



Využitie prostriedkov umelej inteligencie na akciových trhoch¹

Martin Jakubčí

Fakulta managementu Univerzity Komenského v Bratislave

Úvod

Akciové trhy sú terčom záujmu mnohých investorov, ktorí chcú dosiahnuť zisk, ale tiež vedcov, ktorí sa snažia nájsť poriadok v týchto zložitých systémoch. Množstvo interakcií a vzťahov to robí veľmi náročným. Existuje mnoho modelov a stratégií, ktoré si často protirečia. Ak sa zameriame na investorov, ktorí vyberajú akcie do portfólia, tento problém je možné chápať ako viackriteriálny. Medzi kritériá najčastejšie patrí výnos a riziko. Je zrejmé, že tieto kritériá si protirečia: vysoký výnos znamená aj vysoké riziko a naopak nízke riziko znamená nízky výnos. Pri viackriteriálnej optimalizácii sa preto nedá nájsť jedno optimálne riešenie, ale hľadajú sa Pareto optimálne riešenia (tzv. Pareto front), pre ktoré nie je možné zmenou riešenia dosiahnuť lepšie plnenie niektorého kritéria bez zhoršenia v plnení iného kritéria.

Rozvoj informačných technológií umožnil aj rozvoj počítačových riešení pre takéto problémy. Na riešenie problémov na počítači potrebujeme algoritmy, teda postupnosti krokov. Pri niektorých problémoch však nie je táto postupnosť známa. V týchto prípadoch môžeme využiť algoritmy strojového učenia. Patria sem aj evolučné algoritmy, ktoré využívajú operátory inšpirované evolučnou teóriou. Jedným z evolučných algoritmov je genetické programovanie, ktoré využíva stromovú reprezentáciu riešenia. Táto reprezentácia sa hodí aj pre investičné pravidlá, ktoré rozhodujú o akciách zaradených v portfóliu.

Genetické programovanie je evolučný algoritmus na automatické hľadanie riešení, kde riešenie je program, ktorý je zväčša reprezentovaný stromovou štruktúrou. Na začiatku je vytvorená prvá generácia, teda populácia náhodných programov (riešení). Z nej potom stochastickou transformáciou vznikajú ďalšie generácie, pričom vždy dúfame, že každá ďalšia generácia je lepšia. To znamená, že obsahuje programy, ktoré lepšie riešia daný problém. Na vyhodnotenie kvality riešenia sa používa tzv. fitness funkcia. Nové generácie vznikajú aplikáciou genetických operácií, ktoré sú inšpirované evolučnou teóriou, a to výberu, mutácie a kríženia [19]. Na kombináciu viacerých kritérií existujú rôzne modifikácie evolučných algoritmov [9].

Pri hľadaní riešení sú potrebné údaje, na ktorých sa dané pravidlá testujú. Tieto údaje slúžia ako vstup. Najčastejšie sa používajú historické ceny akcií, ale aj rôzne fundamentálne a technické indikátory. Výskum sa však orientuje aj na iné

druhy údajov. Keďže internet používajú miliardy ľudí, dajú sa v ich aktivite nájsť vzťahy. Preto spôsobili tieto údaje (napr. o popularite rôznych pojmov na internete) záujem a boli aplikované aj v oblasti akciových trhov [16] [21] [22]. Evolučné algoritmy sú vhodné na hľadanie rôznych kombinácií týchto údajov. Aplikáciou evolučných algoritmov na finančných trhoch sa zaoberá veľké množstvo publikácií [1] [2] [3] [4] [6] [7] [8] [9] [10] [11] [13] [14] [15] [17] [18] [20] [23].

Pre overenie riešení nájdených algoritmom je potrebné porovnanie s inými stratégiami. Väčšina publikácií sa orientuje len na porovnanie s trhovým indexom, zaujímavé je však aj porovnanie s inými stratégiami, ktoré využívajú investori. Ide o stratégie založené napr. na technickej alebo fundamentálnej analýze.

