

Optimizacija receptov hladnega valjanja na podlagi analize zgodovinskih podatkov

Kristjan Cuznar

Univerza v Ljubljani, Fakulteta za elektrotehniko

Odsek za sisteme in vodenje, Institut "Jožef Stefan"

E-pošta: kc8861@student.uni-lj.si

Optimization of cold rolling process recipes based on historical data

Cold rolling is one of the most important processes in sheet metal production and is used for reducing thickness, making thickness uniform and ensuring appropriate mechanical properties of the workpiece. In order to ensure appropriate quality of the product, it is extremely important to adjust rolling mill properly. This is usually set by using the recipes that define rolling settings for wider range of similar material types.

We propose a decision support tool that enables recipe adaptation for individual workpieces. The tool is based on the analysis of historical process data and their impact on the associated key performance indicators (KPIs). Support tool includes data-based process model of cold rolling mill and multi-objective optimization algorithm.

1 Uvod

Podjetja so na vedno bolj zahtevnem trgu primorana poiskati nove načine za povečanje svoje konkurenčnosti. Kakovost proizvodov in produktivnost procesa sta pomembna dejavnika uspešnosti podjetja, katerima se zaradi naraščajočega konkurenčnega pritiska posveča vedno več pozornosti. Ker so specializirani procesi prilagojeni željam končnih kupcev, je kljub znanju ekspertov na dotednih področjih potrebno optimizirati nastavitev proizvodnega procesa ter jih sproti prilagajati aktualnim razmeram.

Ena izmed rešitev se ponuja v digitalizaciji proizvodnih procesov, kjer z dodajanjem kompleksnih senzorskih sistemov dosežemo podrobnejši vpogled v proizvodno dogajanje. Na podlagi zgodovinskih podatkov, ki razkrivajo trenutno stanje procesa, je z uporabo statističnih analiz in metod strojnega učenja [1] (ang. *machine learning*) možno identificirati matematične modele, ki jih lahko uporabimo za spremljanje opreme [2] (ang. *equipment monitoring*), prediktivno vzdrževanje [3] (ang. *predictive maintenance*), idr.

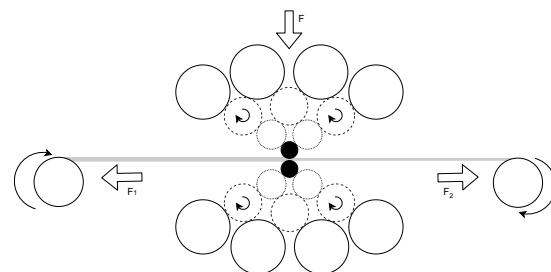
Modeli nam omogočajo tudi identifikacijo najboljših nastavitev oz. receptov procesa, s katerimi sta bili doseženi najvišji meri kakovosti in produktivnosti. Recepti so na obravnavani valjavske napravi enaki za širšo paletu kolobarjev in se v trenutni proizvodni praksi delno prilagajajo z uporabo interpolacije, s čimer pa ni moč doseži popolne prilagojenosti aktualnim razmeram. Pridobljeno znanje

na podlagi analize zgodovinskih podatkov lahko uporabimo za optimizacijo receptov procesa (ang. *process recipe optimization*), ki bodo v prihodnje zagotavljale čim bolj učinkovito delovanje procesa.

Članek je razdeljen na šest poglavij. Naslednje poglavje podrobneje predstavi proces hladnega valjanja, ki je bil predmet analiz. V tretem poglavju sta predstavljeni metodologija dela in optimizacija parametrov recepta na realnem primeru. Četrto poglavje predstavlja rezultate identificiranega modela in vpliv optimiziranih receptov na kakovost in produktivnost procesne linije, v petem poglavju pa je predstavljeno še razvito uporabniško orodje. Zaključki so podani v zadnjem poglavju.

2 Hladno valjanje pločevine z valjavskim ogrodjem Sendzimir

Obravnavan proces je valjavska naprava Sendzimir oz. ZRM [4, str. 527–530], ki je namenjena za hladno valjanje zelo tankih in trdih pločevin. Shematsko je prikazana na sliki 1.



