

Fina detekcija degradirane kakovosti v proizvodnji elektromotorjev

Luka Žnidarič, Jernej Mlinarič in Đani Juričić

Institut Jožef Stefan, Jamova c. 39, 1000 Ljubljana, Slovenija

luka.znidaric@ijs.si, jernej.mlinaric@ijs.si, dani.juricic@ijs.si

Detecting fine quality degradations in electromotor manufacturing

Quality control methods on most manufacturing lines are still largely based on the qualitative experiences of the producer. A purely data-driven fault detection framework would provide additional benefits to the manufacturer in form of quantitative decision support. We developed such framework based on Cumulative Mixture Fit (CMF) algorithm which is able to capture the statistical nature of the manufacturing process. Information extracted in the nominal operational mode can be subsequently compared to the one extracted in an undetermined operational mode via the so-called Wasserstein distance. This metric is proportional to the statistical dissimilarity between the nominal and the unknown operational mode, thus providing an excellent measure of similarity between the processes. This enables a probability-based decision whether the unknown process is in fact a nominal one or not. The framework was tested on real-life data from quality control sensor readings provided by Domel. The method is numerically non-demanding and can be applied to any production line, only requiring input for the desired false-alarm rate.

Kratek pregled prispevka

Metode za kontrolo kvalitete pri večini proizvajalcev izdelkov še vedno temeljijo na izkušnjah proizvajalca, poznavanju mehanske strukture izdelka in zahtevah naročnika. Algoritem za detekcijo napak, ki bi deloval popolnoma na podlagi podatkov, bi prinesel dodatne koristi v obliki kvantitativne podpore pri odločanju. V ta namen smo razvili mehanizem, ki temelji na Cumulative Mixture Fit (CMF) algoritmu in je zmožen zajeti statistično naravo proizvodnega procesa. Informacije v obliki verjetnostih porazdelitev, ki jih pridobimo iz procesa v nominalnem načinu delovanja, lahko naknadno primerjamo z informacijami o trenutnem delovanju z uporabo metrike, v tem primeru Wassersteinove razdalje. Omenjena metrika je sorazmerna s statistično razliko med nominalnim in trenutnim načinom delovanja in je odlično orodje za detekcijo napak. Razviti mehanizem omogoča statistično podprte odločitve o podobnosti med trenutnim in nominalnim delovanjem proizvodnje. Metoda je bila testirana na podatkih izmerjenih med proizvodnjo elektromotorjev v podjetju Domel. Odlikuje jo tudi nizka numerična zahtevnost in možnost uporabe v vsaki proizvodnji, ki je opremljena s senzorji za kontrolo kakovosti.

1 Uvod

Proizvodne linije so tradicionalno temeljile na strokovnjakih, ki so z ročnim nastavljanjem pragov napak identificirali težave s kontrolo kakovosti. Vendar pa je ta pristop lahko subjektiven in nagnjen k napakam, saj lahko imajo različni strokovnjaki različna mnenja o tem, kaj predstavlja okvarjen izdelek. Težava se pojavi tudi v zaznavanju subtilnih sprememb v proizvodnem procesu, ki lahko sčasoma vodijo do poslabšanja kakovosti.

Kot rešitev omenjenih napak je predlagana podatkovna metoda za odkrivanje napak, ki temelji na algoritmu Cumulative Mixture Fit (CMF). Algoritem CMF je sposoben zajeti statistično naravo proizvodnega procesa, informacije, pridobljene v nominalnem načinu delovanja, pa se lahko nato primerjajo z informacijami, pridobljenimi v nedoločenem načinu delovanja prek Wassersteinove razdalje. Ta metrika zagotavlja objektivno in količinsko merjenje podobnosti med procesi, omogoča pa verjetnostno odločanje o tem, ali je neznan proces dejansko nominalen ali ne.

V primerjavi s tradicionalnim pristopom ročnega nastavljanja pragov napak ima predlagani okvir več prednosti. Temelji na količinskem analiziranju podatkov senzorjev, namesto na subjektivnem človeškem presojanju. Sposoben je zaznati nežne spremembe v proizvodnem procesu, ki niso očitne. Nazadnje pa je metoda številčno nezahtevna in se lahko uporablja na kateri koli proizvodni liniji, pri čemer zahteva le vnos zelene stopnje lažnega alarma. Na splošno ima predlagani okvir potencial za pomembno izboljšanje natančnosti in učinkovitosti kontrole kakovosti v proizvodnih linijah.

2 Metodologija

Metodo lahko razdelimo na dva dela. Prvi korak je uporaba CMF algoritma za pridobitev ujemajoče mešanice Lognormal porazdelitev za nominalne vrednosti senzorjev kakovosti. Ob novih meritvah pa po podatkih premikamo tekoče okno stalne velikosti in za njega ponovno z uporabo algoritma CMF pridobimo porazdelitev za podatke v trenutnem oknu.

Drugi korak vsebuje uporabo Wassersteinove razdalje [1], s katero ocenimo razliko med nominalno in trenutno porazdelitvijo. Na podlagi teh razlik določimo učno množico nominalnih razlik in na njej ponovno pridobimo ujemajočo nominalno mešanico Lognormal porazdelitev razlik, iz katere lahko s parametrom α (stopnja lažnega alarma) [2] pridobimo mejo za napako.

