

Rani signali faznog prijelaza

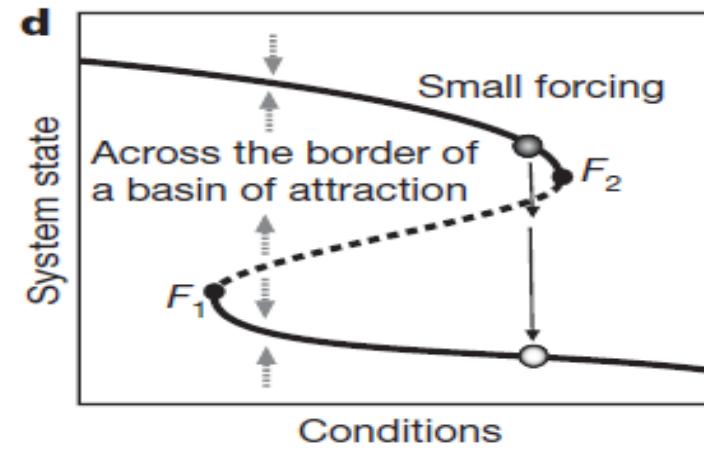
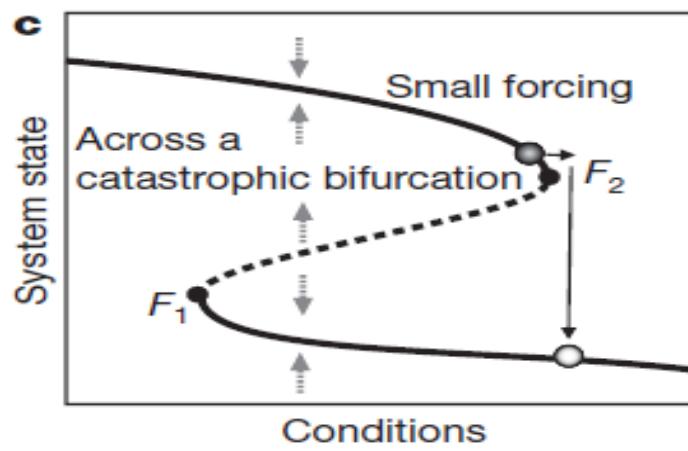
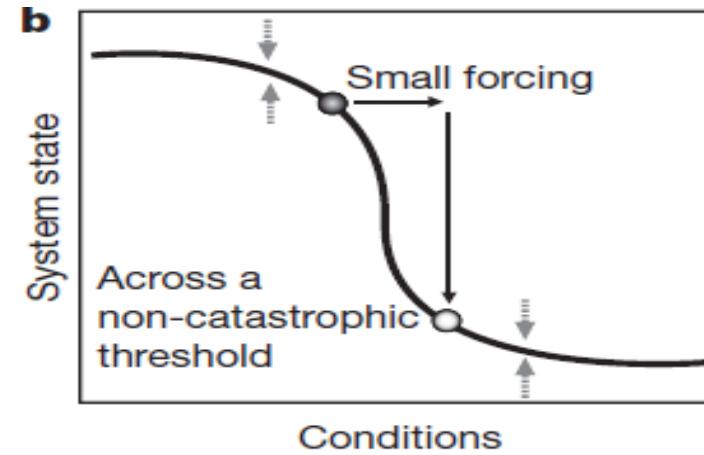
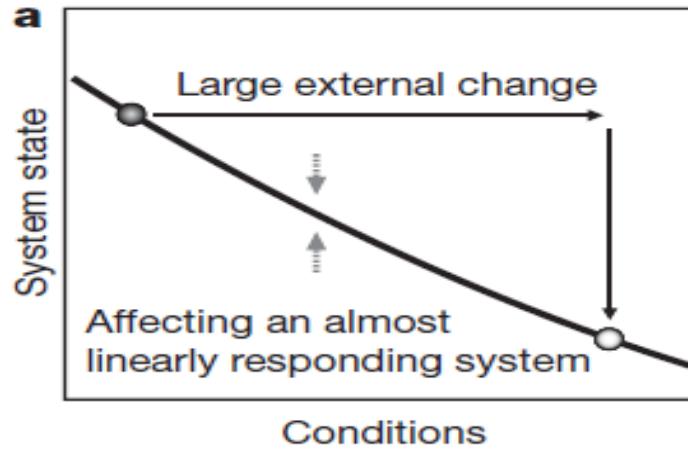
Petar Perković