Slika 1: Valjavska naprava Sendzimir.

Kolobar (pločevina navita v kolot) se iz enega navjalnika odvija skozi valjavsko ogrodje, kjer se stanjša na želeno debelino, in navija na drugem navjalnem kolotu. Ker je želena redukcija (odvzem debeline materiala) navadno večja, kot je mogoče doseči z enim prehodom (prevlekom) skozi valje, se v praksi to rešuje z več zaporednimi valjanji. Vzdolžni profil, tj. debelina obdelovanca, se spreminja [5] z gibanjem opornih valjev v prvem nivoju, s katerimi nastavljamo odmik med delvnima valjema – režo (ang. *gap*).

Glede na razred trdnosti obdelovanca ter začetno in končno (oz. ciljno) debelino kolobarja se določi plan ozi-

roma recept valjanja, katerega definirajo:

- redukcija (odvzem materiala),
- hitrost valjanja,
- sili natega vhodnega in izhodnega navijalnika (F_1 in F_2) in
- začetna sila stiskanja (F), ki v splošnem vpliva na druge kazalnike učinkovitosti, s katerimi se ne ukvarjamo.

3 Optimizacija parametrov recepta

S podrobno analizo preteklih procesnih razmer in pripadajočih kazalnikov učinkovitosti lahko identificiramo vplive nastavitev procesa (receptov) in procesnih spremenljivk na kakovost produkta ter jih zapišemo v obliki matematičnih modelov. Le-te pa lahko v naslednji fazi uporabimo za optimizacijo parametrov recepta.

Parametri recepta, ki jih želimo prilagoditi z namenom optimizacije kakovosti in produktivnosti procesne linije, so hitrost valjanja (v) in sili natega vhodnega (F_1) ter izhodnega (F_2) navijalnika. Značilko kakovosti smo definirali kot absolutno vrednost izhodnega odstopanja debeline od reference, stopnjo produktivnosti pa predstavlja hitrost valjanja.

Posamezni koraki za doseganje cilja so bolj podrobno opisano v sledečih podpoglavljih.

3.1 Predpriprava podatkov

Podatki, ki smo jih pridobili iz podatkovne baze so vzvrjeni s časovnim intervalom 0.01 s, zato smo jih zaradi sistematičnega pristopa pretvorili iz časovnega prostora v prostor razdalje in s tem zagotovili primerljivost značilk pri različnih hitrostih valjanja. Uporabljen je pristop za pretvorbo, kjer razdaljo ocenjujemo preko integriranja hitrosti (v) po času (t), kar je nakazano v enačbi (1).

$$d(t') = \int_{t_0}^{t'} v(t) \cdot dt \approx \sum_{i=1}^{n(t')} v(i) \cdot \Delta t. \quad (1)$$

Valjavska naprava večino časa deluje v ustaljenem stanju, zato smo se pri analizi osredotočili na odseke, kjer je bilo prisotno delovanje v ustaljenih delovnih točkah.

Stanje procesa, na podlagi katerega se bo matematični model naučil zvez med vhodnimi in izhodno spremenljivko, opišemo s karakterističnimi značilkami, ki smo jih izbrali na podlagi razpoložljivih spremenljivk (lastnosti prevleka, lastnosti kolobarja in parametri recepta). Posamezne značilke predstavljajo povprečno vrednost atributa v ustaljenem stanju.

Iz vseh dinamičnih spremenljivk smo pridobili dodatne značilke, ki smo jih definirali kot pripadajoče statistične funkcije:

- aritmetična srednja vrednost,
- standardni odklon,
- mediana,

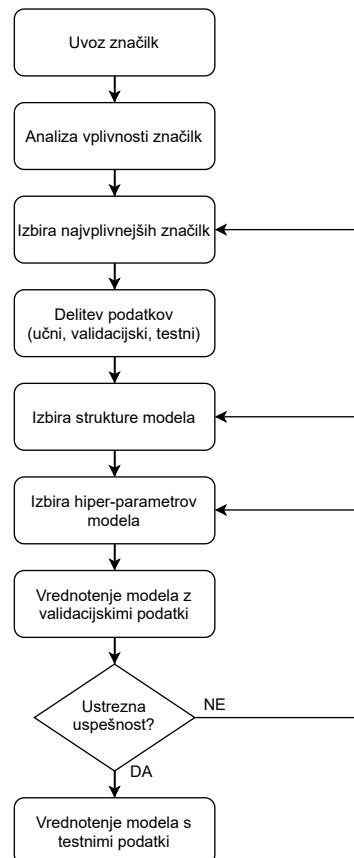
- minimalna vrednost in
- maksimalna vrednost.

