ostatným vrcholom. Medziľahlosť je mimoriadne dôležitá pri identifikácii vplyvu aktérov na tok komunikácie, prípadne inej výmeny medzi aktérmi, kde je dôležitá najkratšia vzdialenosť medzi vrcholmi. Odráža vplyv aktéra na základe toho, akú úlohu zohráva ako most medzi ostatnými aktérmi v rámci siete (Freeman, 1977). Ak by sa v sieti *X1* vrchol N4 rozhodol zdržať tok informácií, žiadne neposielat' ďalej a štruktúra siete by zostala nezmenená, ovplyvnil by tým 18 informačných kanálov v sieti, zatiaľ čo ak by sa rovnako zachoval N3, ovplyvnil by ich iba 16. Napriek tomu, že N3 má vyššiu hodnotu tak vstupného, ako aj výstupného stupňa, N4 má väčší potenciál ovplyvniť tok informácii medzi ostatnými vrcholmi. N4 je najvplyvnejším mostom v sieti, cez ktorý prechádza najväčší počet informácií.<sup>3</sup>

Ak chceme vziať do úvahy vzdialenosti, ktoré informácie musia prejsť od jedného vrcholu k ostatným, budeme počítať *blízkosť* (*closeness centrality*) vrcholu. Blízkosť podobne ako medziľahlosť využíva na určenie vplyvu najkratšie vzdialenosti medzi vrcholmi. Blízkosť však vyjadruje to, ako blízko má daný vrchol k ostatným nezávisle od toho, či cez neho prechádzajú najkratšie cesty ostatných vrcholov. Je počítaná priemernou dĺžkou najkratších vzdialeností daného vrcholu k ostatným (Sabidussi, 1966) – na obrázku 3 normalizovaná do hodnoty 0–1, kde hodnota 1 značí najkratšie vzdialenosti a najvyššiu hodnotu blízkosti. V sieti *X1* má najvyššiu hodnotu blízkosti vrchol N4 (0,6), a teda je z ostatných vrcholov v priemere najbližšie k ostatným. V neposlednom rade *centralita vlastného vektora* (*eigenvector centrality*) meria vplyv vrcholu s predpokladom, že pre vrchol nie je dôležitý priamo jeho vlastný vplyv, ale vplyv vrcholov tesne pri ňom. Vysoká hodnota centrality vlastného

<sup>3</sup> Hodnota polohovej centrality sa dá, podobne ako pri ostatných centralitách, normalizovať do hodnoty 0–1 (na obrázku 3 v zátvorkách).



vektora naznačuje, že vrchol má spojenia s inými vrcholmi, ktoré majú sami vysoké hodnoty centrality vlastného vektora (Bonachich, 1987; 2007). Inými slovami, vrchol s vysokou hodnotou centrality vlastného vektora bude mať potenciál ovplyvniť ostatných aktérov v sieti cez vrcholy, s ktorými má priame väzby. V sieti *X1* má najvyššiu hodnotu centrality vlastného vektora vrchol N3.

Okrem prominentných vrcholov je prospešné identifikovať v sieti podskupiny – v najširšom slova zmysle definované ako vrcholy, ktoré majú medzi sebou v porovnaní so zvyškom siete hustejšie väzby. Podskupiny v sieti sú charakteristické tým, že vo vnútri majú medzi sebou silné prepojenia, no s vrcholmi mimo podskupiny sú spojené iba malým počtom väzieb. Z pohľadu pedagogiky môžu podskupiny reflektovať napríklad vrstevnícke skupiny, neformálne skupiny učiteľov, alebo skupiny spolupráce pri kolaboratívnom učení. Najzákladnejším typom podskupiny je klika (*clique*), ktorá je definovaná ako súhrn vrcholov, kde každý vrchol má s ostatnými vrcholmi medzi sebou väzby, a jedná sa teda o úplný graf. V sieti *X1* je úplná klika len jedna a pozostáva z troch vrcholov – N1, N2, N3. Okrem tejto kliky je v sieti aj neúplná klika medzi vrcholmi N5, N6, N7, kde vrchol N6 zvyšným dvom vrcholom vzťahy neopätuje. Tendencia združovať sa do klík je vyjadrená *klastrovacím koeficientom (clustering coefficient)*, ktorý vyjadruje pomer väzieb susediacich vrcholov, ktoré vedú k ostatným vrcholom, s ktorými má daný vrchol väzby. Hodnota klastrovacieho koeficientu 1 značí, že vrchol má väzby iba s takými vrcholmi, ktoré majú zároveň väzby medzi sebou.<sup>4</sup> Z pohľadu celej siete je možné určiť tendenciu združovať sa do klík *priemerným klastrovacím koeficientom (average clustering coefficient)*, ktorý je vypočítaný ako priemer klastrovacích koeficientov vrcholov v sieti. Hodnota klastrovacieho koeficientu siete *X1* 0,41 naznačuje, že v priemere skoro polovica väzieb vedie k takým vrcholom, ktoré majú zároveň väzby medzi sebou.<sup>5</sup>

Na úrovni siete je okrem priemerného klastrovacieho koeficientu dôležitá aj jej prepojenosť. Čím je sieť prepojenejšia, tým budú k sebe vrcholy bližšie a tým jednoduchšie (príp. rýchlejšie) bude v sieti prebiehať tok informácií. Medzi základné výpočty prepojenosti siete patria *hustota siete (network density)* vypočítaná ako pomer existujúcich väzieb k všetkým možným väzbám,

<sup>4</sup> Pre rozsiahlejší text o klikách pozri Wasserman a Faust (2019).

<sup>5</sup> Pokročilejšími metódami identifikácie podskupín v sieti sú algoritmy na detekciu podskupín v sieti (*community detection algorithms*), ktoré vedia byť užitočné najmä pri veľkých alebo hustých sieťach, kde na identifikáciu podskupín nestačia základné sieťové výpočty (Fortunato, 2010).

ktoré by v sieti mohli vzniknúť; *priemer siete* (*network diameter*) vypočítaný ako najkratšia vzdialenosť medzi dvoma najvzdialenejšími vrcholmi; *centralizácia siete* (*network centralization*) vyjadrujúca, ako veľmi je sieť postavená okolo malého počtu centrálnych aktérov, vypočítaná na základe špecifického typu centrality; a v orientovaných sieťach tiež *reciprocita* (*reciprocity*) vypočítaná ako pomer väzieb v sieti, ktoré sú vzájomné. Na úrovni vrcholov je reciprocita vyjadrená buď počtom vzájomných (na obrázku 3) väzieb, alebo pomerom opätovaných väzieb. Hustota siete  $X1$  je 0,21 a jej priemer 5 (vzdialenosť medzi vrcholmi N8 a N1) pri počte vrcholov 9 naznačuje, že sieť je relatívne málo prepojená. Pre ilustráciu sú pre sieť vypočítané hodnoty centralizácie pre všetky hore uvedené typy centralít s hodnotou od 0,21 pre stupňovú centralizáciu po 0,39 pre centralizáciu vlastného vektora. Hodnoty centralizácií nenaznačujú veľkú tendenciu vrcholov zoskupovať sa okolo centrálnych aktérov. Hodnota reciprocit 0,92 naznačuje, že väčšina hrán je vzájomných.

### SNA v pedagogickom výskume

Zatiaľ čo metódy založené na sociometrii sú ako v česko-slovenskom (Nagy et al., 2018; Kalkusová, 2017; Šalamounová & Fučík, 2019; Titmanová, 2019; Vítová et al., 2013), tak vo svetovom (Barclay, 1967; Baron, 1951; Cerezo & Ato, 2005; Kindermann, 2007; Leung & Silberling, 2006; Peery, 1979) pedagogickom výskume pomerne zaužívané, metódy založené na analýze sociálnych sietí za využitia matematických modelov sú využívané zriedka a začali sa objavovať iba nedávno. V nasledujúcej časti odkazujem na príklady využitia SNA v existujúcom pedagogickom výskume.

Niekoľko autorov využilo SNA pri skúmaní dynamiky tvorby vzťahov medzi žiakmi na úrovni triedy. Výskum v inkluzívnych predprimárnych triedach tímu Chen et al. (2019) preukázal segregáciu detí s postihnutím a menšie rozmery sociálnych sietí detí s postihnutím v porovnaní s deťmi bez postihnutia. Štúdia tímu Anderson et al. (2016) naznačuje, že kombinácia veľkosti triedy a pohlavia žiakov má vplyv na sociálnu pozíciu žiakov s poruchami autistického spektra v inkluzívnych triedach. Zaradenie do väčších tried malo pre chlapcov s týmto spektrom negatívny vplyv na tvorbu ich sociálnych sietí. Štúdia tímu Jiao et al. (2017) naznačuje, že vrstevnícke skupiny na druhom stupni môžu mať vplyv na subjektívny pocit blaha žiakov, kde žiaci v rámci vrstevníckych skupín vykazovali podobné pocity. Huitsing a Veensstra (2012) využili blok modelovanie pri identifikácii podskupín agresorov pri výskume šikany v triede. Analýza sociálnych sietí adolescentov na amerických školách tímu Goodreau et al. (2009) preukázala efekty selektívneho výberu (homofílie) na základe pohlavia a etnika. Zatiaľ čo všetky sledované etniká

preukazovali preferencie tvorby vzťahov s vlastným etnikom, černosi a ázijci vykazovali efekt homofilie najviac. Podobné výsledky prináša aj štúdia Lubbers (2003), ktorá skúmala štruktúru sociálnych sietí medzi žiakmi v triede a medzi triedami v sekundárnom vzdelávaní v Holandsku. Jej výskum preukázal preferencie žiakov vytvárať vzťahy so žiakmi s rovnakým pohlavím, etnickým pôvodom a spoločnou skúsenosťou v predošlom vzdelávaní. V neposlednom rade Snijders a Baerveldt (2003) výskumom sociálnych väzieb na holandských stredných školách preukázali, že žiaci preukazujú tendencie k homofilii na základe delikventného správania.

