

Rani signali faznog prijelaza

Petar Perković
Mentor: Davor Horvatić

20. siječnja 2018.

Sažetak

U ovom radu su opisani mogući oblici ponašanja sustava u blizini faznog prijelaza i signali koji na to upućuju. Bavili smo se kretanjem cijena kriptovaluta i predložili proces s kojim smo predviđali buduće vrijednosti. Proces je baziran na tehnikama strojnog učenja. Na kraju smo dobili modele koji predviđaju cijene raznih kriptovaluta i usporedili njihove rezultate.

1 Uvod

Mnogi složeni sustavi imaju prijelomnu točku u kojoj sustav naglo prelazi iz jednog stanja u drugo. Primjeri se mogu naći u raznim granama znanosti, od naglih klimatskih promjena u klimatologiji,^[2] do kraha burze u ekonomiji^[3] i napadaja epilepsije u medicini.^[4]

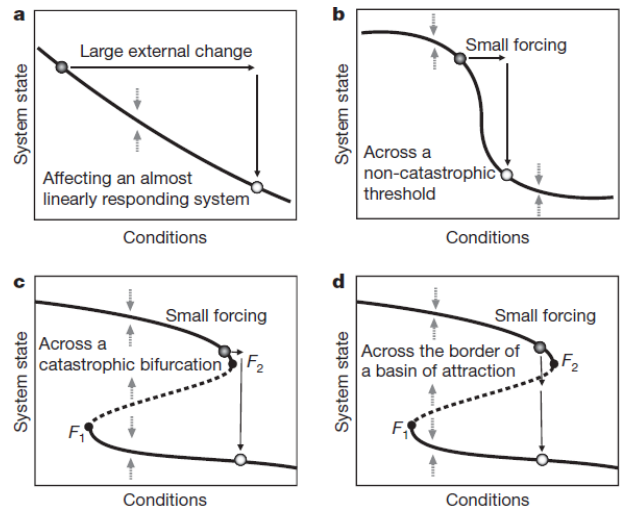
Takvi prijelazi su često teško predvidljivi. Razlog tome je što modeli složenih sustava ne opisuju sustav dovoljno precizno za predviđanje takvih situacija i sustavi uglavnom nemaju jasne signale koji upućuju na fazni prijelaz.

Unatoč tome iz raznih istraživanja je vidljivo da postoje rani signali faznih prijelaza koji imaju slična svojstva za različite sustave.^[5] To govori da se mogu odrediti dinamike ponašanja sustava blizu kritične točke koje su općenite za širok opseg sustava.

Sustavi mogu različito reagirati na promjenu uvjeta u kojima se nalaze. Neki sustavi će reagirati proporcionalno promjeni uvjeta i ne dolazi do velikih iznenađenja(Slika 1, a), dok će drugi sustavi reagirati burno na malu promjenu uvjeta(Slika 1, b). U oba ova slučaja efekt promjene je kontinuiran i reverzibilan, te postoji samo jedno stanje za iste uvjete.

Također postoje sustavi u kojima pri maloj pro-

mjeni uvjeta dolazi do kritičnog prijelaza(Slika 1, c i d). To je primjer katastrofalne bifurkacije. U takvim sustavima dolazi do nagle promjene stanja. Efekt takvih promjena nije kontinuiran i reverzibilan, a sustav se može nalaziti u 2 različita stanja za iste uvjete.



Slika 1: Grafovi ovisnosti stanja o uvjetima za različite sustave.^[1]

Kritično usporavanje je fenomen koji je jedan od glavnih pokazatelja da se sustav približava kritičnoj granici.^[6] Sustav se prilikom malih perturbacija sporije vraća u osnovno stanje što je sus-

tav bliže točki prijelaza. Taj fenomen je prisutan u većini sustava. Analiza raznih modela pokazuje da usporavanje počinje daleko od točke bifurkacije i vrijeme povratka se smanjuje u nula kako se približava kritičnoj točki.

