

Računske družbene študije

Žan Žurič*

Mentor: prof. dr. Rudolf Podgornik, univ. dipl. fiz.†
FMF Oddelek za fiziko
20. MAREC 2016

Družbene vede preučujejo družbeno dinamiko. Računske družbene študije, katere bom podrobneje predstavil pa so interdisciplinarno področje, ki se problemov loteva bolj sistematično in si sposodi koncepte iz naravoslovnih znanosti. Tema te naloge bodo modeli, ki so na tak ali drugač način povezani s fiziko. Dotaknili pa se bomo tudi različnih primerov uporab le-teh v akademskih člankih naših in tujih raziskovalcev.

I. UVOD

Računske družbene študije so področje, ki z modeli in simulacijami analizira družbene pojave. Sam pojem družbenih ved ni natančno opredeljen. V tej nalogi bom mednje štel tudi ekonomijo, jezikoslovje in sociologijo. Disciplina postaja vedno bolj zanimiva zaradi ogromnih količin podatkov, ki se akumulira na spletu kot posledica socialnih omrežij. Ti podatki so največkrat uporabljeni v komercialne namene. Podjetja kot so Facebook, Google in Amazon disciplino s pridom izkoriščajo v marketinške namene tako, da prilagodijo prodajne strategije vsakemu posamezniku. Investicijske banke uporabljajo te metodologije, da skozi analizo novic predvidijo rast oz. padec vrednostnih papirjev. Računske družbene študije pa so poleg naštetega tudi predmet znanstvenih raziskovanj. Tak primer v Sloveniji je oddelek *Tehnologije znanja* na Inštitutu Jožef Štefan.

II. MODELI IN KONCEPTI

Uporabljeni modeli so večinoma statistične narave, saj gre večinoma za analizo obnašanja velikih sistemov. Nekateri modeli so povzeti direktno iz fizike, ostali pa se uporabljajo v fizikalne namene. Tako so npr. temperatura, Isingov model, perkolacija in model povprečnega polja povsem fizikalni modeli; strojno učenje se uporablja pri analizi podatkov iz trkalnikov, kjer je število podatkov po trku ogromno; celični avtomat pa je zelo uporabno orodje v matematični fiziki.

II.1. Celični avtomat

Celični avtomat je diskreten model, ki ga raziskujejo teorija izračunljivosti, matematika in teoretična biologija. Vsebuje pravilno mrežo celic, od katerih je vsaka v končnem številu stanj. Mreža ima lahko končno število


razsežnosti. Tudi čas je diskreten in stanje celice v času t je funkcija stanj končnega števila celic (okolic) v času $t - 1$. [1]

Naj bo L^d d -dimenzionalna mreža s spremenljivkami $S_i (i = 1, 2, \dots, L^d)$, katerih vrednost je navadno binarna, v splošnem pa naravna števila na intervalu $[1, Q]$, kjer $Q \in \mathbb{N}$ in $Q < 2$. Mreža je lahko različnih oblik. Najpogostejše uporabljene so kvadratna in trikotna planarna mreža v 2D ter primitivna kocka v 3D.

V vsakem trenutku t se lahko izračuna vrednost prihodnjega časovnega koraka $S_i(t+1)$ glede na vrednost sosednjih celic $S_k(t)$. Tak način izračuna se imenuje *simultani*. *Sekvenčni* način pa pomeni, da za izračun S_i uporabimo sedanje vrednosti S_k . Razlikujemo prav tako med različnimi zaporedji posodabljanja vrednosti spremenljivk, in sicer med naključnim in regularnim.

Primer takšne simulacije je Conwayeva *Igra življenja*. [2]. Simulacija se dogaja v 2D mreži. Pravila "igre" so:

1. Če je vrednost celice 0 in ima ta celica tri sosednje celice z vrednostjo 1, je v naslednjem koraku vrednost te iste celice enaka 1.
2. Če je vrednost celice 1 in ima ta celica dva ali tri sosednje celice z vrednostjo 1, je v naslednjem koraku vrednost celice 0.



Slika 1. Primeri različnih konfiguracij *Igre življenja*.

* zan.zuric@student.fmf.uni-lj.si

† rudolf.podgornik@fmf.uni-lj.si; http://www.fmf.uni-lj.si/~podgornik/FMF_SITE/Domacastan.html

Simulacija “igre” po zgornjih pravilih je izredno zanimiva in nepredvidljiva. Več o tem [3].

Maja 2010 je Andrew J. Wade objavil samoreproducirajoči vzorec, ki ga je poimenoval Gemini (angl. za dvojčka po horoskopu) [4]. Vzorec naredi kopijo samega sebe in uniči svojega starša po 34 milijonih generacij. Odkritje je bilo zaznamovano kot najpomembnejši vzorec v Conowayevi igri do sedaj, saj nam lahko pomaga razumeti, kako se je razvilo življenje na Zemlji.