Ďalší autori zas využili SNA pri výskume interakcií medzi študentmi. Bokhove (2018) ukazuje využitie SNA pri výskume interakcií v rámci školskej triedy. Han et al. (2016) preukázali rastúcu tendenciu kolaboratívnej siete pri záverečnom projekte online predmetu univerzitného pregraduálneho štúdia. Podobne Naim et al. (2010) pri výskume vývoja interakcií v prezenčnom kolaboratívnom učení študentov univerzitného postgraduálneho štúdia zaznamenali rastúcu tendenciu sietí študentov. Štúdia tímu Stepanyana et al. (2010) na druhú stranu naznačuje postupom času rastúcu tendenciu univerzitných online študentov interagovať so spolužiakmi selektívnejšie – s čoraz menším počtom spolužiakov. Jimoyiannis et al. (2013) využili SNA na skúmanie hlavných aktérov v skupinách kolaboratívneho online učenia. Autori zistili, že participácia na kolaboratívnom učení viedla k efektívnej integrácii ich myšlienok v skupine. Štúdia ďalej preukázala, že skupiny mali tendenciu vytvoriť relatívne centralizované siete okolo malého počtu aktívnych študentov.

Niekoľko autorov využilo SNA na skúmanie učiteľských vzťahov a spolupráce. Meijs a De Laat (2012) preukázali dôležitosť neformálnych vzťahov medzi učiteľmi na ich profesijný rozvoj na základných školách. Autori argumentujú, že najplyvnejší učitelia sú kľúčoví pri zavádzaní nových učebných postupov. K podobným záverom prišla štúdia Quardokusa a Hendersona (2015), ktorá skúmala štruktúru neformálnych vzťahov na univerzitných katedrách. Štúdia tímu Bakkenesa et al. (1999) zas naznačuje, že učitelia na základných školách sa združujú podľa svojej špecializácie, a preukazuje dôležitosť spájajúcich článkov – učiteľov, ktorí tvoria mosty medzi jednotlivými podskupinami učiteľov. Za zmienku stoja aj exploratórne analýzy publikačných sietí výskumníkov z pedagogickej oblasti (Juhaňák, 2017; Munoz et al., 2016).

Na úrovni škôl, organizácií či krajín bola SNA využitá taktiež. Breuer et al. (2009) zozbierali dáta z učiteľského kolaboratívneho projektu eTwinning zo 45 000 škôl z celej Európy. Skúmali štyri úrovne spolupráce – medzi učiteľmi, školami, projektami a krajinami. Štúdia preukázala, že väčšina registrovaných škôl a učiteľov bola v projekte neaktívna. Ďalej preukázala vysokú

mieru centralizácie a malú mieru prepojenosti sietí, čo malo za dôsledok, že väčšina učiteľov nebola prepojená s jadrom siete a mala limitovaný prístup k informáciám. Kolleck (2015) využila SNA na výskum implementácie vládnych opatrení v oblasti školstva v Nemecku. Jej štúdiá na základe výpočtov centralít preukázala, že mimovládne organizácie a vládni aktéri mali oveľa vplyvnejšie postavenie pri implementácii opatrení než školy samotné.

### Metódy SNA v praxi

V nasledujúcej časti ilustrujem využitie, aplikáciu a interpretáciu SNA v pedagogickom výskume na sérii 5 výskumných otázok za použitia orientovanej sociálnej siete  $X_2$  reprezentujúcej fiktívnu školskú triedu (obrázok 4). Pôvodné dáta zahŕňajú okrem matice susednosti mená, pohlavie, status žiaka so špeciálnymi vzdelávacími potrebami (ŠVP) a vážený prospech normalizovaný do hodnoty 0–1, kde hodnota 0 značí najhorší a hodnota 1 najlepší prospech v triede. V triede je 26 žiakov – 13 dievčat (50 %) (tmavá farba vrcholov), 13 chlapcov (50 %) (svetlá farba vrcholov); z toho 10 žiakov (38,46 %) – 4 dievčatá (15,38 %) a 6 chlapcov (23,08 %) – má špeciálne vzdelávacie potreby – ŠVP (biela farba názvu vrcholov). Hrany reprezentujú sympatie – v prípade vzájomných sympatií môžeme väzbu vnímať ako priateľstvo. Veľkosť vrcholov reprezentuje vstupný stupeň – koľko spolužiakov vyjadrilo danému žiakovi sympatie. Sieť je vizualizovaná v softvéri *Gephi* (Bastian et al., 2009) za využitia layoutu *ForceAtlas2* (Jacomy et al., 2014). Sieťové výpočty sú robené v Rknižnici *statnet* (Handcock et al., 2018; Hunter et al., 2008). Permutačné testy sú robené v Rknižnici *RV AideMemoire* (Hervé, 2020).

Výskumné otázky:


VO1: *Líši sa sociálne postavenie žiakov so špeciálnymi vzdelávacími potrebami v triede od ostatných?* (prierezová analýza s použitím permutačného t-testu)

VO2: *Existuje súvislosť medzi centralitou vlastného vektora v rámci triedy a prospechom v škole?* (prierezová analýza za použitia Pearsonovho korelačného koeficientu s permutačným testom)

VO3: *Ovplyvňuje homofília na základe pohlavia a statusu žiaka so ŠVP podobu sociálnej siete v triede?* (prierezová analýza za použitia ERG modelu)

VO4: *Ako sa vyvíjala sociálna sieť v triede v čase?* (deskriptívna dynamická analýza)

VO5: *Čo ovplyvnilo tvorbu sociálnej siete v triede v čase?* (dynamická analýza za použitia STERG modelu)



Obrázok 4  
Zobrazenie siete X2

*VO1: Líši sa sociálne postavenie žiakov so špeciálnymi vzdelávacími potrebami v triede od ostatných?*

Prvú výskumnú otázku bude adresovať prierezová analýza za použitia výpočtu základných štruktúrnych vlastností siete a permutačného t-testu<sup>6</sup>. Aby sme na otázku odpovedali, je potrebné vypočítať hodnoty štruktúrnych premenných všetkých žiakov. Tabuľka 1 zobrazuje deskriptívnu štatistiku siete na úrovni vrcholov siete X2. Pohľadom na jednotlivých žiakov zistíme,

<sup>6</sup> Medzi používané SNA softvéry umožňujúce výpočty základných vlastností siete patria Rknižnica *statnet* (Handcock et al., 2018; Hunter et al., 2008), *Gephi* (Bastian et al., 2009), *Pajek* (Batagelj & Mrvar, 1998), *igraph* (Csárdi & Nepusz, 2006) či *UCINET* (Borgatti et al., 2002). Pre manuály pozri: *statnet* (Butts, 2008; Butts & Butts, 2019; Goodreau et al., 2008), *Gephi* (Cherven, 2013; Cherven, 2015; Gephi.org, 2017), *Pajek* (Mrvar & Batagelj, 2019), *igraph* (Csárdi & Nepusz, 2010), *UCINET* (UCINET, 2020).

že veľká časť žiakov so ŠVP má nízke hodnoty vstupných a výstupných stupňov, nulové hodnoty klastrovacieho koeficientu a nulové hodnoty medziľahlosti, čo môže naznačovať, že žiaci so ŠVP sa menej socializujú a oproti ostatným sa menej združujú do klík. Tieto hodnoty sa dajú interpretovať rôzne, a ak by sme mali prístup do triedy, určite by bolo zaujímavé napríklad pozrieť sa kvalitatívnym dizajnom na správanie sa žiakov s nízkymi hodnotami štruktúrálnych premenných v triede<sup>7</sup>. My však chceme s využitím SNA dospieť k záveru o rozdieloch medzi dvoma skupinami žiakov; preto rozdelíme žiakov do dvoch skupín – ŠVP a bez ŠVP a vypočítame aritmetické priemery so smerodatnými odchýlkami (SD) štruktúrálých hodnôt oboch skupín (tabuľka 2). Namerané priemery naznačujú, že žiaci so ŠVP majú všetky hodnoty štruktúrálnych premenných nižšie než žiaci bez ŠVP.

Ak však chceme z našich dát urobiť záver o rozdieloch medzi žiakmi bez ŠVP a žiakmi so ŠVP, potrebujeme vykonať test významnosti, na základe ktorého budeme alebo nebudeme môcť odmietnuť nulovú hypotézu, že rozdiely v nameraných štruktúrálnych premenných medzi žiakmi boli spôsobené náhodou. Štandardným postupom by v tomto prípade bol nepárový t-test. Štandardný t-test však pri počítaní  $p$  hodnoty predpokladá vzájomnú nezávislosť všetkých pozorovaných hodnôt. Sieťové premenné však majú zo svojej podstaty medzi sebou dyadické závislosti – hodnoty vzájomných väzieb, klastrovacieho koeficientu či centralít sú všetky závislé na vstupných a výstupných stupňoch všetkých ostatných vrcholov. Ak by sme zmenili počet väzieb jedného vrcholu, ovplyvnilo by to hodnoty štruktúrálnych premenných všetkých ostatných vrcholov. Testy predpokladajúce vzájomnú nezávislosť pozorovaných premenných sú preto pri sieťových dátach nepoužiteľné.

Alternatívou sú testy významnosti založené na permutácii dát, ktoré nie sú založené na predpoklade nezávislosti pozorovaní. Permutačné testy veľkým množstvom simulácií sledujú možné rozdelenie výsledkov pozorovaní zo súboru sledovaných premenných a porovnávajú ich s empirickým výsledkom.<sup>8</sup> Permutačné testy sú používané tiež pri modelovaní za použitia sieťových dát. Pri modelovaní veľkosti efektu sa používajú bežné nástroje inferenčnej štatistiky ako testy korelácie či regresné modely, sú však doplnené o testy významnosti založené na permutácii dát. Špeciálnymi typmi permutačných testov využívaných v SNA sú aj CUG test (*conditional uniform graph test*) a QAP

<sup>7</sup> SNA môže byť relevantnou súčasťou zmiešaného výzkumného dizajnu. Kvalitatívny dizajn vie SNA obohatiť o dôležité premenné, zatiaľ čo SNA vie kvalitatívny dizajn obohatiť o pohľad na sledované štruktúry (Edwards, 2010; Martinez et al., 2003).

<sup>8</sup> Pre obsiahlejší výklad permutačného testu pozri kapitolu 8.2 v Borgatti et al. (2018). Pre teóriu za permutačnými testami pozri Berry et al. (2019) a Butts (2007).

test (*quadratic assignments procedure test*). Zatiaľ čo CUG test necháva pri permutáciách jednu štruktúrnú premennú rovnakú a mení štruktúru siete, QAP test necháva pri permutácii celú štruktúru siete nezmenenú. CUG test je preto vhodný na testovanie významnosti štruktúrálnych premenných jednej siete, zatiaľ čo QAP test je vhodný na testovanie významnosti medzi sieťami (Cunningham et al., 2016)<sup>9</sup>.