Mentor: Davor Horvatić

UVOD

- ▶ Mnogi složeni sustavi imaju prijelomnu točku
- ▶ U njoj dolazi do naglog prijelaza iz jednog u drugo stanje
- ▶ Takvi prijelazi su teško predvidljivi
- ▶ Primjeri: epilepsija u medicini, krah burze u ekonomiji, nagle klimatske promjene u klimatologiji

Stanja sustava pri različitim uvjetima



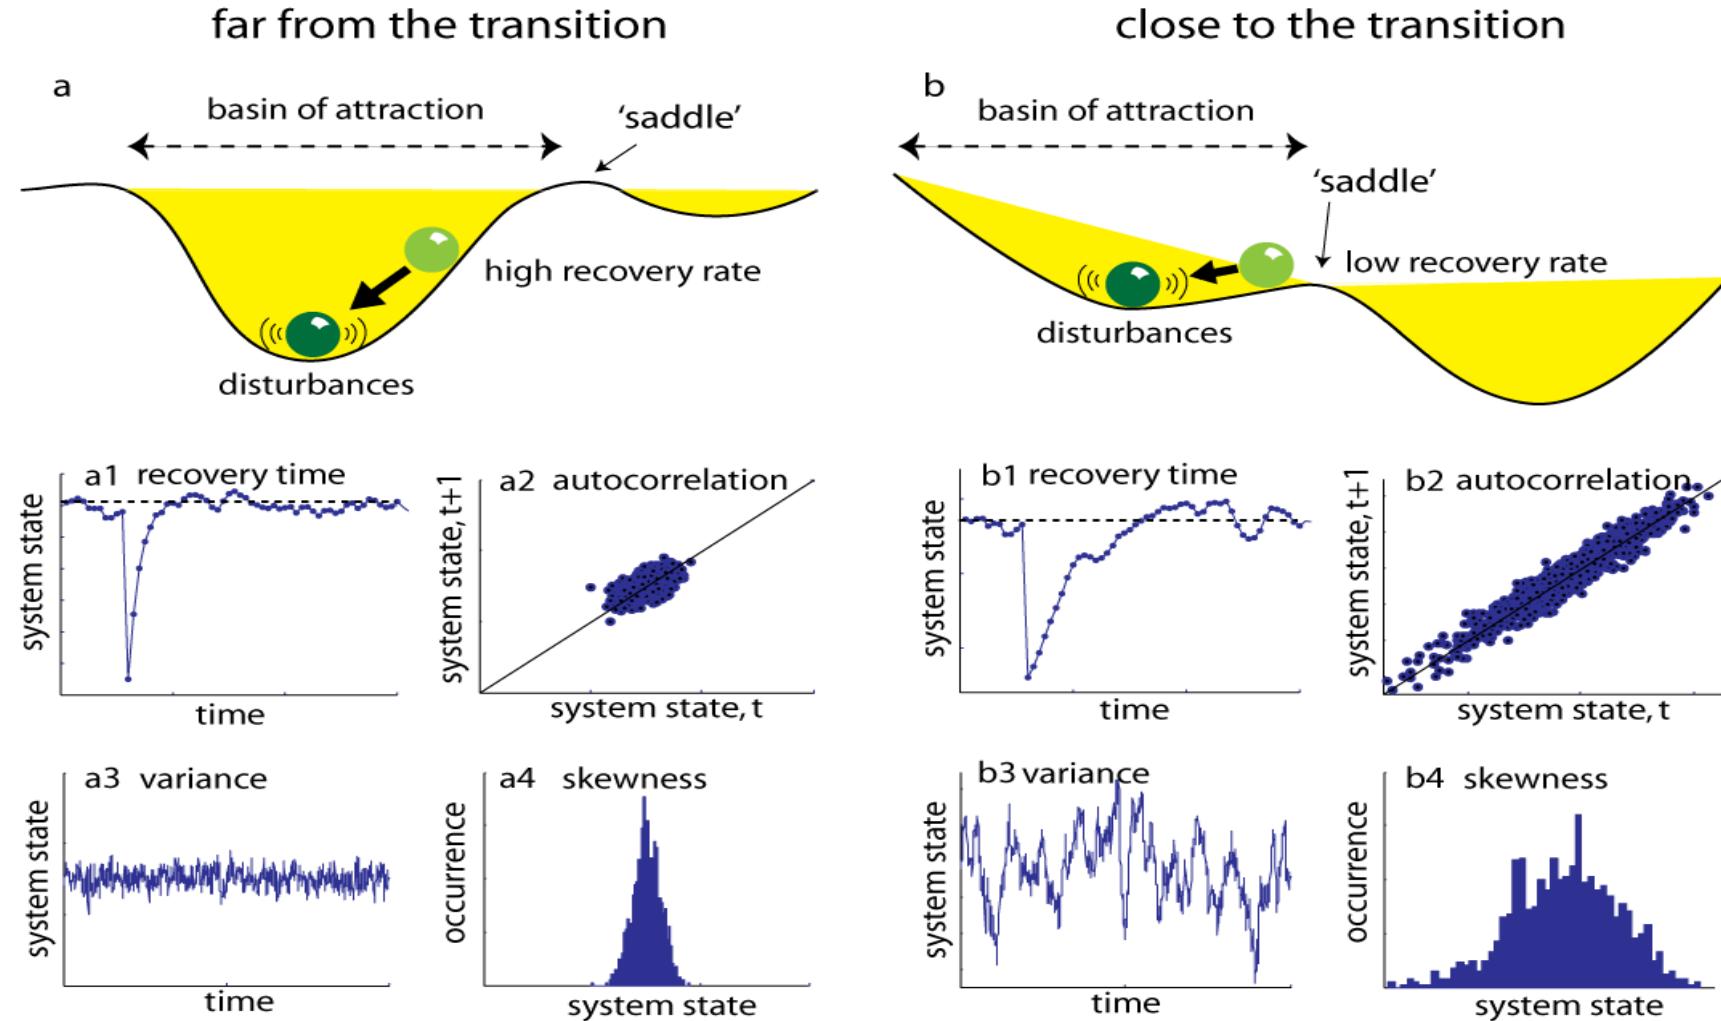
Kritično usporavanje

- ▶ Javlja se u nekim sustavima u blizini faznog prijelaza
- ▶ Sustav se prilikom malih perturbacija sporije vraća u osnovno stanje što je bliže točki prijelaza
- ▶ **Stopa povratka** - vrijeme povratka u osnovno stanje nakon perturbacije se smanjuje prilikom kritičnog usporavanja
- ▶ **Porast autokorelacijske funkcije** - trenutno stanje je sličnije prethodnom stanju
- ▶ **Porast varijance** - utjecaj akumuliranih šokova na sustav se povećava i varijanca raste

Dodatni rani signali

- ▶ **Asimetrija**- u blizini točke prijelaza sustav više vremena provodi u smjeru prijelaza nego na suprotnoj strani. To dovodi do asimetrične distribucije oko točke stabilnosti.
- ▶ **Treperenje** - događa se kad je stohastičko prisiljavanje dovoljno jako da pomiče sustav između dva područja privlačenja kad je sustav u bistabilnom području. Može se uočiti u porastu varijance i asimetrije.