II.2. Temperatura

Temperatura je ena od termodinamičnih spremenljivk, ki določa stanje sistemov. Pove nam, kako vroč oz. hladen je nek objekt.

Za nas bo zanimiva Boltzmannova porazdelitev:

$$p \propto e^{-E/k_B T}$$

kjer E predstavlja energijo konfiguracije, T temperaturo merjeno v K in k_B Boltzmannovo konstanto. Da zadeve poenostavimo, naj bo $k_B = 1$. Tako lahko merimo temperaturo in energijo v istih enotah.

Če je $\Delta\Gamma$ fazni prostor vseh možnih konfiguracij, definiramo *entropijo* kot $S = \ln \Delta\Gamma$. Tako je verjetnost, da izmerimo prav energijo E sorazmerna $P \propto \Delta\Gamma e^{-E/T}$ oz. $P \propto e^{-F/T}$ če uvedemo *prosto energijo* $F = U - TS$.

Uporabimo sedaj principe statistične termodinamike na družbenem pojavu pritiska sovrstnikov na posameznika. Vzemimo za primer dolgoletno vojno med podjetjema gaziranih pijač Coca Cola in Pepsi. Recimo, da moj sosed rajši pije Pepsi. Čeprav trenutno raje pijem Coca Colo, obstaja zunanja iniciativa, da bom v prihodnosti rajši pil Pepsi. Naj bo torej v našem primeru $E = N_{Pepsi} - N_{CocaCola}$, kjer je N_{Pepsi} število najbližjih sosedov, ki pijejo Pepsi in $N_{CocaCola}$ tistih, ki raje pijejo Coca Colo. T je mera, s katero se jaz kot posameznik upiram pijači večine svojih sosedov. V T so zajeti tudi vsi naključni dogodki, ki vplivajo name pa niso del našega modela. Torej lahko “temperaturo” razdelimo na $T = T_{volja} + T_{naključni\ dogodki}$. Verjetnost, da zamenjam svojo najljubšo pijačo, je torej razlika “energij” ali $e^{-2E/T}$. Očitno torej obstaja tendenca znižanja E . V nizko temperaturni limiti $T = 0$ je tako E ogromen, za nizke a pozitivne T se E poveča s sicer nizko verjetnostjo. Medtem ko pri $T \rightarrow \infty$ energija postane nepomembna, kar posledično pomeni, da so vse konfiguracije enako verjetne.

II.3. Isingov model

Model, poimenovan po Ernstu Isingu, je primarno matematični model feromagnetizma v statistični mehaniki. Sestavljen je iz diskretnih spremenljivk, ki predstavljajo magnetne dipolne momente - spine. Ta se lahko nahaja v bodisi +1 bodisi -1. Spini so navadno urejeni v mreži,

kjer interagirajo s svojimi sosedi.

$$E = -J \sum_{i,k} S_i S_k - B \sum_i S_i$$

S_i predstavlja spin, B predstavlja zunanje magnetno polje in $J > 0$ izmenjalni integral.

Če postavimo $B = 0$, dobimo identično različico primera Pepsi proti Coca Coli kot pri zgornjem modelu.

Prva vsota teče preko vseh sosednjih parov, druga pa preko vseh spinov. Torej če spin i spremeni svojo vrednost, je sprememba energije enaka $\pm \Delta E = 2(\sum_k S_k - B)$. Verjetnost, da pride do obrata, je $e^{-\Delta E/T}$.

Pri sobni temperaturi je železo magnetno. Isingov model to predvidi, saj velja $0 < T < T_c$ (T_c kritična temperatura) in $B = 0$. To potemtakem pomeni, da je večina spinov obrnjena v isto smer. Za temperature višje od kritične pa polovica spinov kaže v eno, polovica pa v drugo smer. Parameter reda je *magnetizacija* $M = \sum_i S_i$.

V eni dimenziji magnetni “material” ne obstaja, saj $T_c = 0$, v 2D kvadratni mreži je $T_c = \frac{2}{\ln(1+\sqrt{2})}$, za 3D primer enostavne kocke pa analitična rešitev ne obstaja (numerična $T_c \approx 4,5$).

II.4. Perkolacija

Model perkolacije je enostavnejši kot Isingov, posledično je tudi njegova zmožnost opisa pojavov manjša.

Vsaka celica mreže je zasedena z verjetnostjo p in prazna z verjetnostjo $1 - p$. Obstaja prag perkolacije p_c za katerega velja, da $\forall p < p_c$ obstaja le končno mnogo gruč. (*Gruča oz. cluster po angleško je skupina atomov ali molekul oz. v našem primeru skupina okupiranih celic*).


