Projektiranje RBF neuronske mreže za upravljanje višestrukim modelom procesa

Šojo, Robert

Master's thesis / Diplomski rad

2014

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:075109

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ELEKTROTEHNIČKI FAKULTET

Sveučilišni studij

Projektiranje RBF neuronske mreže za upravljanje višestrukim modelom procesa

Diplomski rad

Robert Šojo

Osijek, 2014

SADRŽAJ

1. UVOD 1
2. IZGRADNJA MODELA PROCESA NA TEMELJU POGONSKIH PODATAKA 3
   2.1 Odabir optimalne dimenzije modela 6
   2.2 Preslikavanje ulaza u latentni prostor 8
   2.3. Metode temeljene na nelinearnoj projekciji ulaza 12
      2.3.1. Lokalne metode preslikavanja ulaza 14
   2.4. Umjetne neuronske mreže 15
      2.4.1. Osnovna svojstva umjetnih neuronskih mreža 15
      2.4.2. Vrste neuronskih mreža 16
      2.4.3. RBF umjetne neuronske mreže 17
3. KLASTERIRANJE PODATAKA 20
   3.1. K-srednjih vrijednosti algoritam klasteriranja podataka 22
   3.2. Fuzzy C-Means algoritam klasteriranja podataka 23
   3.3. Hijerarhijski algoritam klasteriranja podataka 25
   3.4. Algoritam klasteriranja podataka pomoću Gaussovog miješanog modela 26
   3.5. Vrednovanje klasteriranja 28
      3.5.1. Calinski-Harabasz kriterij 30
      3.5.2. Davies-Bouldin kriterij 31
      3.5.3. Vrijednost Silhouette 31
4. POSTIGNUTI REZULTATI GRUPIRANJA PODATAKA 33
   4.1. Prikupljanje mjernih podataka i formiranje skupova za učenje i testiranje 33
   4.2. Klasteriranje raspoloživih pogonskih podataka 36
      4.2.1. Izvedba k-srednjih vrijednosti algoritma za klasteriranje 36
      4.2.2. Izvedba Fuzzy c-srednjih vrijednosti algoritma za klasteriranje 37
      4.2.3. Izvedba hijerarhijskog algoritma za klasteriranje 37
      4.2.4. Izvedba Gaussovog miješanog modela algoritma za klasteriranje 39
      4.2.5. Kriteriji vrednovanja rezultata primijenjenih algoritama za klasteriranje 41
   4.3. Rezultati klasteriranja 43
      4.3.1. Rezultati vrednovanja klasteriranja 12-dimenzionalnih podataka algoritmom k-srednjih vrijednosti 43
      4.3.2. Rezultati vrednovanja i klasteriranja 12-dimenzionalnih podataka algoritmom Fuzzy c-srednjih vrijednosti. 46
      4.3.3. Rezultati vrednovanja i klasteriranja 12-dimenzionalnih podataka hijerarhijskim algoritmom klasteriranja. 48
      4.3.4. Rezultati vrednovanja i klasteriranja 12-dimenzionalnih podataka algoritmom Gaussovi miješani modeli. 51

4.3.5. Rezultati vrednovanja klasteriranja 25-dimenzionalnih podataka algoritmom k-srednjih vrijednosti 53

4.3.6. Rezultati vrednovanja i klasteriranja 25-dimenzionalnih podataka algoritmom Fuzzy c-srednjih vrijednosti. 55

4.3.7. Rezultati vrednovanja i klasteriranja 25-dimenzionalnih podataka hijerarhijskim algoritmom klasteriranja. 57

4.3.8. Rezultati vrednovanja i klasteriranja 25-dimenzionalnih podataka algoritmom Gaussovi miješani modeli. 60

4.4. Upravljanje izlazima linearnih modela 62

5. ZAKLJUČAK 65

LITERATURA 67

SAŽETAK 68

ŽIVOTOPIS 70

PRILOZI 71

SAŽETAK

Kako bi se estimirala teško-mjerljiva procesna veličina potrebno je raspolagati modelom procesa. Procesi su po svojoj prirodi nelinearni, a izgradnja nelinearnog modela i njihova implementacija je bitno složenija u odnosu na linearne modele. S obzirom na pretpostavku da se nelinearni proces u određenom dijelu radnog područja može dovoljno dobro opisati s linearnim modelom, cijelo radno područje procesa se rastavlja na nekoliko manjih dijelova, kako bi se vladanje procesa opisalo s više linearnih modela. Za tu svrhu koriste se metode klasteriranja podataka, kojima se od ulaznog skupa mjernih podataka, prikupljenih kroz duže vremensko razdoblje stvaraju manje grupe podataka, koje se zovu klasteri. Svrha grupiranja podataka leži u tome da se dobiju klasteri koji sadrže međusobno slične podatke, koji su međusobno različiti nasuprot podataka koji su smješteni u druge klastere.

U slučaju nailaska novog mjernog uzorka za koji se treba odrediti izlaz modela procesa potrebno je omogućiti aktivaciju odgovarajućeg modela iz ovog skupa linearnih modela, čime je ovaj višestruki model upravljan. U ovom radu upravljanje višestrukim modelom procesa obavlja se RBF neuronskom mrežom čiji se broj neurona i receptivna polja pojedinog neurona određuju predstavljenim metodama klasteriranja. Ako testni podaci pripadnu samo jednom linearnom modelu, izlaz RBF neuronske mreže predstavlja izlaz tog linearnog modela. U slučaju da testni podaci pripadaju u više linearnih modela, tada bi se koristilo meko određivanje težina za svaki linearni model, a iznos težine ovisi o raspodjeli testnih podataka unutar klastera. Ovako svi linearni modeli imaju doprinos u estimaciji teško-mjerljive veličine. Ovi modeli opisuju vladanje procesa u pojedinom dijelu radnog područja.

Ključne riječi: Modeliranje procesa, neuronske mreže, klasteriranje podataka, višestruki linearni model procesa

ABSTRACT

In order to estimate hard-measured process, it is necessary to have a model of the process. The processes are by their nature non-linear and building non-linear models and their implementation is rather more complicated compared to linear models. Given the assumption that the nonlinear process in a certain part of the work area can be sufficiently well described by a linear model, the entire operating range of the process breaks down into several smaller parts in order to describe the process with multiple linear models. For this purpose data clustering method are used for creating smaller groups of data which are called clusters. Each cluster contains similar data, which are different from other data that are located in other clusters.

If a new measurement sample arrives, for which is needed to determine the output of the process, it is necessary to allow the activation of appropriate model from this set of linear models. In this paper, the management of multiple process model is done by RBF neural network whose number of neurons and receptive fields of each neuron is determined by presented clustering methods. If the test data belongs to a single linear model, the output of RBF neural network represents the output of that linear model. In case that the test data belongs to the several linear models, then the soft determination of weights is used for each linear model and the amount of weight depends on the distribution of test data within a cluster. In that case all linear models have a contribution to the estimation of hard-measured value. These models describe the behavior of the process in a particular part of the work area.

Keywords: Process model, neural network, data clustering, multiple linear process model