Cieľom dizertačnej práce bolo preskúmať možnosti viackriteriálnej optimalizácie pomocou evolučných algoritmov a ich využitia pri hľadaní investičných stratégií. Ako zdroj údajov sú použité zdroje z internetu. Okrem štandardne používaných údajov o cenách a rôznych indikátorov boli použité aj údaje o aktivite na internete:

- zo služby Google Trends (<https://www.google.com/trends>),
- počty videní stránok Wikipedia (<http://stats.grok.se>).

Výsledná implementácia bola porovnaná s inými rôznorodými stratégiami.

METÓDY

Na hľadanie hodnotiacich pravidiel akcií bol použitý algoritmus viackriteriálneho genetického programovania. Vstup takého pravidla pozostáva z historických údajov o firme a výstupom je číselný index. Tento index slúži ako odporúčanie investovať do akcií danej firmy. Nájdené pravidlá sa následne overovali v investičnej stratégii, podľa ktorej boli nakúpené akcie 10 firiem s najvyšším indexom a predané akcie 10 firiem s najnižším indexom.

Na hodnotenia jednotlivých pravidiel v investičnej stratégii sa použili nasledujúce kritériá:

- Priemerná denná miera návratnosti

$$\mu = \frac{1}{T} \left(\sum_{t=1}^T \frac{R_t - R_{t-1}}{R_{t-1}} \right),$$

kde R_0 je počiatočná hodnota portfólia, R_t je výsledná hodnota portfólia v čase t a T je počet období.

¹ Článok je zhrnutím dizertačnej práce s rovnakým názvom, za ktorú získal autor tretiu cenu v súťaži o cenu guvernéra NBS pre študentov univerzít za výnimočnú dizertačnú, prípadne diplomovú prácu v oblasti menovej ekonomie, makroekonomie alebo finančnej ekonomie.



- Štandardná odchýlka denných výnosov

$$\sigma_i = \sqrt{\frac{1}{T} \left(\sum_{i=1}^T (r_i - \mu)^2 \right)},$$

kde T je počet období, r_i je miera návratnosti v čase i a μ je priemerná miera návratnosti.

Na kombináciu kritérií sa použil algoritmus SPEA2, ktorý využíva externý archív pre uchovávanie najlepších riešení a pozostáva z týchto krokov [24]:

1. Inicializácia – vygeneruj náhodnú populáciu riešení a prázdny archív, nastav $t = 0$.
2. Priradenie fitness – vypočítaj fitness hodnoty v populácii aj archíve.
3. Environmentálny výber – skopíruj nedominované riešenia z populácie a archívu do nového archívu. Ak veľkosť nového archívu presiahne definovanú veľkosť, využije sa zmenšovacia operácia. Ak je veľkosť nového archívu menšia, naplní sa dominovanými riešeniami.
4. Ukončenie – ak $t \geq T$ alebo je splnené iné kritérium na ukončenie. Výstupom je množina nedominovaných riešení z archívu.
5. Výber – vykonaj turnajový výber z archívu pre vytvorenie množiny riešení pre kríženie a mutácie.
6. Variácia – aplikuj kríženie a mutáciu pre vytvorenie novej populácie. Inkrementuj číslo generácie $t = t + 1$ a pokračuj krokom 2.

Algoritmus bol implementovaný v jazyku C# na platforme Microsoft .Net, s použitím knižnic MetaLinq na prácu so stromami výrazov a Microsoft Automatic Graph Layout na vizualizáciu riešení.