Prikaz sustava u blizini i daleko od prijelaza



Metodologija

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

Priprema podataka

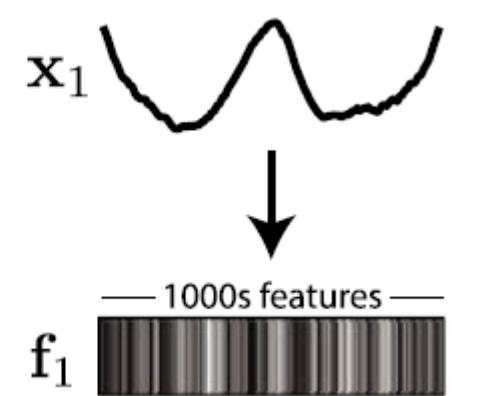
- ▶ Kriptovalute:bitcoin, ethereum, litecoin, monero, ripple, nem i dash.
- ▶ Imamo dnevne podatke o najvišoj i najnižoj cijeni, cijeni na početku i kraju dana, volumenu prometa i kapitalizaciji tržišta.
- ▶ Predviđan postotak rasta idući dan
- ▶ Koristimo podatke zadnjih 7 dana

Izvlačenje karakteristika

- ▶ Izvlačimo karakteristike koje mogu ukazivati na fazni prijelaz
- ▶ Izvučeno oko 200 karakteristika za svaku varijablu vremenskog niza
- ▶ Karakteristike: varijanca, autokorelacija za različiti lag, koeficijent asimetrije, srednja vrijednosti ...

i. Time series

ii. Extensive feature vector



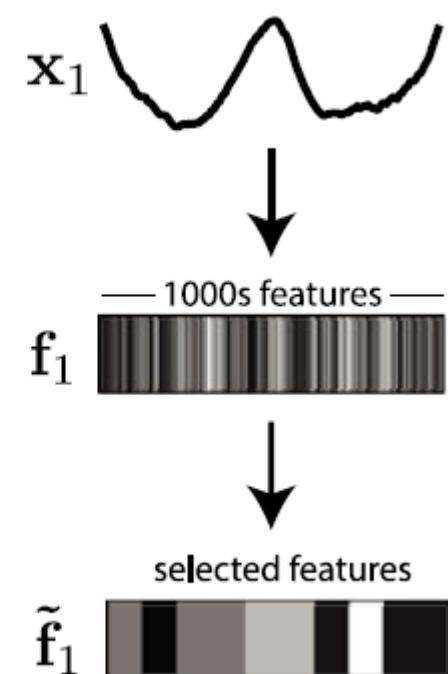
Redukcija dimenzionalnosti

- ▶ Smanjujemo dimenziju ulaznog vektora
- ▶ Izvlačimo najbitnije karakteristike
- ▶ Sprječava prenaučenost modela prilikom treniranja
- ▶ Metode: PCA i autoenkoder