Za $p > p_c$ obstaja le ena neskončna gruča in, ko velja $p = p_c$, lahko soobstaja več neskončnih gruč imenovanih *fraktali*. Število zasedenih celic v neskončni gručici se spreminja s p_c kot L^D , kjer je D dimenzija fraktala. Neskončna grupa enostavno pomeni, da se razteza od enega konca vzorca do nasprotnega.

V eni dimenziji ponovno ni faznega prehoda, ker $p_c = 1$, v kvadratni mreži je $p_c \approx 0,593$ in za enostavno kocko $p_c \approx 0,312$ vsi z dimenzijo fraktala $D = 1$.

II.5. Aproksimacija povprečnega polja

Aproksimacija povprečnega polja se v ekonomiji imenuje “teorija reprezentativnega agenta”. Enostaven primer je Verhulstova logistična enačba $dx/dt = ax(1-x)$, ki se uporablja za modeliranje rasti populacije v znanosti populacijske dinamike. V ekonomiji se tak model imenuje Bassova difuzija, ki pa je dokaj ne zanesljiv.

Vzemimo Isingov model iz II.3 in zamenjajmo S_k v enačbi z njegovim povprečjem $\langle S_k \rangle = m = M/L^d$. Velja $\langle S_k \rangle \in \mathbb{R}$ in $-1 < \langle S_k \rangle < 1$. m predstavlja norma-



Slika 2. Prikaz gruč v dvodimenzionalni kvadratni mreži. a) kvadratna mreža, b) kvadratna mreža z 50% odprtih celic, c) kvadratna mreža z 67 % odprtih celic. Z odebeljeno črto je označena glavna gruča. Povzeto po [5]

lizirano magnetizacijo. Tudi celotno energijo E aproksimiramo kot vsoto E_i :

$$E = \sum_i E_i \quad E_i = \left(- \sum_k \langle S_k \rangle - B \right) S_i = -\bar{B} S_i$$

s povprečnim magnetnim poljem


$\bar{B} = (\sum_k \langle S_k \rangle + B) = B + mz$, kjer je z število sosedov. Sistem se sedaj obnaša, kot da je vsak spin S_i v efektivnem polju $\bar{B}$ na katerega vpliva zgolj magnetizacija m in ne več direktno sosedje S_k . Dve možni orientaciji S_i imajo energiji $\pm \bar{B}$. Povprečje:

$$m = \langle S_i \rangle = \tanh(\bar{B}/T) = \tanh[(B + mz)/T]$$

Ko razvijemo $\tanh$ v Taylorjevo vrsto za majhne m in B :

$$B = (1 - z/T)m + m^3/3 + \dots$$

Za $T < T_c$ je magnetizacija $m = \pm[3(z/T - 1)]^{1/2} \propto (T_c - T)^{1/2}$. Podobna aproksimacija tekoče pare naprimer



Slika 3. Temperaturna odvisnost normalizirane magnetizacije. Velja $T_c = z$. Povzeto po [6]

pripelje do Van der Waalrove enačbe.

Ta približek pa kot že rečeno pripelje do napake v vseh dimenzijah. Za linearno verigo model da vrednost $T_c = z = 2$, medtem ko je prava vrednost $z = 0$. Kar pomeni, da model povprečnega polja predvidi fazni prehod pri $T_c > 0$, čeprav prehod ni mogoč. Očitno so aproksimacija povprečnega polja, Van der Waalova enačba in podobni modeli zgolj približki. Točni postanejo le, ko vsak delec interagira z vsemi ostalimi delci v sistemu.

II.6. Strojno učenje

Strojno učenje oziroma pogostejši angleški izraz *Machine learning* je izredno široko in hitro rastoče področje računalništva. Najboljši opis strojnega učenja je verjetno opis Toma Mitchella iz ameriške univerze Carnegie Mellon iz leta 1997:

Računalniški program se uči iz izkušnje E v odnosu do neke vrste naloge T in uspešnostne mere P , če je njegova uspešnost pri nalogi T , merjena s P , izboljšana z izkušnjo E .

Strojno učenje se uporablja v industriji, medicini, ekonomiji ... za analizo podatkov in odkrivanje zakonitosti v podatkovnih bazah, podatkovno rudarjenje (angl. data mining), za generiranje baz znanja za ekspertne sisteme, za učenje prepoznavanja in predikcij, za razpoznavanje naravnega jezika in prevajanje, klasifikacijo tekstov in rudarjenje na svetovnem spletu, za nadzor dinamičnih procesov, razpoznavanje govora, pisave, slik itd.. Osnovni princip strojnega učenja je opisovanje pojavov iz podatkov. Rezultat učenja so lahko pravila, funkcije, relacije, sistemi enačb, verjetnostne porazdelitve ipd. Naučeni modeli poskušajo razlagati podatke in se lahko uporabijo za odločanje pri opazovanju modeliranega procesa v bodočnosti. [7]

Poznamo dve vrsti strojnega učenja:

1. **Nadzorovano strojno učenje:** Program je treniran na množici vnaprej klasificiranih problemov, iz katerih nato sklepa rešitev novih problemov.