Výsledky boli porovnané s rôznorodými investičnými stratégiami:

- Lotériové obchodovanie, ktoré vykonáva náhodné rozhodnutia, čiže ho implementujeme ako hodnotiace pravidlo, ktoré vracia náhodné hodnotenie akcie.
- Náhodná stratégia využívajúca náhodné hodnotiace pravidlo. Také sa vytvárajú v prvej generácii tréningu genetického programovania.
- Pre preskúmanie veľkého množstva náhodných stratégií bolo použité náhodné prehľadávanie riešení.
- Bezriziková investícia je reprezentovaná trojročnými vládnymi dlhopismi USA.
- Stratégia kúp a drž znamená, že aktívum je kúpené na začiatku obdobia a predané na konci obdobia. Aplikujeme ju na DJIA index.
- Stratégia Psy z Dow investuje do 10 firiem s najvyšším dividendovým výnosom spomedzi firiem indexu DJIA [5].
- Jednoduché plávajúce priemery (skratka SMA, z angl. simple moving averages) sa rátajú ako priemer predošlých dní. Ak cena rastie nad plávajúci priemer, akcia sa má kúpiť, ak klesne pod plávajúci priemer, má sa predáť [12].
- Exponenciálne plávajúce priemery (skratka EMA, z angl. exponential moving averages) sú

podobné SMA, ale s klesajúcim vplyvom starších dní pri výpočte [12].

- Konvergencia a divergencia plávajúcich priemerov (skratka MACD, z angl. moving average convergence divergence) sa ráta ako rozdiel medzi 26-dňovým EMA a 12-dňovým EMA – keď pretne signalizačnú čiaru (EMA z MACD) zdola, je to nákupný signál [12].

VÝSLEDKY

Počas experimentov sa použili údaje 30 firiem, ktoré sú súčasťou indexu DJIA. Historické údaje boli vybrané z obdobia rokov 2008 až 2014, rozdelené na rôzne obdobia. Staršie údaje nebolo možné použiť, lebo údaje o počte videní na Wikipedii sú k dispozícii od decembra 2007. Tieto údaje však obsahujú finančnú krízu rokov 2008 a 2009, keď trh prudko padal, a tiež aj prudko rastúce pokrízové obdobie. Údaje boli rozdelené na niekoľko období v dvoch nastaveniach, každé s dvomi vyhodnocovacími obdobiami:

- tréningové obdobie 2010 až 2012, validačné obdobie 2013, vyhodnocovacie obdobie prvá polovica 2014 a 2008 až 2009,
- tréningové obdobie 2008 a 2009, validačné obdobie 2010, vyhodnocovacie obdobie 2011 až 2012 a 2013.

Tréningové obdobie sa použilo na hľadanie riešení, validačné obdobie na výber tých najlepších z Pareto frontu a vyhodnocovacie obdobie sa použilo na vyhodnotenie (simuluje to vlastné využitie v budúcnosti). Použité boli aj dve nastavenia transakčných nákladov, a to nulové a na úrovni 0,5 % hodnoty transakcie. Skúšali sme aj tri nastavenia vstupných údajov:


- iba historické ceny akcií,
- iba údaje o internetovej popularite (Google a Wikipedia),
- kombináciu oboch.

Obchody sa vykonávali na dennej báze, so začiatočným kapitálom 100 000, pričom sa nedržala žiadna hotovostná rezerva, čiže celá suma sa vždy investovala do akcií. Investovalo sa do 10 akcií s najlepším hodnotením a ak boli vlastnené niektoré z 10 akcií s najhorším hodnotením, tak sa predali. Časové okno pre údaje bolo 50 dní, čiže pri rozhodovaní o akciách v daný deň boli k dispozícii údaje za 50 dní dozadu. Pre genetické programovanie sa použilo vždy 300 generácií, veľkosť populácie 50 riešení, veľkosť archívu 20 riešení a maximálna hĺbka stromu bola 8.

Výsledky boli zobrazené vizuálne na dvojrozmerných grafoch. Na osi x sa nachádza priemerná denná miera návratnosti a na osi y je smerodajná odchýlka miery návratnosti. Hodnoty na osi x maximalizujeme a na osi y minimalizujeme, to znamená, že najlepšie riešenia sa nachádzajú v pravej spodnej časti. Zobrazené sú buď Pareto fronty riešení, alebo body, ktoré reprezentujú konkrétnu stratégiu, alebo priemer naprieč riešeniami. Pri Pareto frontoch z tréningového a overovacieho obdobia ide o ukážkové behy. Pri priemeroch, ktoré sú porovnávané s inými stratégiami, ide o priemery z 10 behov simulácie.