Zaradi narave procesnih veličin, ki nastopajo v zelo različnih velikostnih razredih in merskih enotah, lahko izgubimo informacijo o pomembnosti posameznega atributa, zato jih je v izogib temu potrebno skalirati [6, str. 113–115], kar navadno dosežemo z normalizacijo ali standardizacijo.

3.2 Identifikacija modela

Relacijo med vhodnimi spremenljivkami (značilkami) in značilko kakovosti smo želeli zapisati v obliki modela črne škatle (ang. *black box*), s katerim bi lahko na podlagi razpoložljivih procesnih podatkov sklepali na kakovost produkta.

Diagram poteka modeliranja prikazuje slika 2, v naslednjih odstavkih pa so predstavljene osnovne ideje glavnih korakov.



Slika 2: Potek identifikacije modela.

Ker je naš osnovni cilj optimizacija parametrov recepta, je potrebno med uporabljeni značilke uvrstiti parametre recepta, za katere se predvideva močan vpliv na kazalnik učinkovitosti. Druge značilke, na podlagi katerih bo model napovedoval, pa izberemo z algoritmom iskanja najvplivnejših značilk (v našem primeru Spearmanovim algoritmom [7, str. 372–376]).

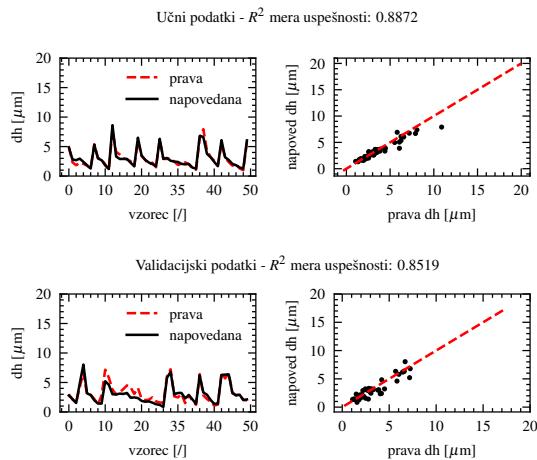
V večini primerov na aktualnem področju uporabe ne razpolagamo s testno množico podatkov, zato je celoten

nabor razpoložljivih podatkov smiselno razdeliti v učno, validacijsko in dodatno testno množico podatkov, katero uporabimo le v končni fazi vrednotenja.

Pri velikih količinah učnih podatkov je učinkovit regresijski model večplastnega perceptron [8] (ang. *multi-layer perceptron – MLP*), kateri je tudi uporabljen v našem primeru. V fazi razvoja in identifikacije najbolj uspešnega modela smo za iskanje najbolj ustreznih hiper-parametrov, uporabili algoritem iskanje v mreži (ang. *grid search*).

Za objektivno oceno uporabnosti modela uporabimo splošno uveljavljene mere uspešnosti. V našem primeru je to koeficient determinističnosti (R^2 uspešnost).

Na sliki 3, grafa na levi (zgoraj na učni, spodaj na validacijski množici podatkov) strani prikazujeta izsek napovedanih vrednosti (črtkano) izhodnega odstopanja debeline od reference, poleg pa je izrisana še prava vrednost (polna črta). Na desni strani (zgoraj na učni, spodaj na validacijski množici podatkov) pa sta prikazana grafa raztrosa, katera v drugi perspektivi predstavlja podobnost med pravo in napovedano vrednostjo.



Slika 3: Vrednotenje identificiranega modela.