Stopa povratka u početno stanje je jedna od veličina koje se mijenjaju prilikom kritičnog usporavanja.^[7] Nju se može mjeriti tako da se na sustav primjeni mala perturbacija, koja neće uzrokovati prijelaz sustava preko granice. Pomoću toga se može odrediti blizina kritične točke. Primjer toga je uzimanje dijela ekosustava i micanje dijela biomase iz njega. Sustav koji je daleko od kritične točke će puno brže obnoviti tu biomasu nego sustav koji je blizu izumiranja.^[8] Problem ove metode je što je često jako teško ili gotovo nemoguće napraviti perturbaciju u nekim složenim sustavima.

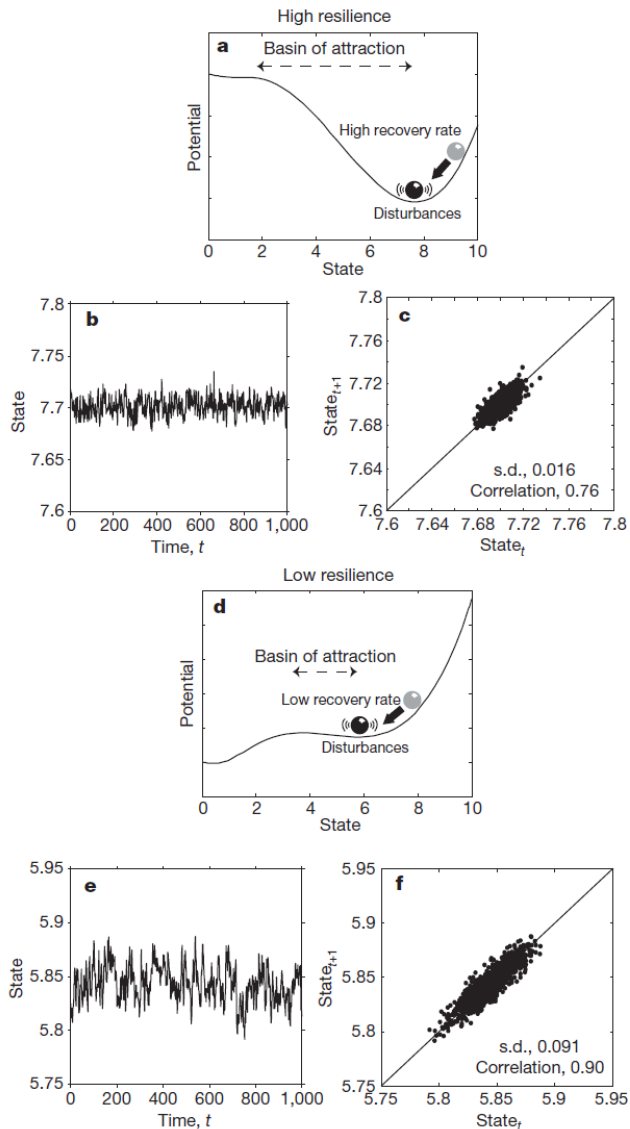
Porast autokorelacije je druga posljedica kritičnog usporavanja.^[9] Kako se sustav sporije vraća u početno stanje, tako je i stanje u trenutku $t + 1$ sličnije stanju u trenutku t . To govori da dolazi do povećanja autokorelacije u sustavu u blizini bifurkacije. Mjeriti se može računanjem autokorelacijskog koeficijenta među susjednim stanjima u vremenskom nizu (Slika 2, c i f).

Porast varijance se također primjećuje prilikom kritičnog usporavanja.^[10] Blizu kritične točke utjecaji šokova ne opadaju i akumulirano povećavaju varijancu u sustavu. Na Slici 2 vidimo primjer sustava daleko od kritične točke koji ima nisku varijancu (b) i primjer sustava blizu kritične točke s visokom varijancom (e).