Obrázok 1 Ukážkové Pareto fronty bez transakčných nákladov: pre tréningové obdobie 2010 až 2012, tréningové obdobie 2008 až 2009, validačné obdobie 2013 a validačné obdobie 2011

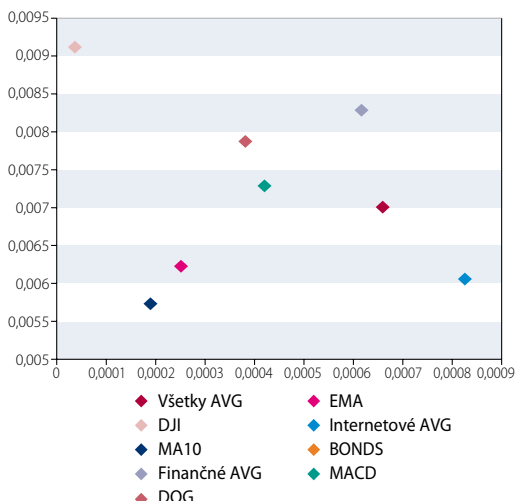


Zdroj: Vlastné výpočty.

Z experimentov nám vyšli Pareto fronty, teda množiny najlepších riešení, ktoré vidieť na obr. 1. V tréningovom období tvorilo Pareto front vždy viac riešení a tvorili pekný front. Vo validačnom období boli preriedené. Na obrázku tiež vidieť, že najlepšie výsledky sú dosiahnuté zapojením oboch druhov údajov. Vidieť tiež, že v krízovom období sa dosahovali nízke výnosy a vysoké odchýlky. Na obr. 2 vidíme ukážku porovnania v jednom z vyhodnocovacích období. Jednoznačne tu dominujú riešenia z genetického programovania a v rámci nich tie so zapojením internetových údajov.

Prí experimentoch bolo nájdené množstvo rôznorodých pravidiel. Ukážku pravidla vidíme na obr. 3. Vidíme tu priamu úmernosť s popularitou na Wikipedii a Googli z predošlého dňa (označené ako lastWiki a lastGoogle). Ďalej tu vidíme nepriamu úmernosť s popularitou na Googli z dňa predtým (Lag 49, teda posun o 49 dní, pričom časové okno je 50 dní). Nepriama úmernosť je daná

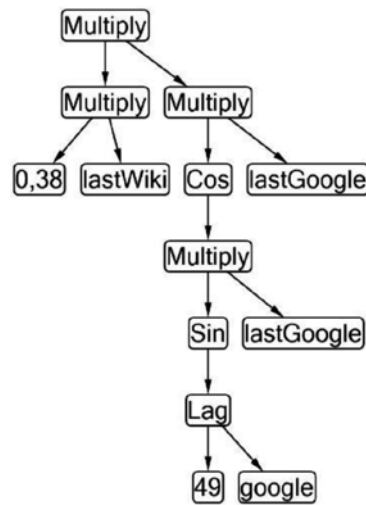
Obrázok 2 Porovnanie vo vyhodnocovacom období 2014



Zdroj: Vlastné výpočty.



Obrázok 3 Ukážka nájdeného hodnotiaceho pravidla s využitím iba internetovej popularity



Zdroj: Vlastné výpočty.

operáciou kosínus. V prípade tohto modelu to môžeme interpretovať ako odporúčanie kupovať akciu, kým popularita rastie, a predávať, keď klesá. Atraktivita akcie je pritom tým vyššia, čím je tento

rast väčší. Toto odporúčanie je v protiklade s výsledkami Preisa a kol. [21] Môže to byť ale dané rôznou frekvenciou obchodov, Preis a kol. ich vykonávali týždenne, my denne. Je však zrejmé, že genetické programovanie je schopné nájsť zložité modely, ktoré by sa ťažko nachádzali inými postupmi.