3.3 Optimizacija na podlagi identificiranega modela

Na podlagi znane relacije med vhodi in izhodom modela lahko izbrane vhodne spremenljivke (v našem primeru je to recept) optimiziramo tako, da uporabimo inverz modela, ki na podlagi merjenih spremenljivk in želene kakovosti, na izhodu poda optimalne parametre recepta

Druga možnost, katero smo tudi uporabili, pa je z uporabo postopka optimizacije, s katerim minimiziramo kriterijsko funkcijo, oblikovano iz večih kriterijev:

- f_1 : izhodna kakovost – absolutna vrednost odstopanja izhodne debeline od reference,
- f_2 : produktivnost – hitrost valjanja in
- f_3 : mehka omejitev – visoka kazen ob preseganju tolerančnih meja odstopanja izhodne debeline od reference.

Pri tem pa moramo upoštevati fizikalne omejitve procesa, kar pomeni, da je potrebno definirati množico možnih

rešitev posamezne spremenljivke, imenovano prostor iskanja (ang. *search space*). Torej vsaki spremenljivki, ki jo želimo optimizirati, priredimo spodnjo in zgornjo mejo.

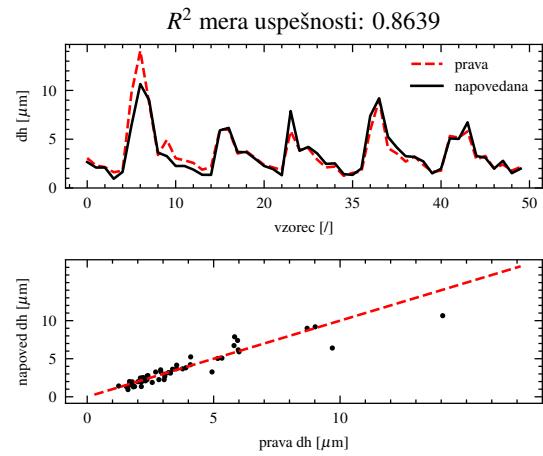
Matematična formulacija večkriterijske optimizacijске funkcije [9] je prikazana v enačbi (2):

$$\min F(\mathbf{x}) = \omega_1 \cdot f_1^2 + \omega_2 \cdot f_2^2 + k \cdot f_3^2 = \\ \omega_1 \cdot \text{model}(\{R, P\})^2 + \omega_2 \cdot (v_{max} - v)^2 + k \cdot (dh_{over})^2, \quad (2)$$

kjer je R vektor značilk recepta, P vektor najinformativnejših procesnih značilk, v hitrost valjanja, v_{max} maksimalna dovoljena hitrost valjanja, dh_{over} presežek odstopanja izhodne debeline od reference čez tolerančno mejo, k visok koeficient za kaznovanje dh_{over} , ω_1 in ω_2 pa sta uteži, s katerima vplivamo na poudarek kriterijske funkcije, ki je bodisi bolj na kakovosti bodisi bolj na produktivnosti. Oba kriterija sta si nasprotujoči zahtevi, kar pomeni da iščemo kompromis med stopnjo produktivnosti in kakovostjo produkta. Vrednost optimizacijske funkcije mora biti pri najboljših optimiziranih parametrih najmanjša.

4 Rezultati

Za nepristransko mero uspešnosti regresijskega modela procesa, smo pri končnem vrednotenju uporabili poseben nabor podatkov (testno množico), katerega pri modeliranju nismo uporabili. Na sliki 4 je številsko in grafično prikazana ovrednotena uspešnost modela.



Slika 4: Vrednotenje identificiranega modela.

Razmeroma visoka mera uspešnosti identificiranega modela procesa je vzpodbudna za praktično uporabo, tj. nastavljanje optimalnejših parametrov recepta za posamezni kolobar. Tabela 1 prikazuje procentualno vrednost izboljšanja kakovosti q in produktivnosti p z optimiziranim receptom (odebeljeni tisk) proti dejansko uporabljenim receptom, kjer izračun temelji na napovedi identificiranega modela. Vpliv uteži ω_1 in ω_2 optimizacijske funkcije (2) preizkusimo z ovrednotenjem različnih receptov, ki favorizirajo bodisi kvaliteto bodisi produktivnost.