Tabuľka 1

*Deskriptívna štatistika siete X2 na úrovni vrcholov*

žiak	pohl.	ŠVP	prosp.	vstup.	výstup.	vzáj.	klastr.	medzi.	blízk.	vlast. vek.
Ann	Ď	N	0,25	5	6	4	0,33	0,37	0,33	0,66
Ben	CH	N	0,42	7	2	1	0,25	0,36	0,32	0,31
Cay	Ď	N	0,52	3	2	2	0,40	0,01	0,26	0,33
Deb	Ď	N	0,05	3	3	2	0,40	0,19	0,26	0,49
Edd	CH	N	0,91	3	3	2	0,53	0,32	0,34	0,15
Fin	CH	N	0,85	1	3	1	0,83	0,04	0,31	0,06
Gem	Ď	N	0,27	4	3	3	0,67	0,03	0,28	0,67
Hay	Ď	A	0,32	2	2	2	0,00	0,08	0,22	0,29
Ina	Ď	A	0,12	1	1	1	0,00	0,00	0,18	0,08
Jim	CH	A	0,00	1	2	1	0,67	0,00	0,29	0,01
Kev	CH	A	0,12	2	2	1	0,50	0,00	0,26	0,01
Leo	CH	A	0,05	0	3	0	0,33	0,00	0,29	0,00
Meg	Ď	A	0,95	5	2	2	0,48	0,12	0,23	0,85
Nat	Ď	A	0,93	4	4	4	0,43	0,33	0,29	0,83
Oly	CH	N	0,23	1	4	0	0,50	0,01	0,35	0,02
Pam	Ď	N	0,96	4	4	4	0,43	0,26	0,25	0,78
Qin	Ď	N	0,78	4	4	4	0,71	0,03	0,21	0,68
Ray	Ď	N	0,54	4	4	4	0,71	0,03	0,21	0,68
Sol	Ď	N	0,42	2	3	2	0,80	0,00	0,18	0,37
Tea	Ď	N	0,75	1	3	3	0,76	0,01	0,21	0,68
Uno	CH	A	1,00	5	5	5	0,32	0,06	0,27	0,94
Vic	CH	N	0,80	3	3	3	0,83	0,00	0,27	0,72
Wyn	CH	A	0,45	2	2	2	0,67	0,00	0,22	0,51
Xan	CH	N	0,41	2	2	2	0,67	0,00	0,22	0,51
Yan	CH	A	0,91	6	6	6	0,24	0,21	0,28	1,00
Zac	CH	N	0,82	4	4	3	0,30	0,40	0,32	0,76

<sup>9</sup> Pre porovnanie a príklady CUG a QAP testov v R pozri Murphy (2020).

Permutačný nepárový t-test s úrovňou významnosti  $\alpha = 0,05$  (tabuľka 2) pri 10 000 permutáciach dokázal v sieti X2 odmietnuť nulovú hypotézu iba pri klastrovacom koeficiente (tučným písmom).<sup>10</sup> Naša analýza preukázala, že žiaci so ŠVP majú v porovnaní so žiakmi bez ŠVP menší klastrovací koeficient, čo naznačuje, že sa menej združujú v klíkách. V ostatných pozorovaných aspektoch sú si však dve skupiny žiakov podobné.

Tabuľka 2

*Priemery hodnôt premenných siete X2 na úrovni kategórií ŠVP/bez ŠVP*

	vstup.	výstup.	vzáj.	klastr.	medzi.	blízko.	vlast. vek.
ŠVP priem. (SD)	2,80 (2,04)	2,9 (1,60)	2,4 (1,96)	0,36 (0,24)	0,08 (0,11)	0,25 (0,03)	0,45 (0,42)
bez ŠVP priem. (SD)	3,19 (1,60)	3,32 (1,01)	2,5 (1,21)	0,57 (0,20)	0,13 (0,16)	0,27 (0,05)	0,49 (0,25)
<i>p</i> hodnota perm. t-testu	0,6729	0,5139	0,9739	<b>0,025</b>	0,3925	0,3837	0,9699

*VO2: Existuje súvislosť medzi centralitou vlastného vektora v rámci triedy a prospechom v škole?*

Druhú výskumnú otázku bude adresovať výpočet Pearsonovho korelačného koeficientu s permutačným testom. Výpočet preukázal pozitívny lineárny vzťah ( $\rho = 0,6522$  s  $p$  hodnotou = 0,001 pri 10 000 permutáciach) medzi premennými centralitou vlastného vektora a prospechu v sieti X2. Výsledok naznačuje, že žiaci s vysokými hodnotami centrality vlastného vektora majú zároveň v porovnaní s ostatnými lepší prospech. Výpovedná hodnota koeficientu je však obmedzená na konštatovanie existencie pozitívneho vzťahu medzi dvoma premennými. Jednak výpočet neberie do úvahy iné premenné, ktoré môžu ovplyvňovať prospech a centralitu vlastného vektora, jednak v prípade prierezných dát nie je možné definitívne určiť smer závislosti – korelácia nám nehovorí, či vysoká hodnota centrality vlastného vektora vedie k lepšiemu prospechu, či prospech vedie k vysokej centralite vlastného vektora, alebo či sú obe premenné tak závislé ako nezávislé.<sup>11</sup> Rovnako ako pri sieťových dátach sa nemusíme obmedzovať na výpočet korelačného koeficientu. Na modelovanie vzťahov s použitím sieťových dát môžeme využiť všetky možnosti regresných modelov. Na posúdenie významnosti však musíme vždy použiť testy založené na permutácii.

<sup>10</sup> Nastavenie úrovne významnosti pri testovaní nulovej hypotézy je komplexnou problematikou a zaužívané hodnoty by nemali byť používané automaticky (Kim, 2015).

<sup>11</sup> Pre dokazovanie kauzality pozri Beebe et al. (2009) a Heath et al. (1993).



*VO3: Ovplyvňuje homofília na základe pohlavia a statusu žiaka so ŠVP podobu sociálnej siete v triede?*

Zatiaľ čo výpočty korelačného koeficientu a regresné modely sa využívajú na preukázanie a meranie vzťahov medzi premennými bez modelovania samotnej štruktúry siete, ERG modely (*exponential random graph models* známe aj ako *p\* models*) sa za použitia prierezových dát snažia identifikovať efekty, ktoré podobu sociálnej siete ovplyvňujú.<sup>12</sup> ERG modely sú založené na myšlienke, že podoba siete je ovplyvnená množstvom navzájom sa prelínajúcich efektov na mikro úrovni. Efekty sú rôzne usporiadania väzieb, o ktorých je predpoklad, že sa v sieti vyskytujú viac alebo menej, než by sme očakávali náhodou. ERG modely vedia poňať veľké množstvo efektov vrátane ich vzájomných závislostí a umožňujú tak realisticky modelovať sieťové štruktúry (Morris et al., 2008)<sup>13</sup>. Najväčším prínosom ERG modelov je práve ich schopnosť identifikovať a oddeliť silu jednotlivých efektov v sieti. Na prvý pohľad sa môže napríklad zdať, že sieť je ovplyvnená efektom homofílie, po započítaní efektu tranzitivít (tendencia vytvárať väzby s tým, s ktorým mám spoločného známeho) však môžeme zistiť, že efekt homofílie je v konečnom dôsledku nevýznamný a pozorované homofílné väzby sú viac dôsledkom tranzitivít než homofílie samotnej. Výsledky ERG modelov sú pravdepodobnosti, s akými sa vytvorí vzťah medzi dvoma vrcholmi v sieti na základe jednotlivých sledovaných efektov. Sila jednotlivých efektov je vo forme log. odds. (logaritmus šancí)<sup>14</sup>. V prípade, že je sila efektu vyššia, než by sme očakávali náhodou, môžeme predpokladať, že daný efekt ovplyvnil podobu sledovanej siete. Lusher et al. (2012) a Harris (2013) do detailov pojednávajú o ERG modelovaní – od základnej charakteristiky, cez riziká spojené s modelmi, po praktické príklady ich využitia<sup>15</sup>

ERG modelovanie sa dá rozdeliť do troch hlavných častí. V prvom rade musí byť do modelu vložená sociálna sieť tak, ako bola odpozorovaná. V našom prípade je to matica susednosti siete  $X_2$  a zoznam vlastností vrcholov. V druhom rade sa špecifikujú parametre modelu; vkladáme do modelu efekty, pri ktorých predpokladáme, že majú vplyv na štruktúru siete. Pri špecifikácii parametrov modelu sa štandardne začína s efektom prepojenosti (*edges*), ktorý slúži ako ekvivalent intercept pri bežných regresných modeloch (Hunter et al., 2008); následne sa pridávajú ostatné efekty a porovnáva sa, či sa celková

<sup>12</sup> Medzi používané SNA softvéry umožňujúce inferenčné analýzy patrí okrem Rknižnice *statnet* a *UCINETu* aj Rknižnica *RSiena* (Ripley et al., 2020) a software *PNet* (Wang et al., 2009).

<sup>13</sup> Pre špecifikácie ERG modelov pozri Robins et al. (2007), Anderson et al. (1999), Wasserman a Pattison (1996) a Frank a Strauss (1986).

<sup>14</sup> Pre vzťah medzi log. odds, odds a odds ratios pozri Grimes a Schulz (2008) a Borenstein et al. (2009).

<sup>15</sup> Pre ERGM manuály pre *statnet* pozri Goodreau et al. (2008) a Hunter et al. (2008).

pravdepodobnosť modelu zlepšila. Najčastejšími efektami, ktoré sa pri špecifikácii ERG modelov používajú, sú pri orientovaných sieťach okrem efektu prepojenosti efekty vzájomnosti (tendencia opätovať jednosmerné väzby a tvoriť vzájomné väzby), tranzitivitu (tendencia združovať sa do klíck), distribúcie stupňov (frekvencia, s akou sa v sieti vyskytujú jednotlivé hodnoty stupňov) a homofílie (tendencia vytvárať vzťahy s vrcholmi s podobnými vlastnosťami).<sup>16</sup> Tieto efekty boli popísané v mnohých štúdiách a ich vplyv je v sociálnych sieťach považovaný za univerzálny (Kadushin, 2012). V našej sieti sa zameriame na všetky spomínané efekty s homofíliou na základe pohlavia a statusu žiaka so ŠVP.