ZÁVER

Vo vyhodnotení sme porovnali stratégiu založenú na hodnotiacich pravidlách s inými stratégiami. Tieto pravidlá slúžia na ohodnotenie atraktivity akcie a boli vytvorené genetickým programovaním s dvomi kritériami, a to priemerným denným výnosom a smerodajnou odchýlkou. Vytvorili sa tri typy pravidiel, a to s využitím iba historických cien akcií, iba údajov o internetovej popularite a s využitím oboch druhov údajov. Pravidlá sa tvorili na tréningovom období, filtrovali sa na validačnom období a overovali sa na dvoch vyhodnocovacích obdobiach. Použili sme dve rôzne nastavenia týchto období a tiež overovanie bez transakčných nákladov, ako aj s transakčnými nákladmi na úrovni 0,5 %, ktoré sa rátali z hodnoty obchodu.

Ukázalo sa, že genetické programovanie je schopné dosahovať zaujímavé výsledky, ktoré vo väčšine prípadov porážajú trh a aj iné stratégie.

Tabuľka porovnania priemerných denných výnosov

		Finančné	Internetové	Všetky	DJI	DOG	Bonds	Random	ma10	ema	macd
Bez trans. nákladov											
Tréningové	2010-2012	0,000673	0,001029	0,001033	0,000531	0,000574	2,03E-05	0,000400	0,000575	0,000560	0,000369
Validačné	2013	0,001505	0,000899	0,001172	0,001234	0,001228	1,48E-05	0,000682	0,000817	0,000941	0,001098
Overovacie	2014	0,000617	0,000826	0,000659	3,67E-05	0,000381	2,11E-05	-0,002425	0,000190	0,000251	0,000420
Overovacie	2008-2009	0,00029	0,0003	0,00033	-0,000112	-0,000266	4,99E-05	-0,000510	0,000145	0,000268	0,000299
Tréningové	2008-2009	0,000557	0,001607	0,000815	-0,000112	-0,000266	4,99E-05	0,00001	0,000145	0,000268	0,000299
Validačné	2010	0,000470	0,000383	0,000506	0,000632	0,000742	3,01E-05	0,000195	0,000552	0,000505	0,000402
Overovacie	2011-2012	0,000317	0,000764	0,0007	0,000427	0,000329	1,04E-05	0,000224	0,000269	0,000278	0,000114
Overovacie	2013	0,001492	0,0014	0,0015	0,001234	0,001228	1,48E-05	0,000682	0,000817	0,000941	0,001098
S trans. nákladmi											
Tréningové	2010-2012	0,000770	0,000620	0,000831	0,000531	0,000574	2,03E-05	-0,003061	0,000578	0,000562	0,000371
Validačné	2013	0,000964	0,001378	0,000845	0,001234	0,001228	1,48E-05	0,000380	0,000819	0,000943	0,001102
Overovacie	2014	0,000279	0,000528	0,000505	3,67E-05	0,000381	2,11E-05	0,001849	0,000190	0,000252	0,000421
Overovacie	2008-2009	0,00029	0,00031	0,00033	-0,000112	-0,000266	4,99E-05	-0,002261	0,000147	0,000270	0,000302
Tréningové	2008-2009	0,000557	0,000536	0,000777	-0,000112	-0,000266	4,99E-05	-0,002261	0,000147	0,000270	0,000302
Validačné	2010	0,000471	0,000744	0,000281	0,000700	0,000745	3,00E-05	-0,015736	0,000552	0,000499	0,000388
Overovacie	2011-2012	0,000205	0,000428	0,000450	0,000427	0,000329	1,04E-05	0,002564	0,000270	0,000280	0,000115
Overovacie	2013	0,0013	0,00135	0,0014	0,001234	0,001228	1,48E-05	0,000380	0,000819	0,000943	0,001102
Priemer za všetky		0,000672	0,000819	0,000758	0,000488	0,000494	2,64E-05	-0,001180	0,000439	0,000502	0,000513
Priemer za overovacie		0,000599	0,000738	0,000734	0,000396	0,000418	2,40E-05	6,30E-05	0,000356	0,000435	0,000484
Počet víťazstiev za všetky		1	6	7	0	1	0	0	0	0	0
Počet víťazstiev za overovacie		0	3	5	0	0	0	0	0	0	0

Zdroj: Vlastné výpočty.