Ova tri rana signala su posljedica kritičnog usporavanja sustava u blizini bifurkacije. Uz njih postoje još neki rani signali koji ukazuju na fazne prijelaze.

Porast asimetrije fluktuacija se javlja kad je sustav blizu kritične točke.^[11] U smjeru prijelaza stopa promjene je manja nego na suprotnoj strani, pa tu sustav provodi više vremena. To rezultira asimetričnom distribucijom oko točke stabilnosti.

Treperenje je još jedan rani signal. Događa se ako je stohastičko prisiljavanje dovoljno jako da pomiče sustav između dva područja privlačenja kad je sustav u bistabilnom području.^[12] Može se uočiti u povećanju varijance i asimetrije.



Slika 2: Prikaz sustava u blizini(d) i daleko(a) od kritične točke. Prikazan su stanja sustava u vremenu i autokorelacijski koeficijenti za oba sustava.^[1]

U ovom radu smo proučavali spektar karakteristika koje mogu nagovjestiti fazni prijelaz povezan s dinamikom vremenskih serija. Predložen je proces za predviđanje cijena kriptovaluta. Koristit će se tehnike strojnog učenja i proučavati njihov značaj za predviđanje budućih vrijednosti u kompleksnim sustavima.

2 Metodologija

U ovom poglavlju ćemo proći proces koji koristimo za predviđanje budućih vrijednosti u vremenskim serijama kompleksnih sustava. Testirat ćemo ga na vremenskim serijama različitih kriptovaluta. Proces se sastoji od 4 osnovna koraka:

1. Priprema podataka
2. Izvlačenje karakteristika
3. Redukcija dimenzionalnosti
4. Treniranje modela i predviđanje

2.1 Priprema podataka

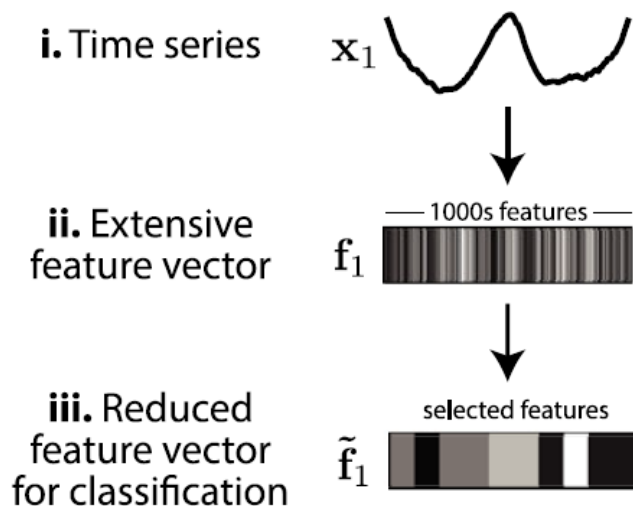
Za podatke su izabrane vremenske serije raznih kriptovaluta zbog mnogo naglih skokova i padova cijena. Također su buduće vrijednosti u tim serijama jako teško predvidljive i kvalitetan rezultat na njima je dobar pokazatelj mogućnosti modela. Kriptovalute koje smo analizirali su: bitcoin, ethereum, litecoin, monero, ripple, nem i dash. Za svaku valutu imamo dnevne podatke o najvišoj i najnižoj cijeni, cijeni na početku i kraju dana, volumenu prometa i kapitalizaciji tržišta.

Za predviđanje podataka su uzete vremenske serije od po 7 dana pomoću kojih je predviđena vrijednost za idući dan. Kako cijene kriptovaluta dugoročno imaju trend rasta treba vrijednosti koje koristimo svesti na red veličine jednak kroz cijelo razdoblje. To postizemo uzimajući postotak rasta od prošlog dana kao vrijednosti koje koristimo. Iz tako pripremljenih podataka izvlačimo karakteristike vremenskih serija.