i. Time series

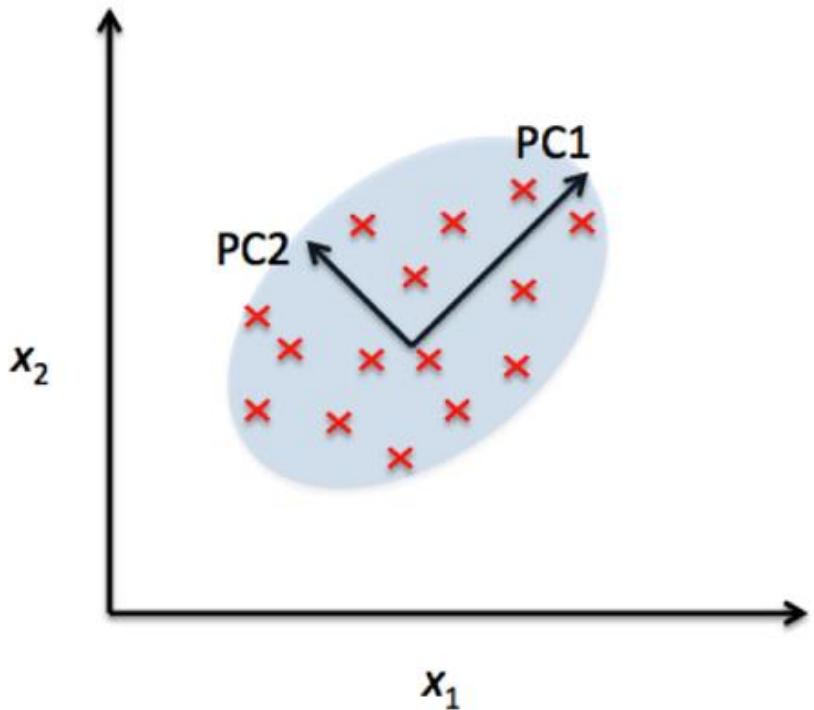
ii. Extensive feature vector

iii. Reduced feature vector for classification



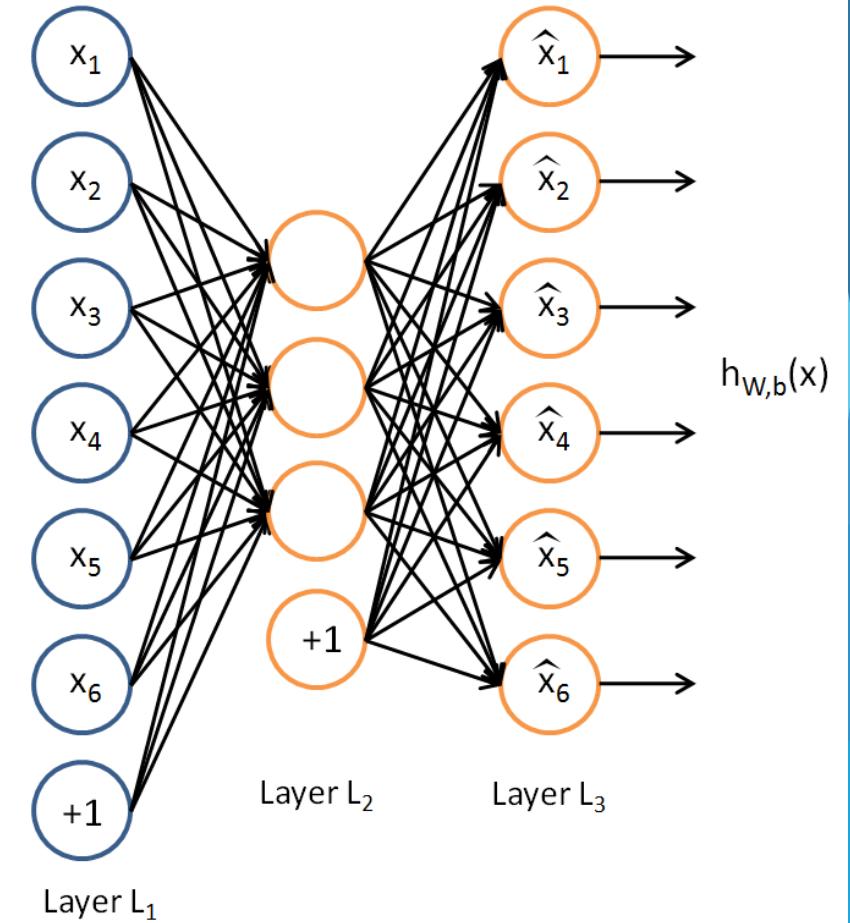
PCA

- ▶ Analiza svojstvenih komponenti
- ▶ Ortogonalno transformira skup vektora u skup nekoreliranih vektora
- ▶ Nove komponente su poredane po varijanci