Posledným a najdôležitejším krokom ERG modelovania je diagnostika modelu. Z ERG modelov môžu vziť hodnoverne vyzerajúce výsledky, ktoré sú ničmenej chybné a ich chybovosť je nutné skontrolovať za použitia diagnostických postupov. Jedná sa o kontrolu konvergenencie modelu (*model convergence*) a kontrolu dobrej zhody s dátami (*goodness of fit*). Kontrola konvergenencie modelu má za cieľ posúdiť, či je model dostatočne špecifikovaný a odhady parametrov modelu sú spoľahlivé. ERG modely zväčša využívajú pri odhadovaní parametrov modelu MCMC (*Markov chain Monte Carlo*) metódy. Ak odhady parametrov nie sú spoľahlivé, hovoríme o degenerácii modelu (*model degeneracy*). Na druhú stranu kontrola dobrej zhody s dátami má za cieľ posúdiť, či je model kvalitný a špecifikovaný tak, že je schopný adekvátne reprodukovat' výsledky pozorovanej siete. Bez konvergenencie modelu a zároveň dobrej zhody s dátami nie sú výsledky ERG modelov validné.<sup>17</sup>

Než prejdeme na interpretáciu výsledkov ERG modelu, musíme sa presvedčiť o konvergencii modelu a dobrej zhode s dátami. V knižnici *statnet* sa konvergenca modelu posudzuje po vytvorení modelu príkazom *mcmc.diagnostics*, ktorý vytvorí sériu modelov s našou špecifikáciou a sleduje hodnoty pozorovaných efektov. Ak model zkonvergoval, hodnoty všetkých efektov budú oscilovať okolo priemernej hodnoty efektu pozorovanej siete. Hodnoty efektu prepojenosti v simulovaných sieťach oscilujú okolo priemeru (obrázok 5). Ostatné hodnoty efektov vyzerajú podobne, čo naznačuje, že model zkonvergoval.<sup>18</sup>

<sup>16</sup> Robins a Lusher v kapitole 13 v Lusher et al. (2012) rozoberajú základné špecifikácie rôznych typov sietí. Pre detaily špecifikácie parametrov v knižnici *statnet* pozri Morris et al. (2008).

<sup>17</sup> Koskinen a Snijders v kapitole 12 v Lusher et al. (2012) vysvetľujú procesy pri ERG modelovaní vrátane diagnostiky. Pre diagnostiku modelov v knižnici *statnet* pozri Goodreau et al. (2008) a Li a Carriere (2013).

<sup>18</sup> Neuvádzam grafy pre všetky sledované efekty, sú však k dispozícii na vyžiadanie. Ak sú ERG modely súčasťou publikovaného výskumu, je dôležité, aby boli výsledky testu konvergenencie buď priložené priamo v štúdiu, alebo aspoň k dispozícii na vyžiadanie. Rovnaké pravidlo platí aj pri testovaní dobrej zhody s dátami.



Obrázok 5

*Graf distribúcie hodnôt efektu prepojenosti  $\xi$  MCMC simulácií*

Dobrá zhoda s dátami sa v knižnici *statnet* posudzuje príkazom *gof*, ktorý z množstva simulovaných sietí náhodne vyberie vzorku a porovnáva hodnoty štrukturálnych premenných vzorky s odpozorovanou sieťou. Sledujú sa hodnoty vstupných a výstupných stupňov, tranzitivity, minimálne geodetické vzdialenosti, ako aj všetky efekty v modeli. Výsledkom testu sú priemery hodnôt zo simulovaných sietí a  $p$  hodnoty vypočítané z porovnania priemerov hodnôt zo simulovaných sietí a reálne odpozorovanej siete. Čím sú priemery hodnôt zo simulácií bližšie k hodnotám odpozorovanej siete a čím je  $p$  hodnota vyššia, tým kvalitnejší model je. Všetky hodnoty priemerov zo simulovaných sietí sa blížia k hodnotám z odpozorovanej siete. V tabuľke 3 sú uvedené  $p$  hodnoty z testu (MC  $p$ -value), ktoré ukazujú vysokú mieru zhody.<sup>19</sup>

Výsledky nášho ERG modelu<sup>20</sup> (tabuľka 3) naznačujú, že štruktúra sociálnej siete  $X_2$  je ovplyvnená efektami vzájomnosti, tranzitivity, homofílie na základe pohlavia, ako aj homofílie na základe statusu žiaka s ŠVP. Všetky tieto efekty ovplyvnili podobu siete pozitívne, žiaci teda majú tendenciu

<sup>19</sup> Neuvádzam  $p$  hodnoty štrukturálnych premenných mimo sledovaných efektov ani hodnoty priemerov, sú však k dispozícii na vyžiadanie.

<sup>20</sup> Náš model použil jednu jednorovňovú sieť s jednoduchými väzbami, MCMC (Markov chain Monte Carlo) výpočtom závislosti a gwesp štatistikou (Snijders et al., 2006) pre výpočet tranzitivity. ERG modely však na túto konkrétnu špecifikáciu niesú odkazané. Pre porovnanie výpočtov závislosti v ERG modeloch pozri Lubbers a Snijders (2007). Pre príklady viacúrovňových modelov pozri Wang et al. (2013) a An (2015). Pre modely s váženými vzťahmi pozri Krivitsky (2012). Pre príklady curved ERGM, pozri Hunter a Handcock (2006). Pre príklady agregovania výsledkov z viacerých sietí pozri Lubbers (2003) a Chen et al. (2019).

<sup>21</sup> Pre rozvinutejšie úvahy pozri Van der Pol (2017), prípadne kapitolu 12 v Lusher et al. (2012).

väzby opätovat', majú tendenciu vytvárat' vzťahy so spolužiakmi, s ktorými majú spoločného priateľa, chlapci dávajú prednosť väzbám s chlapcami, dievčatá väzbám s dievčatami, žiaci s ŠVP s ostatnými žiakmi so ŠVP a žiaci bez ŠVP s ostatnými žiakmi bez ŠVP. Z týchto efektov je najsilnejší efekt vzájomnosti, nasledovaný efektami tranzitivity a homofílie na základe pohlavia s podobnou veľkosťou efektu a efektom homofílie na základe statusu žiaka s ŠVP. Ostatné efekty nie sú štatisticky významné. Za štatisticky významné sa štandardne považujú tie efekty, ktorých hodnota je aspoň dvakrát väčšia ako smerodajná chyba, prípadne ich hodnota  $\Pr(>|z|)$  je menšia ako úroveň významnosti.<sup>21</sup> Znamená to, že žiadna zo sledovaných skupín žiakov, či už na základe pohlavia alebo statusu žiaka s ŠVP, nemá tendenciu vytvárat' vzťahy menej alebo viac než tá druhá (efekt pohlavia a ŠVP). Rovnako tak žiaci nemajú tendenciu centralizovať sa a vytvárat' viac vzťahov so spolužiakmi s vysokými hodnotami stupňov (distribúcie stupňov).<sup>22</sup>

Tabuľka 3

*Výsledky ERG modelu siete X2*

	log. odds (SE)	$\Pr(> z )$	MC p-value
edges (celková prepojenosť)	-3,09525 (1,50836)	0,04016 *	1,00
mutual (vzájomnosť)	3,60490 (0,64779)	< 1e-04 ***	1,00
twopath (prepojenosť cez dve hrany)	-0,39341 (0,24563)	0,10924	0,86
gwideg.fixed.1 (distribúcia vstupných stupňov)	-1,28121 (1,07015)	0,23122	1,00
gwodeg.fixed.1(distribúcia výstupných stupňov)	2,28399 (1,74982)	0,19180	0,94
gwesp.fixed.1 (tranzitivita)	0,75666 (0,16907)	< 1e-04 ***	0,84
gwdsp.fixed.1 (efekt nižšieho rádu tranzitivity)	0,03844 (0,24398)	0,87482	0,84
nodematch.pohlavie (homofília)	0,82143 (0,25412)	0,00123 **	0,94
nodematch.ŠVP (homofília)	0,32737 (0,14008)	0,01943 *	0,98
nodefactor.pohlavie.ch (efekt pohlavia)	-0,06364 (0,13799)	0,64467	1,00
nodefactor.ŠVP.a (efekt ŠVP)	-0,07185 (0,16186)	0,65709	1,00
<i>Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1</i>			

<sup>22</sup> Gwdegree štatistika sa okrem potreby konvergencie používa aj na preukázanie tzv. „popularity effect“, ktorý sa prejavuje tendenciou aktérov vytvárat' vzťahy s aktérmi, ktorí majú vysokú hodnotu centrality, čo má za následok vysokú centralizáciu siete. Zároveň má za následok rozdelenie siete na jadro, v ktorom majú aktéri s vysokými hodnotami centrality množstvo väzieb medzi sebou, a perifériu, v ktorej sú väzby málo početné a vedú smerom k jadrú. Kontraintuitívne, záporná hodnota efektu značí pozitívny efekt centralizácie. Názočne ukázané v softvare *gwdegree* (Levy, 2016).

*V04: Ako sa vyvíjala sociálna sieť v triede v čase?*


Doteraz sme našu sieť analyzovali iba z jedného pozorovania. Predstavme si však, že podobu siete X2 poznáme aj v ďalších momentoch v čase a rôzne podoby siete tak vieme porovnať. Sieť v čase T1 bola odpozorovaná krátko po vzniku triedy, v časoch T2–T5 v dvojmesačných intervaloch a v čase T6 na konci školského roku a zároveň v podobe, ako sme ju poznali doteraz (obrázok 6). Štvrtú výskumnú otázku bude adresovať deskriptívna dynamická analýza za použitia výpočtu základných štrukturálnych vlastností siete. Napriek tomu, že naša analýza sa bude venovať iba vlastnostiam na úrovni siete, dynamické analýzy vedia, podobne ako ich prierezové ekvivalenty, sledovať hodnoty štrukturálnych premenných aj na úrovni jednotlivých vrcholov.