2.2 Izvlačenje karakteristika

Kako bismo što bolje predviđali buduće vrijednosti iz vremenskih serija izvući ćemo karakteristike koje nam mogu ukazivati na fazni prijelaz. Među njima su već navedene karakteristike varijanca, koeficijenti autokorelacije za različit broj koraka i koeficijent asimetrije. Uz te karakteristike vremenskih nizova koje znamo da mogu ukazivati na fazni prijelaz uzete su još dodatne karakteristike koje mogu

pomoći modelu da što bolje predvidi buduću vrijednost. Te karakteristike se kreću od jednostavnijih poput minimuma, maksimuma i srednje vrijednosti, do kompleksnijih poput entropije i parametara ARMA modela. Konačni broj izvučenih karakteristika se penje do 200 za svaku od varijablu dostupnu u vremenskoj seriji u ovisnosti o dužini i tipu vremenske serije. Za izvlačenje karakteristika korišten je programski paket u Pythonu `tsfresh`, a puna lista karakteristika se može pogledati u [15].



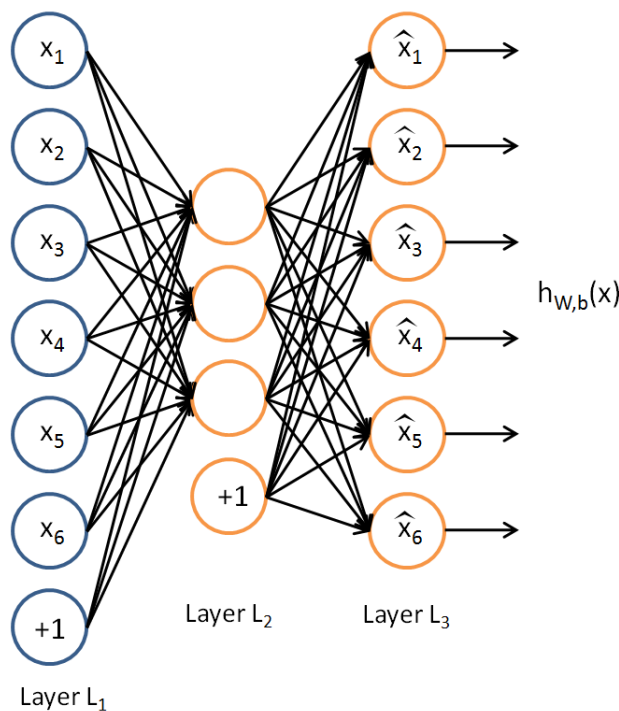
Slika 3: Prikaz procesa dobivanja karakterističnih vektora za treniranje modela. ^[14]

2.3 Redukcija dimenzionalnosti

U prethodnom koraku se izvuče do 1000 karakteristika za svaku varijablu vremenske serije i ako je taj broj u redu veličine broja opservacija, prilikom treniranja modela za predviđanje doći će do prenaučenosti. Kako većina tih karakteristika prenosi slične informacije moguće je iz njih izvući samo najbitnije informacije. To će se postići korištenjem metoda redukcije dimenzionalnosti. Te metode omogućuju da se broj karakteristika drastično smanji, a u procesu se ne gubi puno na prenesenoj informaciji. Metode koje smo koristili su PCA i autoenkoder.

2.4 PCA

PCA ili analiza svojstvenih komponenti je metoda redukcije dimenzionalnosti.^[18] Ona ortogonalno transformira skup vektora koji mogu biti međusobno korelirani u skup vektora koji nisu korelirani. Broj novih komponenti je manji ili jednak broju opservabli ili broju opservacija minus jedan. Komponente novog vektora su poredane po varijanci od najveće do najmanje. Pomoću ove metode iz početnog broja karakteristika dobijemo željeni broj transformiranih karakteristika s najvećom varijancom. Za PCA je korišten paket scikit-learn u Pythonu.



Slika 4: Primjer autoenkodera.