2.1 CMF algoritem

Algoritem kumulativne mešanice (ang. Cumulative Mixture Fit, CMF) se uporablja za pridobitev mešane porazdelitve \mathcal{M} , ki najboljše ustreza podatkom. Algoritem poteka v več korakih in uporablja podatke predstavljene v obliki kumulativnih histogramov. Prvi korak je določanje začetnih parametrov mešane porazdelitve na podlagi opazovanj in predhodnega znanja. Za poseben problem, ki ga rešujemo, smo izbrali mešano porazdelitev, ki je sestavljena iz treh lognormalnih porazdelitev, saj najboljše ustreza fizikalnim lastnostim meritev. Drugi korak je računanje funkcije prileganja. Funkcija prileganja primerja kumulativni histogram in kumulativno funkcijo gostote tako, da se sešteje absolutna razlika med višino bin-a histograma h_i in ustrezno vrednostjo kumulativne funkcije gostote:

$$\sum_{i=1}^n |\mathcal{M}_{CDF}(i) - h_i|. \quad (1)$$

V zadnjem koraku se parametri mešane porazdelitve posodobijo in optimizirajo z uporabo algoritma ADAM [3], glede na vrednosti funkcije prileganja. Nato se drugi in tretji korak ponavljata, dokler se ne doseže zeleno število ponovitev ali željen fit. Izhod algoritma CMF so parametri mešane porazdelitve \mathcal{M} , ki najboljše ustreza podatkom.

2.2 Wassersteinova razdalja

Koncept Wassersteinove razdalje se lahko razloži s preprostim primerom. Recimo, da imamo dva kupčka peska različnih oblik in velikosti. Očiten način za primerjavo teh kupčkov bi bil merjenje mase vsakega kupčka. Lahko pa se zgodi, da imata kupčka različne oblike in velikosti, a enako

maso.

Wassersteinova razdalja upošteva stroške premikanja peska iz enega kupčka v drugega, če bi ju želeli narediti čimbolj podobna. Na primer, če je eden od kupčkov višji, vendar tanjši od drugega, lahko premikanje peska z vrha višjega kupčka na strani pripomore k bolj podobni obliki. Stroški premikanja peska se nato uporabijo za izračun Wassersteinove razdalje med obema kupčkoma, kar zagotavlja natančno merilo njune podobnosti.

V primeru naše metode so ti kupčki porazdelitve in se lahko za diskretne porazdelitve zapišejo s sledečo enačbo. Naj bosta X in Y dve diskretni naključni spremenljivki s porazdelitvenimi funkcijami $P_X(x)$ in $P_Y(y)$. Wassersteinova razdalja med X in Y je definirana kot:

$$W_p(X, Y) = \inf_{\gamma \in \Gamma(X, Y)} (\mathbf{E}_{(x, y) \sim \gamma} d(x, y)), \quad (2)$$

kjer je $\Gamma(X, Y)$ množica vseh parov iz X in Y in $d(x, y)$ evklidska razdalja med x in y .

3 Rezultati

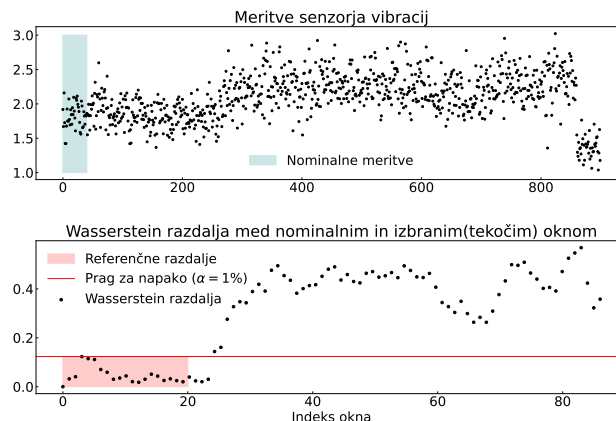
Za testiranje naše metode smo uporabili meritve na senzorjih za kontrolo kakovosti motorjev iz podjetja Domel.

V časovni vrsti meritev senzorja na sliki 1 lahko vidimo očiten skok v izmerjenih vibracijah, ki se je sicer zgodil zaradi ponastavljanja opreme, ampak ga bomo uporabili kot napako, ki jo poskušamo zaznati z našo metodo.

Prag napake je izračunan neposredno iz parametra α (stopnja lažnega alarma), ki je bil v tem primeru nastavljen na 1%. Vidimo, da smo spremembe v vibracijah motorjev uspešno zaznali, pri tem pa smo za polno implementacijo potrebovali le podatke v nominalnem delovanju ter želeni procent lažnih alarmov.

4 Zaključek

V razširjenem povzetku smo predstavili metodo za detekcijo napake v kakovosti končnih produktov, ki temelji na podatkih. Metoda za implemen-



Slika 1: Eden izmed signalov kakovosti motorjev, z označenim nominalnim oknom (zgoraj). Wassersteinove razdalje med izbranimi okni in nominalnim oknom z označenim pragom za napako (spodaj).

tacijo potrebuje le meritve senzorjev pri nominalni proizvodnji ter želeni odstotek lažnih alarmov. Z Wassersteinovo razdaljo med porazdelitvami lahko zaznamo tudi bolj subtilne spremembe v porazdelitvah meritev, ki jih lahko spregledamo, če se odločamo zgolj na podlagi točkovnih vrednosti meritev senzorjev. Postavitev praga za detekcijo napake je izvedena direktno iz nominalnih porazdelitev meritev in ne zahteva obilice izkušenj z proizvodno linijo.

5 Zahvala

Delo je bilo podprto s strani Javne agencije za raziskovalno dejavnost Slovenije skozi Projekt P2-0001.

Literatura

- [1] C. Villani. *The Wasserstein distances*. 2009, 93-111 str.
- [2] B. Everitt. *The Cambridge dictionary of statistics*. Cambridge University Press, Cambridge, UK; New York, 2002.
- [3] D. P. Kingma in J. Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.