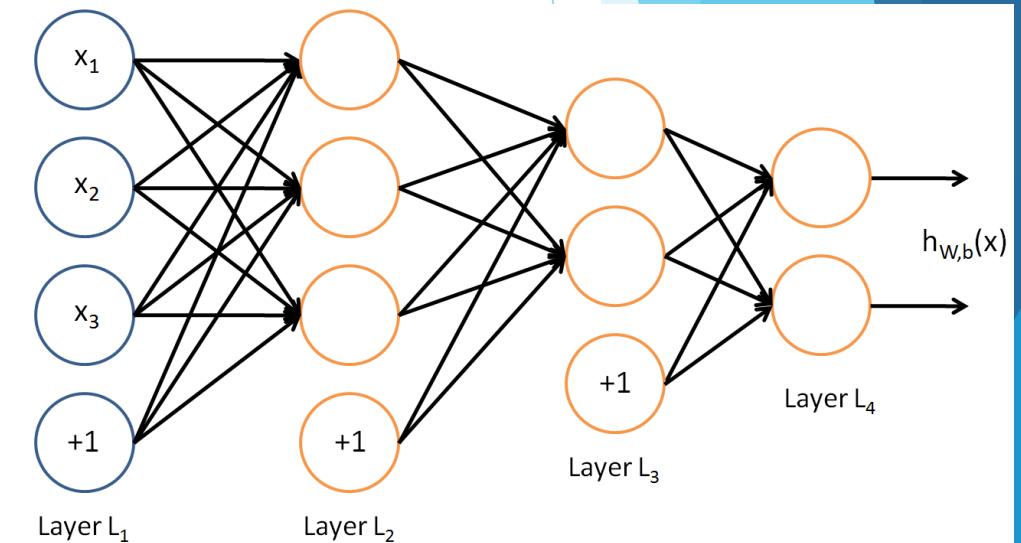
Autoenkoder

- ▶ Tip neuronske mreže
- ▶ Sastoji se od dijela za šifriranje i dešifriranje
- ▶ Vrijednost srednjeg sloja se uzima kao nova karakteristika