2. **Nenadzorovano strojno učenje:** Program dobi neke vhodne podatke, v katerih nato sam najde vzorce in povezave.

II.6.0.1. Metoda podpornih vektorjev :

Eden izmed najpogostejše uporabljenih algoritmov nadzorovanega strojnega učenja je *Metoda podpornih vektorjev* (angl. Support vector machine oz. krajše SVM). Opisan je z množico učnih primerov:


$$\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m)\}; \quad \mathbf{x}_i \in \mathbf{X}, y_i \in \{-1, 1\}$$

Hiperravnina, ki ločuje razreda med sabo, je določena tako, da je razdalja do najbližjega primerka iz obeh razredov maksimalna. V zgornjem izrazu je y_i pripadnost razredu za učni primer $\mathbf{x}_i$. Hiperravnina je podana z normalnim vektorjem $\mathbf{w}$ in pragom b .

Vzorcu $\mathbf{x}_i$ se pri učenju priredi predznak in tako pripadnost razredu:

$$y_i = \text{sgn}((\langle \mathbf{w}, \mathbf{x}_i \rangle + b))$$

Od tega, kje se primer nahaja glede na hiperravnino (nad ali pod njo), je odvisen rezultat (pozitiven ali negativen). Mejni primer ima rezultat nič.[8]




Slika 4. Grafični prikaz, kako SVM algoritem klasificira različne podatke. Če prihodnji podatek pade nad premico, bo klasificiran kot "moder", če pade pod pa kot "zelen".

II.6.0.2. Nevronska mreža :

Pri strojnem učenju in kognitivnih znanostih so *nevronske mreže* skupine modelov, ki posnemajo biološke nevrnske mreže, največkrat možganov.

Današnji računalniki delujejo tako, da dobijo neke vhodne podatke na katerih nato procesor naredi zaporedja osnovnih operacij in prikažejo končen rezultat. Pri nevronske mrežah pa gre za programske ali pa tudi strojne rešitve, ki posnemajo živčne celice.



Slika 5. Nevronska mreža je predstavljena kot utežen usmerjen graf. Skrita vozlišča naredijo komputacije in so bistvo nevronske mreže. Povzeto po [9]

Mreža (oziroma kar graf kot se imenuje v smeri matematike imenovani teorija grafov) je sestavljena iz vozlišč, ki predstavljajo nevrone, in povezav, ki predstavljajo sinapse. Deluje tako, da sprožimo vozlišče z nekim vnosom in ta nato sproži vozlišča, s katerimi je povezan. Da pa ohranimo znano obliko vhoda in izhoda iz klasičnih računalnikov, opredelimo vhodna vozlišča in izhodna vozlišča. Poleg tega pa vsaki povezavi dodelimo utež, saj so nekatere povezave pomembnejše od ostalih. To je priročno, ko do istega vozlišča želi dostopati več različnih povezav. Vnosi so v ciljnim vozlišču v razmerju uteži povezav. Samemu vozlišču pa dodelimo prenosno funkcijo, ki določa prepustnost podatkov.

Uteži povezav so določene skozi strojno učenje. Proces učenja se imenuje po angl. *Backpropagation*. Najprej se povezavam določi naključne uteži, nato na glede že znano množico vhodnih podatkov določimo množico izhodnih podatkov. Napaka mreže je tako:

Željeni izhod – Izračunani izhod

kjer je izračunani izhod vrednost glede na postavljene uteži. Izhodna vozlišča sporočijo napako mreže skritim vozliščem, ki nato preuredijo uteži tako, da zmanjšajo napako. Postopek se ponavlja, dokler napaka ni dovolj majhna. Nato pa se *Backpropagation* ponovi še na ostalih učnih primerih. Prav zaradi tega dolgotrajnega procesa ponavljanja se nevronske mreže izredno počasi učijo, kar je razlog, da so jih povsem izrinili ostali algoritmi. Pred kratkim pa so ponovno pridobile na popularnosti ob razvoju *Deep learninga*.


III. APLIKACIJE

Sedaj pa si natančneje pogledimo še uporabo računskih družbenih študij na konkretnih primerih, da dobimo boljše predstavo, kakšne so dandanes zmožnosti te znanosti.

III.1. Volitve

Recimo, da želimo napovedati izid volitev neke stranke ali predsedniškega kandidata na volitvah. Bi to z zgoraj naštetimi koncepti bilo mogoče? Ekpa znanstevnikov na Inštitutu Jožef Štefan je v [10] spremljala odzive uporabnikov Twitterja na volitve v Bulgariji maja 2013 in primerjala reakcije z rezultati.