2.4.1 Autoenkoder

Autoenkoder je tip neuronske mreže koji se koristi za smanjenje dimenzije podataka. Sastoji se od dijela za šifriranje i dešifriranje podataka. Dio za šifriranje izvlači najbitnije karakteristike ulaza i sprema ih u srednji sloj koji je dimenzijski manji od početnog. Srednji sloj možemo shvatiti kao šifru za podatak. Ona predstavlja bitne karakteristike ulaza i ima manju dimenziju od ulaza.

Dio za dešifriranje pokušava rekonstruirati srednji sloj što sličnije ulaznom podatku. Za aktivacijsku funkciju je uzeta ReLU funkcija, a za funkciju gubitka prosječna kvadratna pogreška. Autoenkoder smo istrenirali na vektorima karakteristika opservacija i kao nove karakteristike uzeli vrijednosti izlaza srednjeg sloja. Za konstruiranje autoenkoder korišten je paket Tensorflow u Pythonu.

2.5 Treniranje modela i predviđanje

Kad smo dobili karakteristične vektore reducirane dimenzije koristili smo duboku neuronsku mrežu za treniranje i predviđanje budućih vrijednosti kriptovaluta. Duboke neuronske mreže smo izabrali zbog toga što mogu modelirati kompleksna nelinearna ponašanja puno bolje od ostalih metoda. Sve karakteristike smo normalizirali na skali od [0, 1]. Skup podataka smo podijelili tako da smo prvih 70% unosa koristili za treniranje, 10% za unakrsnu validaciju i zadnjih 20% opservacija kao test. Tako možemo testirati može li model predviđati buduće događaje u vremenskoj seriji, ako je treniran na prošlosti. Neuronske mreže su konstruirane u ovisnosti o broju opservacija i karakteristika. Cilj je bio da ne dođe do prenaučnosti modela jer broj opservacija nije prevelik, ali da uspije naučiti kompleksna ponašanja kriptovaluta. Kao aktivacijska funkcija korištena je ReLU,^[17] a za funkciju gubitka prosječna kvadratna pogreška. Neuronske mreže su napisane u Pythonu pomoću Tensorflowa i trenirane su na grafičkoj kartici.



Slika 5: Primjer neuronske mreže s 3 sloja.

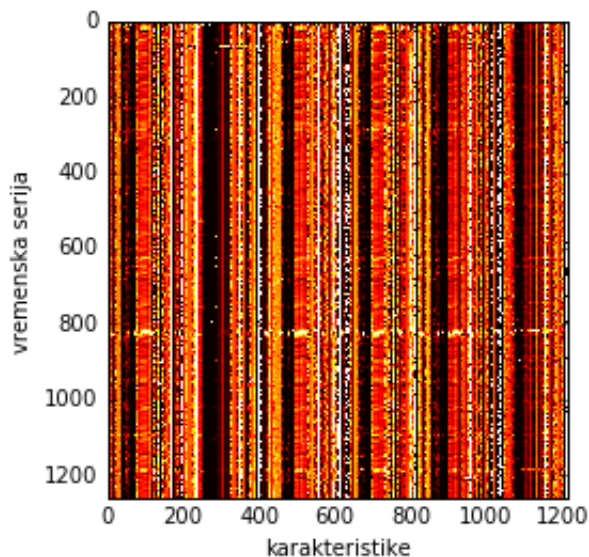
3 Analiza i rezultati

Podatke o sedam različitih kriptovaluta smo pripremili kako je napisano u prethodnom poglavlju. Broj opservacija za svaku kriptovalutu se može vidjeti u Tablici 1. Za svaku kriptovalutu imamo najvišu i najnižu cijenu, cijenu na početku i kraju dana, volumen prometa i kapitalizaciju tržišta. Za svaku od tih vrijednosti su izvučene karakteristike koje opisuju vremenske nizove.

Kriptovaluta	Opservacije	Broj karakt.
Bitcoin	1649	1186
Ripple	1551	1188
Litecoin	1649	1285
Monero	1260	1220
Dash	1363	1189
Nem	946	1185
Ethereum	818	1150

Tablica 1: Prikaz broja opservacija i izvučenih karakteristika za svaku kriptovalutu.