Treniranje modela i predviđanje

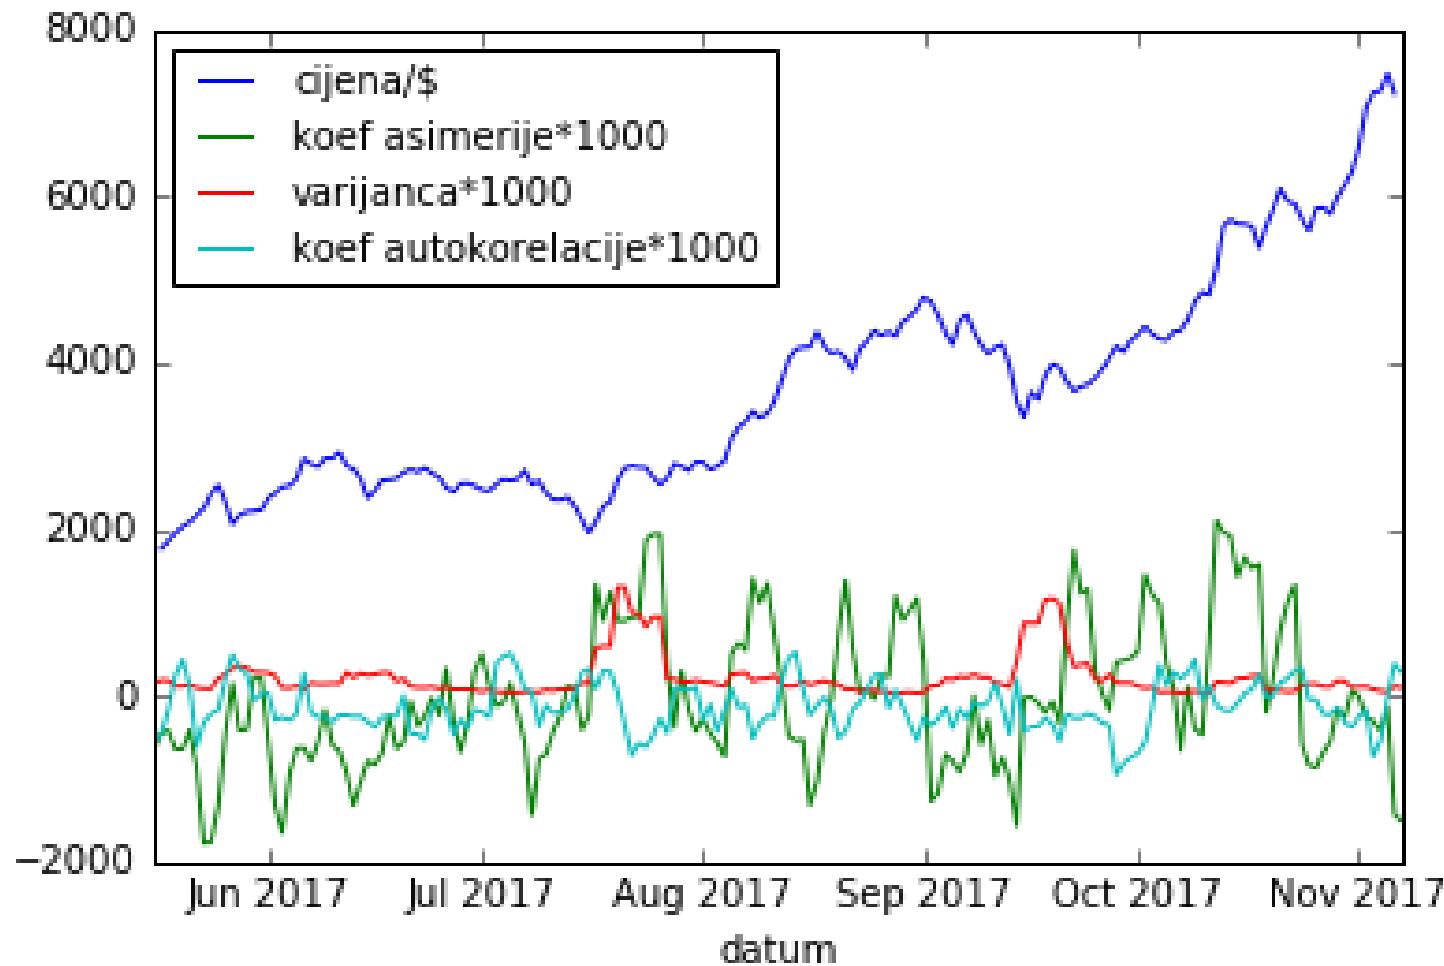
- ▶ Pomoću dobivenih karakteristika prethodnim metodama treniramo model za predviđanje budućih vrijednosti
- ▶ Korištene duboke neuronske mreže
- ▶ Prvih 70% podataka korišteno za treniranje, 10% za unakrsnu validaciju i 10% za testiranje