Problema so se lotili z opazovanjem tvitov v realnem času. Testni množici primerov je pred tem bil določen *sentiment* (mnenje, odnos do nečesa) s pomočjo večih ocenjevalcev, ki so vsak tvit označili kot pozitiven, nevtralen ali negativen.



Slika 6. Diagram učenja klasifikatorja in procesiranja tvitov v realnem času. Povzeto po [10]

V članku so uporabili pristop nadzorovanega strojnega učenja in SVM (II.6.0.1) na množici 29433 učnih primerov. Od tega je bilo 3258 tvitov označenih kot neprijemnih, 6716 kot negativnih, 11015 nevtralnih in 8444 pozitivnih.

Odločitvena funkcija hiperravnine je imela obliko:

$$d(x) = x \times w + b = x_1 \times w_1 + x_2 \times w_2 + \dots + x_n \times w_n + b$$

Splošno razpoloženje volilcev pred volitvami je bilo apatično zaradi številnih afer politikov. To se je izražalo na prevladujočih negativnih tvitih.

III.1.0.3. Analiza pred volitvami :

Zanimivo je, da je bil indikator, ki je napovedal vrstni red volitev skupno število tvitov. Čeprav je torej stranka GERB imela največ negativnih odzivov na Twitterju, je postala relativna zmagovalka volitev z največ sedeži v parlamentu.

Tabela I. Število negativnih, nevtralnih in pozitivnih tvitov na stranko pred volitvami

Stranka	Neg.	Nevt.	Poz.	Skupaj
GERB	2073 (74,4%)	771 (20,9%)	174 (4,7%)	3688 (100%)
BSP	1087 (74,8%)	284 (19,6%)	82 (5,6%)	1453 (100%)
DPS	244 (51,6%)	158 (33,4%)	71 (15,0%)	473 (100%)
ATAKA	123 (60,6%)	62 (30,5%)	18 (8,9%)	203 (100%)

Tabela II. Rezultati volitev, število tvitov in razlika med negativnimi in negativnimi tviti na stranko pred volitvami

Stranka	Sedeži v parlamentu	Skupno število	Neg.-Poz.
GERB	97 (40,4%)	3688 (63,4%)	2569 (66,7%)
BSP	84 (35,0%)	1453 (25,0%)	1005 (26,1%)
DPS	36 (15,0%)	473 (8,1%)	173 (4,5%)
ATAKA	23 (9,6%)	203 (3,5%)	105 (2,7%)

III.1.0.4. Analiza po volitvah :

Dan po volitvah še kar prevladujejo negativni tviti. Opazimo pa lahko dokaj tesno korelacijo med deležem sedežev v parlamentu in procentom skupnega števila odzivov.

Tabela III. Število negativnih, nevtralnih in pozitivnih tvitov na stranko po volitvah


Stranka	Neg.	Nevt.	Poz.	Skupaj
GERB	1510 (78,2%)	367 (19,0%)	54 (2,8%)	1931 (100%)
BSP	1139 (79,4%)	262 (18,3%)	33 (2,3%)	1434 (100%)
DPS	522 (72,4%)	168 (23,3%)	31 (4,3%)	721 (100%)
ATAKA	255 (64,2%)	102 (25,7%)	40 (10,1%)	397 (100%)

Tabela IV. Rezultati volitev, število tvitov in razlika med negativnimi in negativnimi tviti na stranko po volitvah

Stranka	Sedeži v parlamentu	Skupno število	Neg.-Poz.
GERB	97 (40,4%)	1931 (43,1%)	1456 (44,6%)
BSP	84 (35,0%)	1434 (32,0%)	1106 (33,8%)
DPS	36 (15,0%)	721 (16,1%)	491 (15,0%)
ATAKA	23 (9,6%)	397 (8,9%)	2015 (6,6%)

III.2. Finančni trgi

Investicijske banke kot so Goldman Sachs, Morgan Stanley, JPMorgan Chase, Deutsche Bank izkoriščajo analizo sentimenta novic, da kupijo finančne instrumente, preden bi si katerikoli trader uspel sestaviti sliko o situaciji. Vsak dan izide tisoče novih novic in ljudje lahko sledimo le mali del le-teh. Na IJS so v [11] preverjali



Slika 7. Število negativnih minus pozitivnih tvitov o štirih vodilnih strankah: GERB (Državljeni za evropski razvoj Bulgarije), BSP (Bulgarska socialistična stranka), DPS (Gibanje za pravice in svobode), ATAKA (Napad). Volitve so bile 12.5.2013. Povzeto po [10]

korelacijo in kavzalnost sentimenta tvitov korporacij in vplivnih finančnih figur s ceno 30 delnic iz DJIA (Dow Jones Industrial Average) indeksa.

Zbrali so bazo 1,5 milijona tvitov, katere je ocenila skupina finančnih strokovnjakov. Ponovno so uporabili SVM algoritem (II.6.0.1). Za povezavo sentimenta Twitterja in ceno delnic so uporabili *Pearsonovo korelacijo* in *Grangerjev test kavzalnosti*.