Okrem už známych výpočtov hustoty, reciprocitu a priemerného klastrovacieho koeficientu vypočítame aj počet komponentov a počet vzniknutých a zaniknutých väzieb medzi jednotlivými sledovanými obdobiami (tabuľka 4). Zatiaľ čo reciprocita siete zostávala v čase nezmenená, hustota siete sa za rok 2,5násobila. Sieť bola na začiatku veľmi málo prepojená, čo potvrdzuje aj počet štyroch oddelených komponentov, od polovice roka však už žiaci tvorili jeden komponent. Priemerný klastrovací koeficient postupne rástol tiež, čo naznačuje, že nové väzby žiaci smerovali skôr ku spolužiakom v ich blízkosti, ktorí už mali existujúci vzťah s ich známymi. Hodnoty vzniknutých a zaniknutých väzieb naznačujú dôležitý moment v čase medzi T3 a T4. V tomto období vzniklo 37 a zaniklo 42 väzieb, čo sú v porovnaní so zvyškom roka pomerne vysoké čísla. Je to zároveň jediné obdobie, keď viac väzieb zaniklo, než vzniklo. Môžeme teda uvažovať, že v čase medzi T3 a T4 sa v triede udiali významné zmeny v rovesníckych vzťahoch.

Tabuľka 4

*Deskriptívna dynamická štatistika siete X2*

	T1	T2	T3	T4	T5	T6
hustota	0,0477	0,08	0,1031	0,0954	0,1108	0,1262
počet komponentov	4	1	2	1	1	1
reciprocita	0,96	0,92	0,88	0,8831	0,92	0,9446
priemerný klastrovací koeficient	0	0,042	0,111	0,088	0,242	0,488
vznik väzieb	n/a	24	22	37	22	25
zánik väzieb	n/a	3	7	42	12	15



Obrázok 6  
Vývoj siete X2 v čase

V05: Čo ovplyvnilo tvorbu sociálnej siete v triede v čase?

Piatu výskumnú otázku bude adresovať STERG model (*separable temporal exponential random graph model*), ktorý je podobný ERG modelu, s rozdielom, že na preukázanie vplyvov ovplyvňujúcich podobu siete využíva dynamické dáta (Krivitsky & Goodreau, 2019; Krivitsky & Handcock, 2014). Postup STERG modelovania je taktiež podobný postupu ERG modelovania s rozdielom, že do modelu sa nevloží jedna sieť, ale séria sietí tak, ako boli odporozorované. Rovnakým postupom sa špecifikujú efekty modelu, na rozdiel od ERG modelov však STERG modely počítajú silu efektov tak pre vznik, ako aj pre zánik väzieb a tieto efekty sa môžu špecifikovať každé zvlášť. Rovnako ako pri ERG modeloch prebieha testovanie konvergencie modelu a rovnako prebieha aj test dobrej zhody s dátami.<sup>23</sup>

Tabuľka 5

Výsledky STERG modelu siete X2

VZNIK VÄZIEB	log. odds (SE)	Pr(> z )	MC p-value
edges (celková prepojenosť)	-5,83946 (0,67666)	<1e-04 ***	1,00
mutual (vzájomnosť)	2,07775 (0,23609)	< 1e-04 ***	1,00
twopath (prepojenosť cez dve hrany)	0,13410 (0,06223)	0,031166 *	0,98
gwideg.fixed.1 (distribúcia vstupných stupňov)	1,12588 (0,59917)	0,060234 ,	0,96
gwodeg.fixed.1 (distribúcia výstupných stupňov)	2,32698 (0,73244)	0,001488 **	0,88
gwesp.fixed.1 (tranzitivita)	0,43717 (0,08273)	<1e-04 ***	0,98
gwdsp.fixed.1 (efekt nižšieho rádu tranzitivity)	-0,11456 (0,08453)	0,175318	0,98
nodematch.pohlavie (homofília)	0,65748 (0,17531)	0,000177 ***	1,00
nodematch.ŠVP (homofília)	0,35912 (0,18348)	0,050310	1,00
nodefactor.pohlavie.ch (efekt pohlavia)	-0,06302 (0,10065)	0,531270	0,92
nodefactor.ŠVP.a (efekt ŠVP)	-0,05813 (0,13950)	0,676903	1,00
ZÁNİK VÄZIEB			
edges (celková prepojenosť)	-0,94288 (0,89892)	0,29422	1,00
mutual (vzájomnosť)	1,13590 (0,36251)	0,00173 **	0,98
twopath (prepojenosť cez dve hrany)	0,57537 (0,60277)	0,33980	0,92
gwideg.fixed.1 (distribúcia vstupných stupňov)	-0,50074 (0,61642)	0,41660	1,00

<sup>23</sup> Výsledky testu konvergencie sú k dispozícii na vyžiadanie. Rovnako ako pri ERG modely uvádzam  $p$  hodnotu z testu dobrej zhody s dátami pri jednotlivých efektoch.

gwodeg.fixed.1 (distribúcia výstupných stupňov)	1,57866 (0,80234)	0,04912 *	0,98
gwesp.fixed.1 (tranzitivita)	0,40846 (0,20533)	0,04667 *	0,82
gwdsp.fixed.1 (efekt nižšieho rádu tranzitivity)	-0,67815 (0,62147)	0,27518	0,90
nodematch.pohlavie (homofília)	0,96630 (0,30394)	0,00148 **	0,96
nodematch.ŠVP (homofília)	0,31971 (0,32494)	0,32516	1,00
nodefactor.pohlavie.ch (efekt pohlavia)	-0,03357 (0,18564)	0,85651	0,98
nodefactor.ŠVP.a (efekt ŠVP)	0,13078 (0,22250)	0,55668	1,00
<i>Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1</i>			

Náš STERG model používa rovnakú špecifikáciu ako predošlý ERG model a rovnaké efekty sleduje tak pre vznik, ako aj pre zánik väzieb<sup>24</sup> (tabuľka 5). STERG model potvrdil významnosť všetkých efektov z ERG modelu pri tvorbe väzieb – efekty vzájomnosti, tranzitivity, homofílie na základe pohlavia, ako aj homofílie na základe statusu žiaka s ŠVP, aj keď tento efekt sa pohybuje na hranici významnosti. Okrem spomínaných efektov však výsledky STERG modelu naznačujú aj pozitívny vplyv prepojenosti cez dve hrany a efekty distribúcie stupňov. Pri zániku väzieb model preukázal pozitívny vplyv efektu vzájomnosti, tranzitivity, homofílie na základe pohlavia, ako aj distribúcie výstupných stupňov.

Model ukazuje, že žiaci počas roka dávali prednosť tvorbe vzájomných väzieb, a keď väzby prerušili, bola tendencia väzby ukončiť vzájomne. Pozitívny efekt tranzitivity pri tvorbe ako aj pri zániku väzieb naznačuje, že žiaci dávali prednosť vzťahom vo väčších celkoch, a keď väzby zanikali, zanikali tiež v rámci väčších celkov. Efekt homofílie na základe pohlavia tak pri tvorbe ako pri zániku väzieb zas naznačuje, že žiaci mali tendenciu nevytvárať väzby s opačným pohlavím, a preto aj keď väzby zanikali, zanikali len v rámci homofílnych skupín. Model tiež ukazuje, že žiaci pri tvorbe vzťahov nedávali prednosť spolužiakom s vysokými hodnotami stupňov, a teda neprebíhala centralizácia. Rovnako ako pri ERG modely nemala žiadna zo sledovaných skupín žiakov, či už na základe pohlavia alebo statusu žiaka s ŠVP, tendenciu vytvárať ani prerušovať vzťahy viac alebo menej než tá druhá.

<sup>24</sup> Pre detaily špecifikácie parametrov STERG modelov pozri Morris et al. (2019).



## Ďalšie modely

Okrem počítaných ERG a STERG modelov ponúka SNA využitie množstva ďalších modelov, ktoré prinášajú možnosti mimo ich rámca a napriek tomu, že v tomto článku nie sú ako súčasť praktických príkladov uvedené, majú potenciál pedagogický výskum obohatiť.

Blokmodely (Abbe, 2018; Holland et al., 1983; Wang & Wong, 1983) sú postavené na koncepte ekvivalencie – sieť je možné zredukovať na zjednodušenú verziu pozostávajúcu zo série pozíc (uskupenia aktérov) a rolí (väzbami medzi nimi), ktoré svojimi vlastnosťami reprezentujú vlastnosti siete. Sú užitočné najmä pri porovnávaní vlastností viacerých sietí či pri veľkých sieťach, kde je žiadúce sieť pri zachovaní štrukturálnych vlastností zjednodušiť.<sup>25</sup>

Iným príkladom sú latentné priestorové modely (*latent space models*) (Hoff et al., 2005; Kim et al., 2018; Sarkar & Moore, 2006; Sewell & Chen, 2015; Sweet et al., 2013), založené na myšlienke, že aktéri v odpozorovanej sieti majú medzi sebou väzby, pretože sú pri sebe blízko v nízkorozmernom latentnom (nepozorovanom) priestore. Latentný priestor reprezentuje nepozorované atribúty, ktoré ničmenej ovplyvňujú podobu pozorovanej siete. Oproti ostatným modelom sú latentné priestorové modely vhodnejšie pri sieťach so skrytými štruktúrami a/alebo množstvom chýbajúcich dát (Kim et al., 2018).

V neposlednom rade je potrebné spomenúť SAOM (*stochastic actor-oriented models*) (Burk et al., 2007; Snijders, 1996; Snijders et al., 2010), ktoré sú založené na rovnakom princípe ako ERG a STERG modely; predpokladajú, že podoba siete je ovplyvnená množstvom navzájom sa prelínajúcich efektov na mikro úrovni. Potenciálom SAOM je oddeliť efekt sociálneho výberu od efektu sociálneho vplyvu (Steglich et al., 2010). Zatiaľ čo efekt výberu je dôsledok konania jednotlivca na dynamiku siete, efekt vplyvu je dôsledok dynamiky siete na konanie jednotlivca. Príkladom efektu výberu je preferencia žiakov vytvárať vzťahy so spolužiakmi s podobným prospechom. Na druhú stranu, efekt vplyvu je efekt skupiny spolužiakov na prospech žiaka. Oba efekty majú za dôsledok pozorovanú homofíliu na základe prospechu, v skutočnosti je však homofília výsledkom dvoch samostatných mechanizmov. SAOM využívajú dynamické dáta, a sú preto užitočné, ak máme sieťové dáta vo viacerých časoch a chceme efekty sociálneho výberu a sociálneho vplyvu posudzovať samostatne.<sup>26</sup>

<sup>25</sup> Pre dobrý úvod do blokmodelov pozri Diviák (2017).

<sup>26</sup> Snijders et al. (2010) ilustrujú využitie SAOM pri štúdiu dynamiky vzťahov v triede.

