

Projekt 1 & 2: “Visibility graphs” pre finančné časové rady

“Visibility graphs” sa zostroja z priebehu časového radu tak, že vrcholy tvoria jednotlivé pozorovania a hranou sa spoja v prípade, že sa pri nakreslení priebehu „navzájom vidia“. Rozlišuje sa pritom „natural“ a „horizontal visibility graph“.





Fig. 1. Graphical illustration of the Horizontal Visibility Graph algorithm. On the top we plot a periodic time series while at the bottom there is a graphical representation of the associated network.

Pri všetkých analýzach má zmysel pozrieť sa na to, či výsledky závisia od toho, aký typ grafu zvolíme.

Projekt 1: Zhlukovanie v týchto grafoch

Physica A 410 (2014) 483–495



Time series analysis of the developed financial markets' integration using visibility graphs

Enyu Zhuang^{a,*}, Michael Small^b, Gang Feng^a

^a Department of Mechanical and Biomedical Engineering, City University of Hong Kong, Hong Kong, China

^b School of Mathematics and Statistics, The University of Western Australia, Perth, Australia



<https://www.sciencedirect.com/science/article/abs/pii/S0378437114004397>

V článku sa hľadajú komunity v grafe zostrojenom pre časový rad vyjadrujúci segmentáciu trhu. V projekte sa pracuje s niekoľkými príbuznými časovými radmi – napríklad ceny akcií z rôznych odvetví, výmenné kurzy eura voči rôznym menám alebo úrokové miery v rôznych štátoch (alebo iné, podľa vlastného výberu).

Prvou otázkou je, či sa nájdú komunity s väčšou veľkosťou a ak áno, akým obdobiam zodpovedajú. Druhá otázka je, či sa pre tieto časové rady dosiahnu podobné výsledky ako v článku ohľadom hustoty a kompaktnosti komunít (obr. 10 a 11 v článku).

Projekt 2: Koeficient zhlukovania v týchto sieťach

Physica A 650 (2024) 130004



Contents lists available at ScienceDirect

Physica A

journal homepage: www.elsevier.com/locate/physa



Visibility graph analysis of the grains and oilseeds indices

Hao-Ran Liu^a, Ming-Xia Li^{b,c,*}, Wei-Xing Zhou^{a,c,d}

^a School of Business, East China University of Science and Technology, Shanghai 200237, China

^b School of Sports Science and Engineering, East China University of Science and Technology, Shanghai 200237, China

^c Research Center for Econophysics, East China University of Science and Technology, Shanghai 200237, China

^d School of Mathematics, East China University of Science and Technology, Shanghai 200237, China

<https://www.sciencedirect.com/science/article/abs/pii/S0378437124005132>

V projekte sa pracuje s niekoľkými príbuznými časovými radmi – napríklad ceny akcií z rôznych odvetví, výmenné kurzy eura voči rôznym menám alebo úrokové miery v rôznych štátoch (alebo iné, podľa vlastného výberu).

Cieľom je zrekonštruovať obrázky 5 (body v grafe sú jednotlivé siete, t. j. jednotlivé časové rady), 6, 7, 9 (vo všetkých predstavujú body jednotlivé vrcholy, dostaneme teda jeden obrázok pre každý časový rad) pre vlastné časové rady, vysvetliť, čo znázorňujú a zhodnotiť, či sa pozorujú podobné závislosti ako v prípade časových radov uvažovaných v článku.

Projekt 3: Centralita vrcholov a konštrukcia portfólia



Journal of Empirical Finance

Volume 38, Part A, September 2016, Pages 157-180



A network approach to portfolio selection

Gustavo Peralta^a , Abalfazl Zareei^b  

^a Department of Research and Statistics at CNMV, Calle Edison, 4, 28006 Madrid, Spain

^b Department of Business Administration at Universidad Carlos III de Madrid, Calle Madrid, 126, 28903, Getafe, Madrid, Spain

<https://www.sciencedirect.com/science/article/abs/pii/S0927539816300603>

Čo je to MST, tým sa budeme zaoberať v práve v súvislosti s takýmito sieťami vytvorenými z korelácií. Stručne: MST (minimum spanning tree, v slovenčine minimálna kostra) obsahuje všetky vrcholy pôvodného grafu, je to súvislý graf a neobsahuje cyklus (v tom zmysle je to „kosta“, že spája všetky vrcholy najjednoduchším spôsobom, bez zbytočných cyklov, ktoré k tomu nie sú potrebné). Na obrázku z článku sa dáva do súvislosti centralita vrcholov s váhami pri Markowitzovej diverzifikácii portfólia.




Fig. 2. MST stock market network for the d-S&P dataset. The size of nodes corresponds to the optimal weights for the minimum-variance strategy (see Eq. 3) and the intensity of the colour accounts for the corresponding security's centrality.

Cieľom projektu je vytvoriť podobné obrázky pre vlastné dáta (pre niekoľko rôznych volieb množiny akcií, ktoré uvažujeme pri optimalizácii portfólia) a zrekonštruovať aj niektorý z ďalších obrázkov v článku alebo regresii (napríklad je tam lineárna regresia, ktorá modeluje váhy v portfóliu pomocou centrality a štandardnej odchýlky).

Projekt 4: Hodnotenie úspešnosti algoritmov na hľadanie komúní

Evaluation of Community Detection Methods

Xin Liu, Hui-Min Cheng, and Zhong-Yuan Zhang 

Abstract—Community structures are critical towards understanding not only the network topology but also how the network functions. However, how to evaluate the quality of detected community structures is still challenging and remains unsolved. The most widely used metric, normalized mutual information (NMI), was proven to have finite size effect, and its improved form relative normalized mutual information (rNMI) has reverse finite size effect. Corrected normalized mutual information (cNMI) was thus proposed and has neither finite size effect nor reverse finite size effect. However, in this paper, we show that cNMI violates the so-called proportionality assumption. In addition, NMI-type metrics have the problem of ignoring importance of small communities. Finally, they cannot be used to evaluate a single community of interest. In this paper, we map the computed community labels to the ground-truth ones through integer linear programming, and then use kappa index and F-score to evaluate the detected community structures. Experimental results demonstrate the advantages of our method.

Index Terms—Normalized mutual information, kappa index, F-score, community structures detection

<https://ieeexplore.ieee.org/abstract/document/8693534/>

V článku sa navrhuje nový postup na hodnotenie algoritmov zhukovania, my ho však použijeme kvôli prehľadu klasických metód v časti 2.1.2

2.1.2 *External Indices*

Generally speaking, external indices evaluate the clustering result by comparing it with the external supplied true labels. For the sake of clarity, we assume that there are 10 samples with the true labels $[1, 1, 1, 1, 1, 1, 2, 2, 3, 3]$.

Tento prístup predpokladá, že máme k dispozícii správne rozdelenie, čo je prípad napríklad Zacharyho karate klubu alebo aj niektorých iných sietí (niektoré sa spomínajú v článku).

V prezentácii sa vysvetlia tieto indexy a vypočítajú sa v R-ku (je možné použiť aj funkcie z balíkov (nie je to povinné), ale v takom prípade treba na jednoduchom príklade „ručne“ spočítať, že dávajú presne to, čo požaduje definícia).

Porovná sa úspešnosť preberaných algoritmov na sieťach so známym delením na komunity – karate klub + aspoň jedna iná sieť.