Pearsonova korelacija med spremenljivkami X_t in Y_t :

$$\rho(X, Y) = \frac{\langle X_t Y_t \rangle - \langle X_t \rangle \langle Y_t \rangle}{\sqrt{(\langle X_t^2 \rangle - \langle X_t \rangle^2)(\langle Y_t^2 \rangle - \langle Y_t \rangle^2)}}$$

kjer $\langle \cdot \rangle$ pomeni časovno povprečje. $\rho(X, Y)$ pa nam kvantizira linearno povezanost med spremenljivkama. Grangerjev test kavzalnosti pa ima nekoliko več korakov in je prezapleten za natančnejši opis.

Čeprav so izračunani Pearsonovi koeficienti relativno nizki, so lahko iz njih zaključili, da korelacija obstaja. Grangerjev test pa je pokazal vzročnost v obe smeri; iz tvitov v finančni trg in obratno, odvisno od delnice.

III.2.0.5. Komulativni abnormalni donos :

Komulativni abnormalni donos predstavlja mero, s katero bi investor ocenil pravilnost teorije. Abnormalni donos se izračuna:

$$AD = \text{Dejanski donos} - \text{Pričakovani donos}$$

Komulativni abnormalni donos pa je zgolj seštevek vseh abnormalnih donosov. Torej nam KAD (Komulativni abnormalni donos) pove, koliko delnica odstopa od vredno-

sti, ki bi jo ta imela, če se nek finančni dogodek ne bi zgodil.


V 8 lahko opazimo statistično relevanten odstop od cene pred samim dogodkom. V grafu so vključeni tudi "Earning Announcements", ki jih podjetja izdajo vsake četrta leta. Pojav dviga oz. pada cene po EA je dobro poznan in se po angl. imenuje *Post-earnings-announcement drift*. Bolj zanimiv pa je dvig cene pred samim dogodkom, kar lahko pripišemo uhašanju informacij in trgovanju na podlagi notranjih informacij.

III.3. Zaupanje v gospodarstvo (angl. Business confidence)

V Nemčiji večkrat naredijo raziskavo, v kateri vprašajo pomembne poslovneže, kako bi ocenili prihodnost gospodarstva. Njihova mnenja so povzeta in objavljena kot Ifo indeks v obliki pozitivnih, nevtrálnih in negativnih mnenj ter povprečja.


Očitno je, da obstaja tendenca k močno pozitivnemu ali močno negativnemu mnenju podobno kot pri simulaciji Isingovega modela v 9. Torej se čredni nagon pojavlja tudi, ko strokovnjaki ocenjujejo povsem objektivne ekonomske podatke.

Strokovnjaki v anketi drug na drugega vplivajo kot feromagnetni spini. High tech bubble ameriške borze, ki je počil spomladi leta 2000, je verjetno bil še en primer psihološkega vpliva na ekonomijo. Najprej so številni mislili, da bo vse v zvezi z računalniki prineslo dobiček, nato pa so se začeli porajati dvomi.



Slika 8. Prikaz komulativnega abnormalnega. x os predstavlja zamik med nekim finančnim dogodkom in KAD. Povzeto po [11]

Ugotovili so tudi, da preveč šuma prepreči proces spontane magnetizacije. Recimo, da izide dobro poročilo ali novica, večina ljudi posledično postane optimistična. Če pa pride do fluktuacij med dobrimi in slabimi novicami, ljudje enostavno ignorirajo novice in prevzamejo naključna mnenja o situaciji.



Slika 9. Isingov model na 19×19 kvadratni mreži pri $T = 2,2$. Spontana sprememba magnetizacije iz pozitivne v negativno se lahko interpretira kot sprememba zaupanja v gospodarstvo. Povzeto po [12]


III.4. Asimetrične Coulombove tekočine

Interdisciplinarnost pa ni samo enosmerna. Tudi koncepti in ideje iz družbenih ved so lahko prenosljivi na fiziko. Fizikom dajo možnost, da na nek fizikalen problem pogledajo drugače. V [13] so Podgornik et al. uporabili idejo antifragility (antikrhkost) Nassima Taleba iz istoimenske knjige [14].

Antikrhkost kot jo definira Taleb:

Enostavno je antikrhkost definirana kot konveksen odziv na stresor ali vir škode, ki vodi k pozitivni občutljivosti ob porastu nestabilnosti. Krhkost je definirana kot konkavna senzitivnost na stresor, ki vodi k negativni občutljivosti ob porastu nestabilnosti. Povezava med krhkostjo, konveksnostjo in občutljivostjo na nered je matematična, pridobljena z izrekom in ne izhaja iz empiričnega rudarjenja podatkov ali kakšne zgodovinske pripovedi. Je *a priori*.