## Problémy spojené s využitím SNA

S množstvom možností, ktoré SNA vo výskume prináša, treba tiež spomenúť aj problémy a úskalía pri jej používaní. Tieto problémy plynú najmä z charakteru SNA, keď sieťové výpočty predpokladajú vzájomnú prepojenosť aktérov.

Veľkým úskalím v SNA sú chýbajúce dáta, ktoré poznačujú sieťové výpočty viac než iné – aj najmenšia zmena v sieti môže ovplyvniť premenné ostatných aktérov (Kossinets, 2006). To znamená, že ak nám v sieti chýbajú aktéri, ktorí by tam však byť mali, budú tým skreslené výpočty pre celú sieť. Toto platí špeciálne, ak nám chýbajú aktéri s prominentnou polohou v rámci siete – môžu nám chýbať dôležité uzly, ktorých výpadok drasticky ovplyvní podobu siete. Rovnako tak sú mimoriadne ovplyvnené siete s malým počtom vrcholov, kde akákoľvek zmena v štruktúre je o to významnejšia. Okrem latentných priestorových modelov je pravdepodobne najspoľahlivejším spôsobom, ako sa vysporiadať s chýbajúcimi dátami v SNA, bezstratová imputácia, keď sa hodnoty chýbajúcich premenných odvodí od nechýbajúcich premenných (Huisman, 2009).

Ďalším problémom je validita dát. Dáta používané v SNA sa väčšinou týkajú ľudí a vzťahov medzi nimi, čo dáta robí mimoriadne citlivými a ich zber mimoriadne náročným. Výskum Parkhursta a Hopmeyera (1998) napríklad preukázal významný rozdiel medzi popularitou v triede na základe sebahodnotenia a na základe hodnotenia spolužiakov. Rozdielne dáta tiež môžu priniesť rozdielne spôsoby zberu dát – Schofield et al. (1983) a Williams a Gilmour (1994) preukázali rozdiel medzi dátami o priateľstvách v triede zozbieranými dvomi rozdielnymi metódami. Zatiaľ čo dáta zozbierané spôsobom limitovaného výberu spolužiakov boli spoľahlivejšie pri identifikácii blízkych priateľstiev, dáta zozbierané spôsobom Likertovej škály s neobmedzeným výberom spolužiakov boli spoľahlivejšie pri posudzovaní sociálnej pozície žiakov v rámci triedy. Pri zbere dát je preto potrebné zaistiť ich čo najväčšiu objektivitu a pri ich interpretácii vziať do úvahy pôvod a charakter zozbieraných dát.

Úskalím je tiež časová náročnosť SNA metód. Špeciálne SNA modelovanie si pri špecifikácii parametrov vyžaduje veľkú dávku času a trpezlivosti. Jednak sa pri špecifikácii parametrov pracuje s veľkým množstvom efektov a konvergencia a kvalita výsledných modelov musí byť posúdená jednotlivo, jednak sú SNA modely náročné na výpočtovú pamäť a výkon počítača. Špeciálne pri veľkých sieťach sa môže výpočet jedného modelu pohybovať v desiatkach minút až hodinách (Harris, 2013).

V neposlednom rade je potrebné spomenúť problémy s konvergenciou pri modelovaní za použitia odhadov parametrov modelu. Tento problém sa týka najmä ERG/STERG modelov. V súčasnosti sú za použitia algoritmov pre odhad parametrov ERG modelu náchylné na degeneráciu a tento problém

zatiaľ nebol úplne odstránený. Problémy týkajúce sa degenerácie sa dajú minimalizovať použitím g-wesp štatistiky (Snijders et al., 2006), nie je však nezvyčajné, že aj ERG modely špecifikované podľa dobrej praxe neskonvergujú a môžu byť pre danú sieť nepoužiteľné (The Statnet Development Team, 2019).

### Záver

V tomto článku bola predstavená analýza sociálnych sietí ako skupina metód založených na štúdiu sociálnych štruktúr a polohy aktérov v týchto štruktúrach, ktoré sa môžu stať súčasťou pedagogického výskumu. Vzdelávanie je od žiakov až po vzdelávacie politiky tvorené množstvami aktérov a vzťahov medzi nimi. Niekoľko štúdií uvedených v článku dokazuje, že SNA sa dá v pedagogickom výskume aplikovať od najmenších štruktúr v rámci triedy po štruktúry medzi krajinami. V hlavnej časti článku bol potenciál SNA ilustrovaný za využitia niekoľkých príkladov z fiktívnej školskej triedy a rovnako tak boli predstavené úskalia spojené s jej použitím. Napriek ťažkostiam spojeným s potrebou kvalitných dát a časovou náročnosťou vie byť SNA užitočným nástrojom pri skúmaní veľkého množstva procesov sociálneho sveta. S kvalitnými dátami sú možnosti SNA prakticky neobmedzené – môže slúžiť ako výstup sama o sebe, byť súčasťou exploratórnej analýzy, alebo súčasťou zmiešaného dizajnu. Sieťové modely vedia poňať veľké množstvo efektov vrátane ich vzájomných závislostí a umožňujú tak realisticky modelovať sieťové štruktúry. Už aj najjednoduchšie výpočty za použitia SNA však vedia pedagogický výskum obohatiť o cenné informácie. Bola by škoda to nevyužiť.

### Podakovanie

Autor ďakuje dvom anonymným recenzentom, ktorých posudky nemalou mierou dopomohli k zvýšeniu kvality tohto článku.

### Literatúra

- Abbe, E. (2017). Community detection and stochastic block models: recent developments. *The Journal of Machine Learning Research*, 18(1), 6446–6531. <https://doi.org/10.5555/3122009.3242034>
- An, W. (2015). Multilevel meta network analysis with application to studying network dynamics of network interventions. *Social Networks*, 43, 48–56. <https://doi.org/10.1016/j.socnet.2015.03.006>

- Anderson, A., Locke, J., Kretzmann, M., Kasari, C., & AIR-B Network. (2016). Social network analysis of children with autism spectrum disorder: predictors of fragmentation and connectivity in elementary school classrooms. *Autism*, 20(6), 700–709. <https://doi.org/10.1177/1362361315603568>
- Anderson, C. J., Wasserman, S., & Crouch, B. (1999). A p\* primer: Logit models for social networks. *Social networks*, 21(1), 37–66. [https://doi.org/10.1016/S0378-8733\(98\)00012-4](https://doi.org/10.1016/S0378-8733(98)00012-4)
- Bakkenes, I., De Brabander, C., & Imants, J. (1999). Teacher Isolation and Communication Network Analysis in Primary Schools. *Educational Administration Quarterly*, 35(2), 166–202. <https://doi.org/10.1177/00131619921968518>
- Barclay, J. R. (1967). Effecting behavior change in the elementary classroom: An exploratory study. *Journal of Counseling Psychology*, 14(3), 240–247. <https://doi.org/10.1037/h0024541>
- Baron, D. (1951). Personal-social characteristics and classroom social status: A sociometric study of fifth and sixth grade girls. *Sociometry*, 14(1), 32–42. <https://doi.org/10.2307/2785208>
- Bastian, M., Heymann, S., & Jacomy, M. (2009). Gephi: an open source software for exploring and manipulating networks. *International AAAI Conference on Weblogs and Social Media*. <https://gephi.org/publications/gephi-bastian-feb09.pdf>
- Batagelj, V., & Mrvar, A. (1998). Pajek – Program for Large Network Analysis. *Connections*, 21(2), 47–57. [https://doi.org/10.1007/978-3-642-18638-7\\_4](https://doi.org/10.1007/978-3-642-18638-7_4)
- Beebe, H., Hitchcock, C., & Menzies, P. (Eds.). (2009). *The Oxford Handbook of Causation*. Oxford University Press. <https://doi.org/10.1093/oxfordhb/9780199279739.001.0001>
- Berry, K. J., Johnston, J. E., & Mielke, J. P. W. (2019). *A Primer of Permutation Statistical Methods*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-20933-9>
- Bokhove, C. (2018). Exploring classroom interaction with dynamic social network analysis. *International Journal of Research & Method in Education*, 41(1), 17–37. <https://doi.org/10.1080/1743727X.2016.1192116>
- Bonacich, P. (1987). Power and Centrality: A Family of Measures. *American Journal of Sociology*, 92(5), 1170–1182. <https://doi.org/10.1086/228631>
- Bonacich, P. (2007). Some unique properties of eigenvector centrality. *Social Networks*, 29(4), 555–564. <https://doi.org/10.1016/j.socnet.2007.04.002>
- Borenstein, M., Hedges, L. V., Higgins, J. P., & Rothstein, H. R. (2009). *Introduction to meta-analysis*. John Wiley & Sons. <https://doi.org/10.1002/9780470743386>
- Borgatti, S. P. (2005). Centrality and network flow. *Social Networks*, 27(1), 55–71. <https://doi.org/10.1016/j.socnet.2004.11.008>
- Borgatti, S. P., Everett, M. G., & Freeman, L. C. (2002). *Ucinet for Windows: Software for Social Network Analysis*. Analytic Technologies.
- Borgatti, S. P., Everett, M. G., & Johnson, J. C. (2018). *Analyzing social networks*. SAGE.
- Borgatti, S. P., Mehra, A., Brass, D. J., & Labianca, G. (2009). Network analysis in the social sciences. *Science*, 323(5916), 892–895. <https://doi.org/10.1126/science.1165821>
- Breuer, R., Klamma, R., Cao, Y., & Vuorikari, R. (2009, September). Social network analysis of 45,000 schools: A case study of technology enhanced learning in europe. In *European Conference on Technology Enhanced Learning* (s. 166–180). Springer.
- Burk, W. J., Steglich, C. E., & Snijders, T. A. (2007). Beyond dyadic interdependence: Actor-oriented models for co-evolving social networks and individual behaviors. *International journal of behavioral development*, 31(4), 397–404. <https://doi.org/10.1177/0165025407077762>
- Butts, C. T. (2007). 8. Permutation Models for Relational Data. *Sociological Methodology*, 37(1), 257–281. <https://doi.org/10.1111/j.1467-9531.2007.00183.x>