U Tablici 1 se može vidjeti broj izvučenih karakteristika za svaku kriptovalutu i on je približno dvjesto po svakoj od šest varijabli. Broj varijabli varira zato što su neke karakteristike nisu mogle biti dobivene u svakoj vremenskoj seriji. Vizualni prikaz karakteristika se može vidjeti na slici 6.



Slika 6: Vizualni prikaz karakterističnih vektora za sve vremenske serije kriptovalute Monero.

Nakon što smo dobili karakteristike na njima je izvršena redukcija dimenzionalnosti. Korištena je PCA i autoenkoder. Autoenkoder se sastojao od sloja za enkodiranje veličine 256 neurona, srednjeg sloja od 30 neurona, sloja za dekodiranje od 256 neurona i izlaznog sloja veličine vektora koji ulazi u autoenkoder. Autoenkoder je treniran za svaku kriptovalutu zasebno. Pomoću obje metode vektore karakteristika reduciramo na dimenziju 30 i koristimo ih u daljnjem treniranju modela za predviđanje.


Za predviđanje smo koristili dvije arhitekture.

Kriptovaluta	Arhitektura neuronske	Greška na treningu (autoenkoder)	Greška na testu (autoenkoder)	Greška na treningu (PCA)	Greška na testu (PCA)
Bitcoin	16-8-4-2-1	0.0108	0.0144	0.0132	0.0156
Ripple	16-8-4-2-1	0.0089	0.0150	0.0084	0.0166
Litecoin	16-8-4-2-1	0.0085	0.0128	0.0099	0.0133
Monero	16-8-4-2-1	0.0105	0.0163	0.0138	0.0145
Dash	16-8-4-2-1	0.0133	0.0154	0.0164	0.0150
Nem	8-4-2-1	0.0203	0.0350	0.0258	0.0297
Ethereum	8-4-2-1	0.0261	0.0370	0.0337	0.0333

Tablica 2: Prikaz korištenih arhitektura i pripadajućih pogrešaka za kriptovalute.

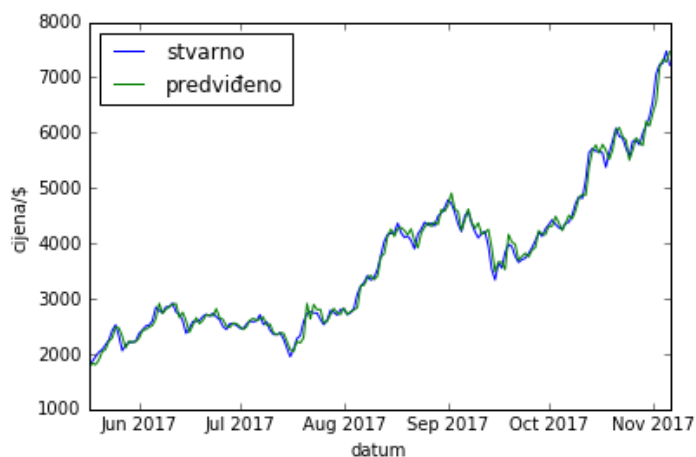
Arhitekturu sa slojevima redom od 16, 8, 4, 2 i 1 neurona za kriptovalute s više opservacija i manju s redom 8, 4, 2 i 1 neurona za one s manje opservacija. U Tablici 2 su prikazane arhitekture za svaku kriptovalutu, pogreške na trening i test setovima za obje metode redukcije dimenzionalnosti.

Iz tablice se može vidjeti da greška istreniranih modela nije velika i da greška na test setu ne odstupa puno od one na trening setu. To nam govori da nije došlo do pretreniranosti modela. Vidljivo je da karakteristike dobivene autoenkoderom daju bolje rezultate za kriptovalute s više opservacija i većim neuronskim mrežama, dok se PCA pokazala bolja na manjim modelima i kriptovalutama s manje opservablji. Razlog tome je što je autoenkoder kompleksniji model i bolje radi što je veći broj opservacija.