Če poenostavimo, je antikrhkost lastnost sistema, da ob stresu, šokih, volatilnosti, šumih, napakah, napadih ali okvarah, postane odpornejši ali robustnejši. Taleb v knjigi poudarja razliko med odpornostjo in antikrhkostjo. Robusten sistem v najboljšem primeru ob šoku ostane enak, antikrhek sistem pa je po šoku



Slika 10. Shema modela sestavljenega iz neskončne plošče potopljene s ϵ_p v raztopini s ϵ_m . Desna stran plošče pri $z = 0$ je naključno nabita. Multivalentni ioni z valentnostjo q so prikazani kot velike modre krogle, monovalentni anioni soli pa kot majhne modre in oranžne kroglice. Povzeto po [13]

robustnejši kot pred njim. Ugotavlja, da je pojem antikrhkosti dandanes povsem izven družbene zavesti, saj ob vprašanju, kaj je nasprotje krhkega, večina odgovori odporen, kar pa lahko po krajšem razmisleku ovržemo. To pa je zanimivo predvsem, ker je prav antikrhkost gonilo naravne selekcije in razlog, da znanstvene ideje in koncepti preživijo skozi stoletja poskusov.

Coulombova tekočina je tekočina nabitih ionov. V članku so uporabili asimetrično mešanico multivalentnih protionov (ion, ki spremlja nek drug ionski del, zato da se obdrži električna nevtralnost celote. V NaCl je natrijev kation protiion za kloridni anion in obratno) v raztopini monovalentnih ionov. Antikrhkost se v članku nanaša na dejstvo, da zunanja nehomogeno nabita površina zmanjša termični nered v sistemu tako, da ga prisili, da se obnaša bolj urejeno.

Model je sestavljen iz neskončne dielektrične plošče debeline b in dielektrične konstante ϵ_p , potopljene v raztopini ionov z dielektrično konstanto ϵ_m . Glej III.4.


Desna stran plošče je naključno nabita z Gaussovo porazdelitvijo:

$$\mathcal{P}[\rho] = C \exp \left(-\frac{1}{2} \int d\mathbf{r} g^{-1}(\mathbf{r}) [\rho(\mathbf{r}) - \rho_o(\mathbf{r})]^2 \right)$$

kjer je C normalizacijska konstanta, $\rho_o(\mathbf{r})$ je povprečje in $g(\mathbf{r})$ varianca prostorske porazdelitve naključnih površinskih nabojev.

Opazili so, da se ob površini kopičijo protiioni zaradi enodelčne interakcijske energije, ki je posledica nereda. Energija je privlačna in je logaritmčno odvisna od razdalje od plošče. To pomeni, da neenkomerno nabita površina privede sistem v nižje stanje termičnega nereda. Pojav lahko sistematično opišemo z razliko entropij protionov v redu in neredu:

$$\frac{\Delta S(\chi)}{Nk_B} = \chi \psi \left(1 - \frac{\chi}{2} \right) + \ln \Gamma \left(1 - \frac{\chi}{2} \right)$$



Slika 11. Komulativni naboj $Q(\tilde{z})$ poleg naključno nabite površine za različne parametre sklopitve nereda χ . Povzeto po [13]

kjer je $\psi(\cdot)$ digama funkcija, definirana kot $\psi(x) = \frac{d}{dx} \ln(\Gamma(x))$ in $\chi = 2\pi q^2 l_B^2 g$ parameter sklopitve nereda.

Drugače povedano, zmanjšanje *translacijske entropije* multivalentnih protionov v raztopini se zgodi, ker dodamo končno mero *konfiguracijske entropije* z neenakomerno nabito površino. Tu lahko povlečemo vzporednico z antikrhkostjo, saj se z zunanjim neredom efektivno zmanjša notranji termalni nered.

ZAKLJUČEK

Kot ste lahko opazili, je možnost uporabe fizike v družbenih vedah ogromna. V nalogi sem predstavil zgolj nekaj načinov, v praksi pa jih seveda obstaja mnogo več. Vseeno pa kot študent lahko rečem, da je aplikativna stran fizike na naši fakulteti na žalost povsem zanemarjena. Predavatelji bi lahko ob predstavitvi modelov podali tudi aplikacijo v drugih znanostih (biologiji, sociologiji, računalništvu itd.). Tako bi lahko na primer Isingov model, ki je bil del predavanj Statistične termodinamike v drugem letniku, obravnavali v malce drugačni luči, predstavljeni v II.3. To bi bil način, da nam predstavijo še druge aplikacije fizike in tako razbili monotonost nekaterih predmetov.