- Butts, C. T. (2008). Social network analysis with sna. *Journal of statistical software*, 24(6), 1–51. <https://doi.org/10.18637/jss.v024.i06>
- Butts, C. T., & Butts, M. C. T. (2019). *Package 'sna'*.
- Carrington, P. J., Scott, J., & Wasserman, S. (2009). *Models and methods in social network analysis*. Cambridge University Press.
- Cerezo, F., & Ato, M. (2005). Bullying in Spanish and English pupils: A sociometric perspective using the BULL-S questionnaire. *Educational psychology*, 25(4), 353–367. <https://doi.org/10.1080/01443410500041458>
- Chen, J., Lin, T. J., Justice, L., & Sawyer, B. (2019). The social networks of children with and without disabilities in early childhood special education classrooms. *Journal of autism and developmental disorders*, 1–16. <https://doi.org/10.1007/s10803-017-3272-4>
- Cherven, K. (2013). *Network graph analysis and visualization with Gephi: visualize and analyze your data swiftly using dynamic network graphs built with Gephi*. Packt Publishing.
- Cherven, K. (2015). *Mastering Gephi network visualization*. Packt Publishing Ltd.
- Csárdi, G., & Nepusz, T. (2006). The igraph software package for complex network research. *InterJournal, complex systems*, 1695(5), 1–9.
- Csárdi, G., & Nepusz, T. (2010). *igraph Reference manual*. <http://igraph.sourceforge.net/documentation.html>
- Cunningham, D., Everton, S., & Murphy, P. (2016). *Understanding dark networks: A strategic framework for the use of social network analysis*. Rowman & Littlefield.
- Daldal, A. (2014). Power and ideology in Michel Foucault and Antonio Gramsci: A comparative analysis. *Review of History and Political Science*, 2(2), 149–167.
- Diviák, T. (2017). Ekvivalence a blokové modelování v analýze sociálních sítí. *Naše společnost (Our Society)*, 15(1), 27–40. <https://doi.org/10.13060/1214438X.2017.1.15.366>
- Edwards, G. (2010). *Mixed-method approaches to social network analysis*. National Centre for Research Methods.
- Fortunato, S. (2010). Community detection in graphs. *Physics reports*, 486(3–5), 75–174. <https://doi.org/10.1016/j.physrep.2009.11.002>
- Frank, O., & Strauss, D. (1986). Markov graphs. *Journal of the American Statistical Association*, 81(395), 832–842. <https://doi.org/10.2307/2289017>
- Freeman, L. C. (1977). A Set of Measures of Centrality Based on Betweenness. *Sociometry*, 40(1), 35–41. <https://doi.org/10.2307/3033543>
- Freeman, L. C. (2004). *The development of social network analysis. A Study in the Sociology of Science*. Empirical Press.
- Friedkin, N. E. (1991). Theoretical Foundations for Centrality Measures. *American Journal of Sociology*, 96(6), 1478–1504. <https://doi.org/10.1086/229694>
- Gephi.org. (2017). *Learn how to use Gephi*. <https://gephi.org/users/>
- Goodreau, S. M., Handcock, M. S., Hunter, D. R., Butts, C. T., & Morris, M. (2008). A statenet Tutorial. *Journal of statistical software*, 24(9), 1–26. <https://doi.org/10.18637/jss.v024.i09>
- Goodreau, S. M., Kitts, J. A., & Morris, M. (2009). Birds of a feather, or friend of a friend? Using exponential random graph models to investigate adolescent social networks. *Demography*, 46(1), 103–125. <https://doi.org/10.1353/dem.0.0045>
- Grimes, D. A., & Schulz, K. F. (2008). Making sense of odds and odds ratios. *Obstetrics & Gynecology*, 111(2), 423–426. <https://doi.org/10.1097/01.AOG.0000297304.32187.5d>

- Grund, T. U., & Densley, J. A. (2015). Ethnic homophily and triad closure: Mapping internal gang structure using exponential random graph models. *Journal of Contemporary Criminal Justice*, 31(3), 354–370. <https://doi.org/10.1177/1043986214553377>
- Han, G., McCubbins, O. P., & Paulsen, T. H. (2016). Using Social Network Analysis to Measure Student Collaboration in an Undergraduate Capstone Course. *NACTA Journal*, 60(2), 176–182. [https://lib.dr.iastate.edu/ageds\\_pubs/33/](https://lib.dr.iastate.edu/ageds_pubs/33/)
- Handcock, M., Hunter, D., Butts, C., Goodreau, S., Krivitsky, P., & Morris, M. (2018). *ergm: Fit, Simulate and Diagnose Exponential-Family Models for Networks*. The Statnet Project (<http://www.statnet.org>). R package version 3.9.4, <https://CRAN.R-project.org/package=ergm>
- Harris, J. K. (2013). *An introduction to exponential random graph modeling* (Vol. 173). Sage Publications.
- Heath, A. C., Kessler, R. C., Neale, M. C., Hewitt, J. K., Eaves, L. J., & Kendler, K. S. (1993). Testing hypotheses about direction of causation using cross-sectional family data. *Behavior Genetics*, 23(1), 29–50. <https://doi.org/10.1007/bf01067552>
- Hervé, M. (2020). *Package 'RV AideMemoire'*.
- Hoff, P. D., Raftery, A. E., & Handcock, M. S. (2002). Latent space approaches to social network analysis. *Journal of the American Statistical Association*, 97(460), 1090–1098. <https://doi.org/10.1198/016214502388618906>
- Holland, P. W., Laskey, K. B., & Leinhardt, S. (1983). Stochastic blockmodels: First steps. *Social Networks*, 5(2), 109–137. [https://doi.org/10.1016/0378-8733\(83\)90021-7](https://doi.org/10.1016/0378-8733(83)90021-7)
- Huisman, M. (2009). Imputation of missing network data: Some simple procedures. *Journal of Social Structure*, 10(1), 1–29. [https://doi.org/10.1007/978-1-4614-7163-9\\_394-1](https://doi.org/10.1007/978-1-4614-7163-9_394-1)
- Huitsing, G., & Veenstra, R. (2012). Bullying in classrooms: Participant roles from a social network perspective. *Aggressive Behavior*, 38(6), 494–509. <https://doi.org/10.1002/ab.21438>
- Hunter, D. R., & Handcock, M. S. (2006). Inference in curved exponential family models for networks. *Journal of Computational and Graphical Statistics*, 15(3), 565–583. <https://doi.org/10.1198/106186006X133069>
- Hunter, D., Handcock, M., Butts, C., Goodreau, S., & Morris, M. (2008). ergm: A Package to Fit, Simulate and Diagnose Exponential-Family Models for Networks. *Journal of Statistical Software*, 24(3), 1–29. <https://doi.org/10.18637/jss.v024.i03>
- Jacomy, M., Venturini, T., Heymann, S., & Bastian, M. (2014). ForceAtlas2, a continuous graph layout algorithm for handy network visualization designed for the Gephi software. *PLoS one*, 9(6). <https://doi.org/10.1371/journal.pone.0098679>
- Jiao, C., Wang, T., Liu, J., Wu, H., Cui, F., & Peng, X. (2017). Using Exponential Random Graph Models to analyze the character of peer relationship networks and their effects on the subjective well-being of adolescents. *Frontiers in Psychology*, 8, 583. <https://doi.org/10.3389/fpsyg.2017.00583>
- Jimoyiannis, A., Tsiotakis, P., & Roussinos, D. (2013). Social network analysis of students' participation and presence in a community of educational blogging. *Interactive Technology and Smart Education*, 10(1), 15–30. <https://doi.org/10.1108/17415651311326428>
- Juhaňák, L. (2017). Sociální síť autorů publikujících v pedagogických vědách v letech 2009–2013: Exploratorní analýza. *Studia paedagogica*, 22(1), 9–36. <https://doi.org/10.5817/SP2017-1-2>
- Kadushin, C. (2012). *Understanding social networks: Theories, concepts, and findings*. OUP USA.
- Kalkusová, L. (2017). Adaptační kurz jako nástroj změny sociálních vztahů ve třídním kolektivu. *Studia sportiva*, 11(1), 128–134. <https://doi.org/10.5817/StS2017-1-30>

- Kindermann, T. A. (2007). Effects of Naturally Existing Peer Groups on Changes in Academic Engagement in a Cohort of Sixth Graders. *Child Development*, 78(4), 1186–1203. <https://doi.org/10.1111/j.1467-8624.2007.01060.x>
- Kim, B., Lee, K. H., Xue, L., & Niu, X. (2018). A review of dynamic network models with latent variables. *Statistics surveys*, 12, 105–135. <https://doi.org/10.1214/18-SS121>
- Kim, J. (2015). *How to choose the level of significance: A pedagogical note*.
- Kolleck, N. (2015). Uncovering influence through Social Network Analysis: the role of schools in Education for Sustainable Development. *Journal of Education Policy*, 31(3), 308–329. <https://doi.org/10.1080/02680939.2015.1119315>
- Kossinets, G. (2006). Effects of missing data in social networks. *Social Networks*, 28, 247–268. <https://doi.org/10.1016/j.socnet.2005.07.002>
- Krivitsky, P. N., & Goodreau, S. M. (2019). *STERGM-Separable Temporal ERGMs for modeling discrete relational dynamics with statnet*. <https://cran.r-project.org/web/packages/tergm/vignettes/STERGM.pdf>
- Krivitsky, P. N., & Handcock, M. S. (2014). A separable model for dynamic networks. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 76(1), 29–46. <https://doi.org/10.1111/rssb.12014>
- Krivitsky, P. N. (2012). Exponential-family random graph models for valued networks. *Electronic journal of statistics*, 6, 1100–1128. <https://doi.org/10.1214/12-EJS696>
- Knoke, D., & Yang, S. (2020). *Social network analysis*. SAGE.
- Landherr, A., Friedl, B., & Heidemann, J. (2010). A Critical Review of Centrality Measures in Social Networks. *Business & Information Systems Engineering*, 2(6), 371–385. <https://doi.org/10.1007/s12599-010-0127-3>
- Leung, B. P., & Silberling, J. (2006). Using sociograms to identify social status in the classroom. *The California School Psychologist*, 11(1), 57–61. <https://doi.org/10.1007/BF03341115>
- Levy (2016). gwdegree: Improving interpretation of geometrically-weighted degree estimates in exponential random graph models. *Journal of Open Source Software*, 1(3), 36, <https://doi.org/10.21105/joss.00036>
- Li, Y., & Carriere, K. C. (2013). Assessing goodness of fit of exponential random graph models. *International Journal of Statistics and Probability*, 2(4), 64. <https://doi.org/10.5539/ijsp.v2n4p64>
- Lin, N. (2017). Building a Network Theory of Social Capital. *Social Capital*, 3–28. <https://doi.org/10.4324/9781315129457-1>
- Lubbers, M. J. (2003). Group composition and network structure in school classes: a multi-level application of the p- model. *Social Networks*, 25(4), 309–332. [https://doi.org/10.1016/S0378-8733\(03\)00013-3](https://doi.org/10.1016/S0378-8733(03)00013-3)
- Lubbers, M. J., & Snijders, T. A. (2007). A comparison of various approaches to the exponential random graph model: A reanalysis of 102 student networks in school classes. *Social networks*, 29(4), 489–507. <https://doi.org/10.1016/j.socnet.2007.03.002>
- Lusher, D., Koskinen, J., & Robins, G. (Eds.). (2012). *Exponential Random Graph Models for Social Networks: Theory, Methods, and Applications (Structural Analysis in the Social Sciences)*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511894701>
- Martinez, A., Dimitriadis, Y., Rubia, B., Gómez, E., & De La Fuente, P. (2003). Combining qualitative evaluation and social network analysis for the study of classroom social interactions. *Computers & Education*, 41(4), 353–368. <https://doi.org/10.1016/j.compedu.2003.06.001>