Rezultati

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

Usporedba kretanja cijene s ranim signalima



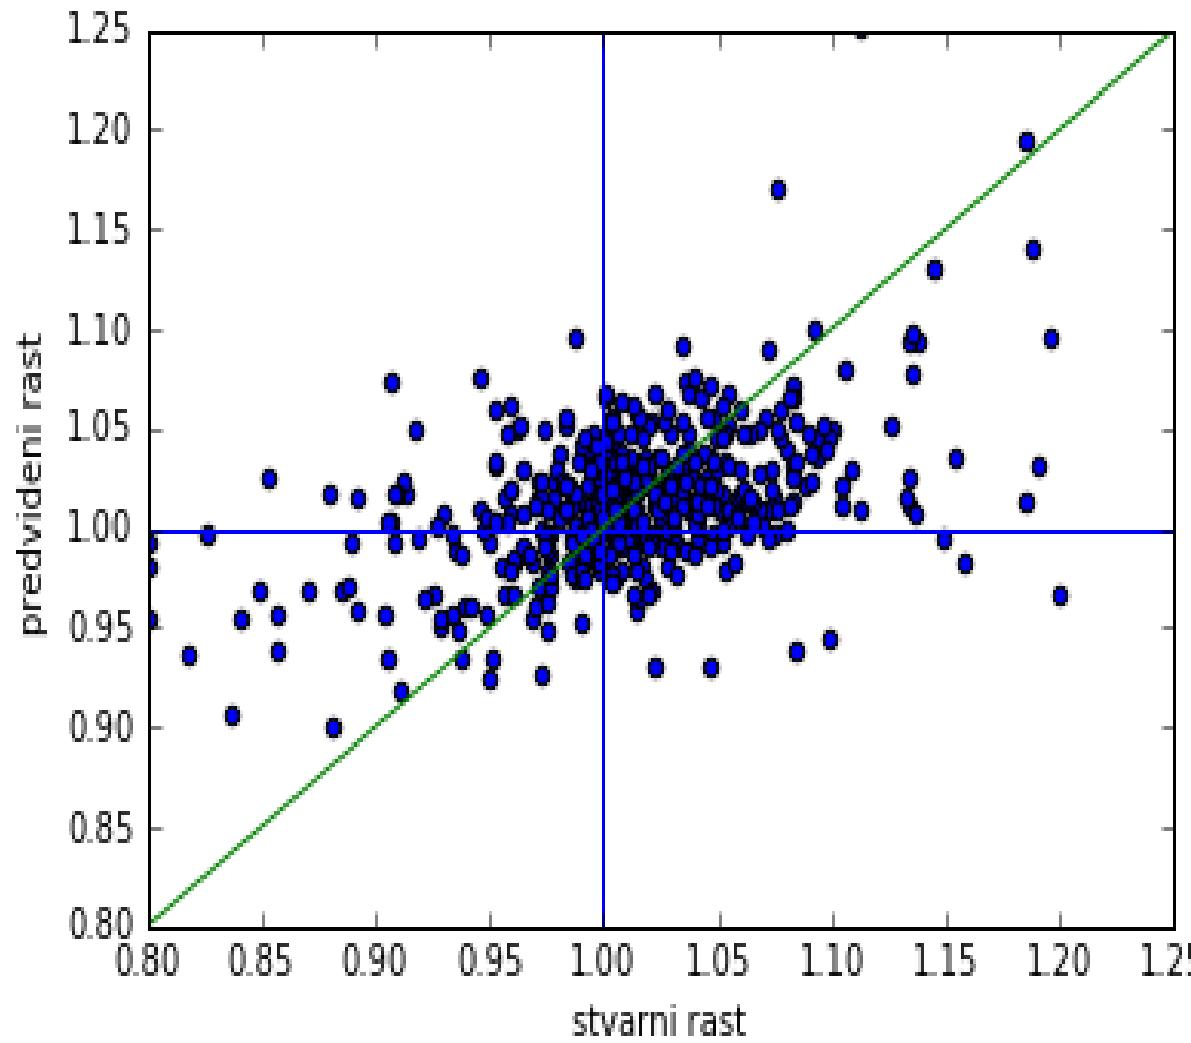
Treniranje modela

- ▶ Pomoću PCA i autoenkodera dobiveni su vektori karakteristika veličine 30 za svaku kriptovalutu
- ▶ Podijeljeni su na trening, unakrsno-validacijski i test set
- ▶ Za kriptovalute s više od 1000 opservacija je korištena veća mreža(16-8-4-2-1), dok je za one s manje opservacija korištena (8-4-2-1)

Modeli i pripadajuće pogreške

| 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 |

Usporedba stvarnih i predviđenih vrijednosti postotka rasta



Usporedba predviđenih i stvarnih cijena



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



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

Zaključak

- ▶ Izračunati rani signali nam omogućuju predviđanje budućih vrijednosti
- ▶ Autoenkoder se pokazao bolji za kriptovalute s puno opservacija, dok je PCA bolji za one s manje opservacija
- ▶ Modeli uspijevaju dobro predvidjeti trend rasta odnosno pada kriptovaluta
- ▶ Izračunati rani signali nam omogućuju predviđanje budućih vrijednosti
- ▶ Tehnike strojnog učenja imaju široku primjenu u predviđanju faznih prijelaza

Hvala na pažnji!