VIRI

- [1] https://sl.wikipedia.org/wiki/Celi%C4%8Dni_avtomat (Datum: 25.2.2016)
- [2] Gardner, Martin (Oktober 1970). Mathematical Games – The fantastic combinations of John Conway’s new solitaire game “life”. Scientific American 223. pp. 120–123. ISBN 0-89454-001-7
- [3] <https://www.youtube.com/watch?v=R9Plq-D1gEk> (Datum: 26.2.2016)
- [4] "Universal Constructor Based Spaceship". Conway-life.com. (Datum: 24.6.2012)
- [5] Berkowitz, Brian & Ewing, P. Robert (1998). Percolation theory and network modeling applications in soil physics. Surveys in Geophysics 19. pp. 23-72.
- [6] <http://www-f1.ijs.si/~vilfan/SM/ln4a.pdf> (Datum: 27.2.2016)
- [7] <https://www.fri.uni-lj.si/si/izobrazevanje/11813/class.html> (Datum: 27.2.2016)
- [8] https://sl.wikipedia.org/wiki/Metoda_podpornih_vektorjev (Datum: 28.2.2016)
- [9] https://en.wikipedia.org/wiki/Artificial_neural_network (Datum: 9.3.2016)
- [10] Smailović J., Kranjc J., Grčar M., Žnidaršič M., Mozetič I.. Monitoring the Twitter sentiment during the Bulgarian elections. Proc. IEEE Intl. Conf. on Data Science and Advanced Analytics (DSAA), pp. 1-10, IEEE, doi: 10.1109/DSAA.2015.7344886, Paris, France, October 19-21, 2015.
- [11] G. Ranco, D. Aleksovski, G. Caldarelli, M. Grčar, I. Mozetič. The effects of Twitter sentiment on stock price returns, supplement, PLoS ONE 10(9): e0138441, doi: 10.1371/journal.pone.0138441, 2015.
- [12] Stauffer D., Social applications of two-dimensional Ising models. Institute for Theoretical Physics, Cologne University, D-50923 Köln, Euroland
- [13] Naji A., Ghodrat M., Komaie-Moghaddam H., Podgornik R.. Asymmetric Coulomb fluids at randomly charged dielectric interfaces: Anti-fragility, overcharging and charge inversion. The Journal of Chemical Physics 141, 174704 (2014); doi: 10.1063/1.4898663
- [14] Taleb, Nassim. Antifragile: Things That Gain From Disorder. New York: Random House, 2012.
- [15] Stauffer D., Solomon S.. Applications of Physics and Mathematics to Social Science. Racah Institute of Physics, Hebrew University, IL-91904 Jerusalem, Israel

SEZNAM SLIK

- | | | |
|----|---|---|
| 1 | Primeri različnih konfiguracij <i>Igre življenja</i> . | 1 |
| 2 | Prikaz gruč v dvodimenzionalni kvadratni mreži. a) kvadratna mreža, b) kvadratna mreža z 50% odprtih celic, c) kvadratna mreža z 67 % odprtih celic. Z odebeljeno črto je označena glavna gruča. Povzeto po [5] | 3 |
| 3 | Temperaturna odvisnost normalizirane magnetizacije. Velja $T_c = z$. Povzeto po [6] | 3 |
| 4 | Grafični prikaz, kako SVM algoritem klasificira različne podatke. Če prihodnji podatek pade nad premico, bo klasificiran kot “moder”, če pade pod pa kot “zelen”. . . | 4 |
| 5 | Nevronska mreža je predstavljena kot utežen usmerjen graf. Skrita vozlišča naredijo komputacije in so bistvo nevrnske mreže. Povzeto po [9] | 4 |
| 6 | Diagram učenja klasifikatorja in procesiranja tvitov v realnem času. Povzeto po [10] | 5 |
| 7 | Število <i>negativnih</i> minus <i>pozitivnih</i> tvitov o štirih vodilnih strankah: GERB (Državljeni za evropski razvoj Bulgarije), BSP (Bulgarska socialistična stranka), DPS (Gibanje za pravice in svobode), ATAKA (Napad). Volitve so bile 12.5.2013. Povzeto po [10] | 6 |
| 8 | Prikaz komulativnega abnormalnega. x os predstavlja zamik med nekim finančnim dogodkom in KAD. Povzeto po [11] | 7 |
| 9 | Isingov model na 19×19 kvadratni mreži pri $T = 2,2$. Spontana sprememba magnetizacije iz pozitivne v negativno se lahko interpretira kot sprememba zaupanja v gospodarstvo. Povzeto po [12] | 7 |
| 10 | Shema modela sestavljenega iz neskončne plošče potopljene s ϵ_p v raztopini s ϵ_m . Desna stran plošče pri $z = 0$ je naključno nabita. Multivalentni ioni z valentnostjo q so prikazani kot velike modre krogle, monovalentni anioni soli pa kot majhne modre in oranžne kroglice. Povzeto po [13] | 8 |
| 11 | Komulativen naboj $Q(\tilde{z})$ poleg naključno nabite površine za različne parametre sklopitve nereda χ . Povzeto po [13] | 8 |