- Meijs, C., & De Laat, M. (2012). Social Network Analyses (SNA) as a method to study the structure of contacts within teams of a school for secondary education. In V. Hodgson, C. Jones, M. de Laat, D. McConnell, T. Ryberg, & P. Sloep (Eds.), *Proceedings of the 8th International Learning Conference on Networked Learning*.
- Moreno, J. L. (1934). *Who shall survive?: A new approach to the problem of human interrelations*. Nervous and Mental Disease Publishing Co. <https://doi.org/10.1037/10648-000>
- Morris, M., Handcock, M. S., & Hunter, D. R. (2008). Specification of exponential-family random graph models: terms and computational aspects. *Journal of statistical software*, 24(4), 1548–7660. <https://doi.org/10.18637/jss.v024.i04>
- Morris, M., Krivitsky, P. N., Handcock, M. S., Butts, C. T., Hunter, D. R., Goodreau, S. M., & Bender de-Moll, S. (2019). *Temporal Exponential Random Graph Models (TERGMs) for dynamic network modeling in statnet*. [http://statnet.org/tergm\\_tutorial.html](http://statnet.org/tergm_tutorial.html)
- Mrvar, A., & Batagelj, V. (2019). *Programs for analysis and visualization of very large networks: Reference manual*. <http://mrvar.fdv.uni-lj.si/pajek/pajekman.pdf>
- Munoz, D. A., Queupil, J. P., & Fraser, P. (2016). Assessing collaboration networks in educational research. *International Journal of Educational Management*, 30(3), 416–36. <https://doi.org/10.1108/IJEM-11-2014-0154>
- Murphy, P. (2020). *Phil Murphy Tutorials*. <https://rpubs.com/pjmurphy>
- Nagy, T., Nagyová, S., & Szárazová, B. (2018). Sociometria v pedagogickom výskume. *Biológia, Ekológia, Chémia*, 22(4), 4–11.
- Naim, K., Yuldashev, F., Demiroz, F., & Arslan, T. (2010). Social network analysis (SNA) applications in evaluating MPA classes. *Journal of Public Affairs Education*, 16(4), 541–564. <https://doi.org/10.1080/15236803.2010.12001614>
- Parkhurst, J. T., & Hopmeyer, A. (1998). Sociometric popularity and peer-perceived popularity: Two distinct dimensions of peer status. *The Journal of Early Adolescence*, 18(2), 125–144. <https://doi.org/10.1177/0272431698018002001>
- Peery, J. C. (1979). Popular, amiable, isolated, rejected: A reconceptualization of sociometric status in preschool children. *Child Development*, 50(4), 1231–1234. <https://doi.org/10.2307/1129356>
- Quardokus, K., & Henderson, C. (2015). Promoting instructional change: using social network analysis to understand the informal structure of academic departments. *Higher Education*, 70(3), 315–335. <https://doi.org/10.1007/s10734-014-9831-0>
- Radford, M. (2008). Complexity and truth in educational research. *Educational Philosophy and Theory*, 40(1), 144–157. <https://doi.org/10.1111/j.1469-5812.2007.00396.x>
- Ripley, R. M., Snijders, T. A., Boda, Z., Vörös, A., & Preciado, P. (2020). *Manual for SIENA version 4.0*. University of Oxford.
- Robins, G., Pattison, P., Kalish, Y., & Lusher, D. (2007). An introduction to exponential random graph (p\*) models for social networks. *Social networks*, 29(2), 173–191. <https://doi.org/10.1016/j.socnet.2006.08.002>
- Sabidussi, G. (1966). The centrality index of a graph. *Psychometrika*, 31(4), 581–603. <https://doi.org/10.1007/bf02289527>
- Sarkar, P., & Moore, A. W. (2006). Dynamic social network analysis using latent space models. In *Advances in Neural Information Processing Systems* (s. 1145–1152). <https://doi.org/10.1145/1117454.1117459>
- Schofield, J. W. & Whitley, B. E. (1983). Peer Nomination vs. Rating Scale Measurement of Children's Peer Preferences. *Social Psychology Quarterly*, 46(3), 242–251. <https://doi.org/10.2307/3033795>



- Scott, J. (2012). *What is social network analysis?* Bloomsbury Academic.
- Scott, J. (2017). *Social network analysis* (Fourth Edition). SAGE.
- Sewell, D. K., & Chen, Y. (2015). Latent space models for dynamic networks. *Journal of the American Statistical Association*, 110(512), 1646–1657. <https://doi.org/10.1080/01621459.2014.988214>
- Shibutani, T. (2000). *Social processes: an introduction to sociology*. iUniverse.com.
- Snijders, T. A. (1996). Stochastic actor-oriented models for network change. *Journal of mathematical sociology*, 21(1–2), 149–172. <https://doi.org/10.1080/0022250X.1996.9990178>
- Snijders, T. A., & Baerveldt, C. (2003). A multilevel network study of the effects of delinquent behavior on friendship evolution. *Journal of mathematical sociology*, 27(2–3), 123–151. <https://doi.org/10.1080/00222500305892>
- Snijders, T. A., Pattison, P. E., Robins, G. L., & Handcock, M. S. (2006). New specifications for exponential random graph models. *Sociological methodology*, 36(1), 99–153. <https://doi.org/10.1111/j.1467-9531.2006.00176.x>
- Snijders, T. A., Van de Bunt, G. G., & Steglich, C. E. (2010). Introduction to stochastic actor-based models for network dynamics. *Social networks*, 32(1), 44–60. <https://doi.org/10.1016/j.socnet.2009.02.004>
- Steglich, C., Snijders, T. A. B., & Pearson, M. (2010). 8. Dynamic Networks and Behavior: Separating Selection from Influence. *Sociological Methodology*, 40(1), 329–393. <https://doi.org/10.1111/j.1467-9531.2010.01225.x>
- Stepanyan, K., Borau, K., & Ullrich, C. (2010). A social network analysis perspective on student interaction within the twitter microblogging environment. In *2010 10th IEEE international conference on advanced learning technologies* (s. 70–72). IEEE.
- Sweet, T. M., Thomas, A. C., & Junker, B. W. (2013). Hierarchical network models for education research: Hierarchical latent space models. *Journal of Educational and Behavioral Statistics*, 38(3), 295–318. <https://doi.org/10.3102/1076998612458702>
- Šalamounová, Z., & Fučík, P. (2019). The relationship between peer status and students' participation in classroom discourse. *Educational Studies*. <https://doi.org/10.1080/03055698.2019.1706042>
- The Statnet Development Team (2019). *An Example Analysis Using LOLOG*. <https://cran.r-project.org/web/packages/lolog/vignettes/lolog-ergm.pdf>
- Titmanová, M. (2019). Klima ve školní třídě aneb šikana v praxi. *Školský psycholog/Školní psycholog*, 20(1), 67–76.
- UCINET. (2020). *UCINET Software*. <https://sites.google.com/site/ucinetsoftware/>
- Valente, T. W., Coronges, K., Lakon, C., & Costenbader, E. (2008). How Correlated Are Network Centrality Measures?. *Connections*, 28(1), 16–26.
- Van Der Pol, J. (2017). *Introduction to network modeling using Exponential Random Graph models (ERGM)*. <https://hal.archives-ouvertes.fr/hal-01284994/document>
- Vítová, J., Balcarová, J., & Linhartová, V. (2013). The social position of pupils with special educational needs in the group intact peers. *Paidagogos – Journal of Education in Contexts*, 2013(2), 451–464.
- Wang, P., Robins, G., & Pattison, P. (2009). *PNet: program for the simulation and estimation of exponential random graph models*. Melbourne School of Psychological Sciences, The University of Melbourne.

- Wang, P., Robins, G., Pattison, P., & Lazega, E. (2013). Exponential random graph models for multilevel networks. *Social Networks*, 35(1), 96–115. <https://doi.org/10.1016/j.socnet.2013.01.004>
- Wang, Y. J., & Wong, G. Y. (1987). Stochastic blockmodels for directed graphs. *Journal of the American Statistical Association*, 82(397), 8–19. <https://doi.org/10.1080/01621459.1987.10478385>
- Wasserman, S., & Faust, K. (2019). *Social network analysis: methods and applications*. Cambridge University Press.
- Wasserman, S., & Pattison, P. (1996). Logit models and logistic regressions for social networks: I. An introduction to Markov graphs and *p*. *Psychometrika*, 61(3), 401–425. <https://doi.org/10.1111/j.1469-7610.1994.tb01806.x>
- White, H. C. (2008). *Identity and control: How social formations emerge*. Princeton University Press.
- Williams, B. T., & Gilmour, J. D. (1994). Annotation: Sociometry and peer relationships. *Journal of Child Psychology and Psychiatry*, 35(6), 997–1013. <https://doi.org/10.1111/j.1469-7610.1994.tb01806.x>

**Kontakt na autora**

Tomáš Lintner

Ústav pedagogických věd, Filozofická fakulta, Masarykova univerzita

E-mail: [tomas.lintner@mail.muni.cz](mailto:tomas.lintner@mail.muni.cz)

**Corresponding author**

Tomáš Lintner

Department of Educational Sciences, Faculty of Arts, Masaryk University

E-mail: [tomas.lintner@mail.muni.cz](mailto:tomas.lintner@mail.muni.cz)