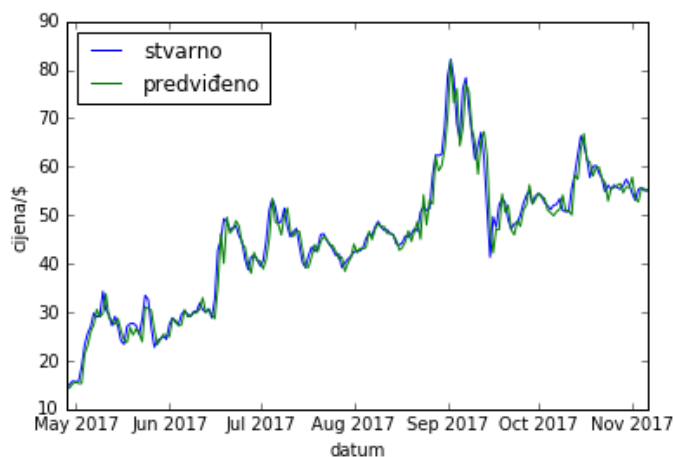


Slika 7: Graf usporedbe predviđenih i stvarnih vrijednosti rasta za bitcoin.

Iz Slike 7 se može vidjeti kako se odnosi predviđanje rasta modela sa stvarnom vrijednošću. Model u prosjeku dobro predviđa trend rasta odnosno pada. Ima vidljivog odstupanja od točne predikcije rasta, ali to je očekivano s obzirom na složenost sustava i teškoće predviđanja. Također nema situacija u kojima je model predvidio veliki rast, a u stvarnosti je bio veliki pad i obrnuto. To nam govori da je model stabilan u predviđanju. Slična je situacija i s drugim kriptovalutama.



Slika 8: Graf kretanja stvarne i predviđene cijene kroz vrijeme za bitcoin.



Slika 9: Graf kretanja stvarne i predviđene cijene kroz vrijeme za litecoin.

Na slikama 8 i 9 su prikazana kretanja cijene kroz vrijeme za bitcoin i litecoin, te su uspoređena s predviđanjem modela. Rezultati su prikazani za posljednjih šest mjeseci dostupnih u podacima u kojima je došlo do naglog rasta cijena svih kriptovaluta. Može se vidjeti da modeli u globalu dobro prate trend kretanja cijene. Linije predviđene i stvarne vrijednosti su u većini vremena preklopljene i nema većih odstupanja od stvarne cijene. Ovo nam pokazuje da modeli dobro predviđaju neočekivane situacije i uspijevaju prepoznati rane signale faznih prijelaza u cijenama kriptovaluta.

4 Zaključak

U ovom radu bavili smo se ranim signalima koji ukazuju na kretanje cijena kriptovaluta. Prošli smo kroz teorijski uvod u kojem smo opisali moguće oblike ponašanja sustava kad je u blizini faznog prijelaza i karakteristike koje mogu ukazivati na to. Nakon toga smo predstavili proces koji koristi metode strojnog učenja za predviđanje budućih vrijednosti vremenskih serija i primijenili smo ga na kretanje vremenskih serija kriptovaluta.

Proces se sastoji od 4 koraka: priprema podataka, izvlačenje karakteristika, redukcija dimenzionalnosti i treniranje modela i predviđanje. Podatke o kriptovalutama smo pripremili za daljnju obradu i iz njih izvukli karakteristike koje mogu ukazivati na fazni prijelaz. Nakon toga smo koristili metode redukcije dimenzionalnosti da bismo smanjili karakteristične vektore. Koristili smo PCA i autoenkoder. Autoenkoder se pokazao bolji za kriptovalute s više opservacija, dok je PCA bolja za one s manje. Dobivene karakteristike smo koristili za treniranje dubokih neuronskih mreža za predviđanje. Dobiveni modeli su naučeno na trening setu dobro prenosili na test set. Uspjevali su predvidjeti trend rasta cijena i nisu radili drastične pogreške.