Zapojenie údajov o internetovej popularite tieto výsledky ešte zlepšuje. Z hodnotiacich pravidiel je jednoduché, vďaka prehľadnej stromovej reprezentácii, extrahovať zložité nelineárne modely. Jedným z takýchto extrahovaných modelov je pozitívne hodnotenie akcie podľa rastúcej popularity vo vyhľadávачi Google a na encyklopédii Wikipedia.

Bolo tiež overené, že napriek tomu, že tréningovanie sa vykonávalo na rastúcom trhu pokrízových rokov, dobré výsledky sa dosiahli aj na klesajúcom trhu krízových rokov. A platilo to aj naopak. Transakčné náklady ovplyvnili negatívne výsledky genetického programovania, ale stále bolo schopné vo väčšine prípadov poraziť ostatné stratégie.

Čo sa týka ostatných stratégií, dlhopisy sa potvrdili ako bezriziková investícia s nízkym a stabilným výnosom, čo bolo zaujímavé najmä v krízových rokoch. Technická a fundamentálna analýza je schopná dosiahnuť zaujímavé výnosy,

v niektorých prípadoch porovnateľné s genetickým programovaním. Jednoduchá stratégia kúp a drž aplikovaná na trhovú index je veľmi jednoduchá a stále výnosná, najhoršie výsledky dosiahla, pochopiteľne, v krízových rokoch. Náhodné stratégie neboli schopné dosiahnuť zaujímavé výsledky. Prehľad priemerných denných výnosov pre rôzne stratégie, nastavenia a obdobia vidieť v tab. 1, genetické programovanie s údajmi o internetovej popularite vyhralo v ôsmich z ôsmich overovacích období.

V budúcnosti je potrebný ďalší výskum v tejto oblasti. Dajú sa zapojiť aj ďalšie druhy údajov (sociálne siete), je však ťažké dostať sa k týmto údajom. Zaujímavé by bolo tiež porovnanie na ďalších časových obdobiach. To ale komplikuje dostupnosť údajov o internetovej popularite len zhruba za posledných 10 rokov. Porovnanie by tiež bolo možné rozšíriť o ďalšie stratégie a vytvoriť tak štandardizovanú platformu pre vyhodnocovanie stratégií.

Použitá literatúra:

- Allen, F., Karjalainen, R.: Using genetic algorithms to find technical trading rules. In: Journal of Financial Economics, vol. 51, pp. 245-271 (1999).
- Becker, L. A., Seshadri, M.: GP-evolved technical rules can outperform buy and hold. In: Proceedings of the 6th International Conference on Computational Intelligence and Natural Computing, pp. 26-30 (2003).
- Becker, Y. L., Fei, P., Lester, A.: Stock Selection – An Innovative Application of Genetic Programming Methodology. In: Genetic Programming Theory and Practice IV, pp. 315-334 (2007).
- Briza, A. C., Naval, P. C.: Design of stock trading system for historical market data using multiobjective particle swarm optimization of technical indicators. In: Proceedings of the 2008 GECCO conference companion on Genetic and evolutionary computation, pp. 1871-1878 (2008).
- Domiana, D. L., Loutonb, D. A., Mossman, C. E.: The rise and fall of the Dogs of the Dow. In Financial Services Review, vol. 7, no. 3, pp. 145-159 (1998).
- Chen, S. S., Huang, CH. F., Hong, T. P.: A Multi-objective Genetic Model for Stock Selection. In: The 27th Annual Conference of the Japanese Society for Artificial Intelligence (2013).
- Chen, S. S., Huang, CH. F., Hong, T. P.: An Improved Multi-Objective Genetic Model for Stock Selection with Domain Knowledge. In: Technologies and Applications of Artificial Intelligence, Lecture Notes in Computer Science, vol. 8916, pp. 66-73 (2014).
- Chen, S. H., Navet, N.: Failure of Genetic-Programming Induced Trading Strategies: Distinguishing between Efficient Markets and Inefficient Algorithms. In Computational Intelligence in Economics and Finance, vol. 2, pp. 169-182 (2007).
- Ghosh, A., Dehuri, S.: Evolutionary Algorithms for Multicriterion Optimization: A Survey. In: International Journal of Computing & Information Sciences, vol. 2, no. 1, pp. 38-57 (2005).
- Hassan, G. N. A.: Multiobjective genetic programming for financial portfolio management in dynamic environments. (Doctoral dissertation). University College London (2010).
- Huang, C. F., Chang, C. H., Chang, B. R., Cheng, D. W.: A Study of a Hybrid Evolutionary Fuzzy Model for Stock Selection. In: Proceeding of the 2011 IEEE International Conference on Fuzzy Systems, pp. 210-217 (2011).
- Kirkpatrick, Ch., Dahlquist, J.: Technical analysis. New Jersey : FT Press (2010).
- Lohpetch, D., Corne, D.: Discovering effective technical trading rules with genetic programming: Towards robustly outperforming buy-and-hold. In: World Congress on Nature and Biologically Inspired Computing, pp. 431-467 (2009).
- Lohpetch, D., Corne, D.: Outperforming buy-and-hold with evolved technical trading rules: Daily, weekly and monthly trading. In: Proceedings of the 2010 international conference on Applications of Evolutionary Computation, vol. 6025, pp. 171-181 (2010).
- Lohpetch, D., Corne, D.: Multiobjective algorithms for financial trading: Multiobjective out-trades single-objective. IEEE Congress on Evolutionary Computation, pp. 192-199 (2011).
- Moat, H. S., Curme, CH., Avakian, A., Kenett, D. Y., Stanley, H. E., Preis, T.: Quantifying Wikipedia Usage Patterns Before Stock Market Moves. In: Scientific Rep, 3, 1801 (2013).
- Mullei, S., Beling, P.: Hybrid evolutionary algorithms for a multiobjective financial problem. In: Proceedings of the 1998 IEEE International Conference on Systems, Man, and Cybernetics, vol. 4, pp. 3925-3930 (1998).
- Neely, CH.: Risk-adjusted, ex-ante, optimal technical trading rules in equity markets. In: International Review of Economics and Finance, vol. 12, pp. 69-87 (1999).
- Poli, R., Langdon, W. B., McPhee, N. F.: A Field Guide to Genetic Programming. Retrieved from: <http://www.gp-field-guide.org.uk> (2008).
- Potvin, J. Y., Soriano, P., Vallée, M.: Generating trading rules on the stock markets with genetic programming. In: Computers & Operations Research, vol. 31, no. 7 (2004).
- Preis, T., Moat, S. H., Stanley, H. E.: Quantifying Trading Behavior in Financial Markets Using Google Trends. In: Sci Rep, 3, 1684 (2013).
- Ruiz, J. E., Hristidis, V., Castillo, C., Gionis, A., Jaimes, A.: Correlating Financial Time Series with Micro-Blogging Activity. In: Proceedings of the fifth ACM international conference on Web search and data mining, pp. 513-522 (2012).
- Tapia, G. C., Coello, C. A.: Applications of Multi-Objective Evolutionary Algorithms in Economics and Finance: A Survey. In: IEEE Congress on Evolutionary Computation, pp. 532-539 (2007).
- Zitzler, E., Laumanns, M., Thiele, L.: SPEA2: Improving the Strength Pareto Evolutionary Algorithm. In: Evolutionary Methods for Design, Optimization, and Control. In CIMNE, pp. 95-100 (2001).