

MODELIRANJE PROCESA VIŠESTRUKOM PRETVORBOM ANALITIČKIH IZNOSA PROCESNIH VARIJABLI U KVALITATIVNI OBLIK

Franjo Jović, emeritus HATZ, FERIT Sveučilište J.J. Strossmayera u Osijeku Osijek, fjovic90@gmail.com

Sažetak: Prikazan je algoritam za izradu nelinearnog analitičkog modela procesa. Konvergenciju modela osigurava postupak skaliranja procesnih varijabli, konačni broj ponavljanja uz ispitivanje konvergencije u kvantitativnom obliku. Konačni model dobiva se pretvorbom varijabli iz kvalitativnog u kvantitativni oblik.

1. Uvod

Složeni prirodni, energetski, industrijski i prometni procesi, te tokovi kapitala, nastoje se postupcima vođenja i nadgledanja dovesti u stanje da se njihova manifestacija, proizvod ili usluga dovedu na što viši stupanj kvalitete sa što manje rasipanja kvalitete. Stoga se modeliranjem pristupa rješavanju vođenja takvih procesa kako bi se procijenilo, odnosno predvidjelo njihovo ponašanje i eventualno moglo na ispravan način djelovati na određene procesne veličine u cilju popravka.

2. Opis patenta, patentne prijave ili inovacije

Prediktorski model zasniva se na ekspanziji barem jedne varijable procesa u skup varijabli. Taj se skup varijabli pretvara u kvalitativni oblik. Ciljna funkcija je budući iznos procesne veličine ili modelski opis analitičke analogije procesa i on se također pretvara u kvalitativni oblik.

Uzimanjem u obzir kvalitativnog modela procesa kao osnove za predikciju omogućuje optimum iz većeg izbora rješenja algebarskih oblika nelinearnog tipa. Optimum na osnovici minimuma kvadrata odstupanja modelske od ciljne funkcije osigurava nepristranu ocjenu pri izboru rješenja.

Postupak modeliranja kružnom pretvorbom kvantitativnog u kvalitativni vid procesne informacije opisan u patentnoj prijavi broj HP-P950207A rezultirao je nizom radova i primjena, u kojima međutim nije suviše detaljno objašnjena sama priroda modeliranja.

Stoga se može općenito navesti da se kružni postupak modeliranja procesa sastoji od tri odvojena koraka koji se mogu ponavljati povoljan broj puta, sve dok se više ne dobiva poboljšanje modela.

U prvom koraku uspoređuju se kvalitativna svojstva modelske i ciljne funkcije i izabire najpovoljnija modelska funkcija M1 iz skupa kombinacija procesnih varijabli. U drugom koraku se istražuju najpogodnije komplementarne funkcije M2, koje mogu dopuniti razliku između ciljne i modelske funkcije, ukoliko ona postoji. U trećem se koraku algebarskom operacijom tipa

$$M = M1 +/- kM2$$

izabire optimalni iznos konstante k koja daje minimum razlike modela M i ciljne funkcije G.

Postupak modeliranja daje eksplicitni kvalitativni nelinearni model koji se može jednostavno pretvoriti u kvantitativni model, tako da se računaju ekvivalentni iznosi korespondentnim rangovima, te se mogu tako izraziti kao konačna pogreška modela prema ciljnoj funkciji. U idealnom slučaju pogreška je jednaka stupnju kvantizacije, tj ovisi o broju perioda promatranja.

Namjena je ovog patenta da za sve slučajeve, a ne samo za linearne, predloži rješenje optimalnog procesa modeliranja i predikcije danog procesa.

1. Sažeti opis izuma

Izum se sastoji od niza postupaka kojima se automatskim načinom ili uz malu intervenciju operatora dobiva nelinearni nestacionarni eksplicitni prediktivni model složenih prirodnih, energetskih, industrijskih i prometnih procesa prema sljedećem postupku:

1. priprema podataka, ekspanzijom procesne(ih) varijabli, tako da se uzmu pomaćne i diferencijalne iznose,
2. kao funkcija cilja određuje se prediktivna procesna varijabla odnosno model pripremljen prema odgovarajućim analitičkim analogijama
3. algoritam obrade, tako da se ekspanzirane varijable pomaknu u pozitivni dio realne osi, odrede optimalni prediktivni modeli s obzirom na funkciju cilja sve izvedeno u tri koraka koji se mogu ciklički obavljati
4. prikaz rezultata s izborom optimalnog rješenja po kriteriju maksimalne sličnosti.

3. Zaključak

Prikazan je postupak predikcije ponašanja napona ferorezonantnog kruga.

Podaci napona ferorezonantnog kruga u kaotičnom stanju dati su po autoru I. Flegaru. Podaci napona ferorezonantnog kruga u kaotičnom stanju su upotrebljeni u prediktivnom algoritmu te su postignuti rezultati predikcije rangova dati na slici 5. Alternativno su na slici 9. prikazani i rezultati predikcije upotrebom linearnog autoregresijskog modela (Graupe, Astrom-Wittenmark). Varijable nelinearnog predikcijskog modela ponašanja ferorezonancijskog kruga dane su na slici 7. Modelska i ciljna funkcija predikcije ponašanja napona ferorezonancijskog kruga date su na slici 8. Relativne pogreške modelske predikcije ponašanja napona dane su slikom 8.