Predloženi proces dobro prepoznaje rane signale koji upućuju na fazni prijelaz. Također nije pokazana cijela mogućnost neuronskih mreža jer smo bili ograničeni s ne jako velikim brojem opservacija. Na kraju zaključujemo da metode strojnog učenja omogućuju kvalitetno prepoznavanje ranih signala faznog prijelaza i imaju velike mogućnosti primjene u predviđanju budućih vrijednosti vremenskih serija u složenim sustavima.

Literatura

[1] Marten Scheffer, Jordi Bascompte, William A. Brock, Victor Brovkin, Stephen R. Carpenter, Vasilis Dakos, Hermann Held, Egbert H. van Nes, Max Rietkerk & George Sugihara: Early-warning signals for critical transitions, *Nature* 461, 53–59 (03 September 2009)

[2] Lenton, T. M. et al. Tipping elements in the Earth's climate system. *Proc. Natl Acad. Sci. USA* 105, 1786–1793 (2008).

[3] Kambhu, J., Weidman, S. & Krishnan, N. *New Directions for Understanding Systemic Risk: A Report on a Conference Cosponsored by the Federal Reserve Bank of New York and the National Academy of Sciences* (The National Academies Press, 2007).

[4] Litt, B. et al. Epileptic seizures may begin hours in advance of clinical onset: a report of five patients. *Neuron* 30, 51–64 (2001).

[5] Schroeder, M. *Fractals, Chaos, Power Laws: Minutes from an Infinite Paradise* (Freeman, 1991).

[6] Wissel, C. A universal law of the characteristic return time near thresholds. *Oecologia* 65, 101–107 (1984).

[7] Van Nes, E. H. & Scheffer, M. Slow recovery from perturbations as a generic indicator of a nearby catastrophic shift. *Am. Nat.* 169, 738–747 (2007).

[8] Ovaskainen, O. & Hanski, I. Transient dynamics in metapopulation response to perturbation. *Theor. Popul. Biol.* 61, 285–295 (2002).

[9] Ives, A. R. Measuring resilience in stochastic systems. *Ecol. Monogr.* 65, 217–233 (1995).

[10] Biggs, R., Carpenter, S. R. & Brock, W. A. Turning back from the brink: detecting an impending regime shift in time to avert it. *Proc. Natl Acad. Sci. USA* 106, 826–831 (2009).

[11] Guttal, V. & Jayaprakash, C. Changing skewness: an early warning signal of regime shifts in ecosystems. *Ecol. Lett.* 11, 450–460 (2008).

[12] Berglund, N. & Gentz, B. Metastability in simple climate models: pathwise analysis of slowly driven Langevin equations. *Stoch. Dyn.* 2, 327–356 (2002).

[13] B.D. Fulcher & N.S. Jones. hctsa: A computational framework for automated time-series phenotyping using massive feature extraction. *Cell Systems* 5, 527 (2017).

- [14] B.D. Fulcher, M.A. Little, N.S. Jones Highly comparative time-series analysis: the empirical structure of time series and their methods. *J. Roy. Soc. Interface* 10, 83 (2013).
- [15] Christ, M., Kempa-Liehr, A.W. & Feindt, M. (2016). Distributed and parallel time series feature extraction for industrial big data applications. ArXiv e-print 1610.07717
- [16] Juergen Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. *Neural Networks*. 61: 85–117 . arXiv 1404.7828
- [17] Xavier Glorot, Antoine Bordes and Yoshua Bengio (2011). Deep sparse rectifier neural networks
- [18] Jolliffe I.T. *Principal Component Analysis*, Series: Springer Series in Statistics, 2nd ed., Springer, NY, 2002, XXIX, 487 p. 28 illus. ISBN 978-0-387-95442-4