Tabela 1: Primerjava vplivov uporabe različnih receptov na kazalnike proizvodne učinkovitosti. Pripona * označuje izbor uteži $\omega_1 = 0,6$, $\omega_2 = 0,4$, pripona ** pa označuje izbor uteži $\omega_1 = 0,4$, $\omega_2 = 0,6$.

vzorec /	recept			rezultat	
	v [m/s]	F_1 [kN]	F_2 [kN]	q [%]	p [%]
1	8,98	78	118		
1*	10,29	90	117	17,16	14,57
1**	10,35	90	117	17,14	15,24
2	8,80	82	121		
2*	9,16	90	171	6,23	4,12
2**	9,83	90	124	-3,19	11,73

Opazimo, da je s prilagoditvijo parametrov recepta posameznemu kolobarju, moč bistveno vplivati na produktivnost procesne linije oziroma kakovost produkta. Pri prvem vzorcu se pri večjem poudarku optimizacijske funkcije na produktivnosti kakovost bistveno ne poslabša, pri drugem vzorcu pa je poslabšanje konkretno. Iz tega sledi, da izbor uteži pomembno vpliva na kakovost rezultata. Za bolj zanesljivo napovedovanje, bi bilo v prihodnje potrebno izvesti še dodatno analizo vpliva izbranih uteži.

5 Razvoj uporabniškega orodja

Razvito prototipno podporno orodje za svetovanje optimalnih nastavitev recepta pred pričetkom procesa je prikazano na sliki 5.



Slika 5: Orodje *Optimizator*.

V levem zgornjem oknu so prikazane značilnosti kolobarja, spodnje okno pa je namenjeno za upravljanje z nastavtvami optimizacije. Desni tabeli prikazujeta dejansko uporabljeni ter izračunani (za več segmentov kolobarja) optimalne parametre recepta.

Graf na sredini prikazuje predvidene poteke značilke kakovosti v naslednjem prevleku za različne uporabljeni recepte (dejansko uporabljen, optimalen, uporabniško nastavljen). Nad grafom je ocena izboljšanja kakovosti in produktivnosti z uporabo izračunanih parametrov recepta.

6 Zaključek

Predlagali smo možnost optimizacije procesa hladnega valjanja na podlagi analize arhivskih procesnih podatkov.

Identificirani model omogoča napovedovanje izhodne kakovosti pred pričetkom valjanja, kar se lahko uporabi tako za preverjanje ustreznosti že uporabljenih receptov, kot za optimizacijo nastavitev recepta še pred pričetkom valjanja na podlagi lastnosti aktualnega kolobarja.

Uporabljen pristop izrabe zgodovinskih podatkov za optimizacijo proizvodne učinkovitosti ni vezan na specifične lastnosti obravnavane naprave, zato je – z modifikacijami – omogočena prenosljivost na druge procese.

Priložnost za nadaljnje delo je v dodatni validaciji identificiranega modela in smiselnosti izračunanih optimalnejših parametrov recepta vzporedno z realnim procesom, integraciji razvitega orodja v sam proces ter razvoju dodatnih funkcionalnosti za sprotno evaluacijo ter avtomatsko posodabljanje modelov. Tako bi bila možna tudi analiza opreme valjavskega ogrodja in implementacija storitev prediktivnega vzdrževanja.

Zahvala

Delo je bilo izvedeno v okviru mednarodnega projekta INEVITABLE (“Optimization and performance improving in metal industry by digital technologies”) (GA No. 869815), ki je sofinanciran s strani Evropske komisije v okviru programa Obzorja 2020, SPIRE in v sklopu nacionalnega raziskovalnega programa Sistemi in vodenje, P2-0001.

Posebna zahvala gre dr. Mihi Glavanu za strokovno pomoč in usmerjanje pri delu na projektu ter komentarje pri nastajanju prispevka. Hvala tudi doc. dr. Vitu Logarju in dr. Dejanu Gradišarju za svetovanje in predloge pri pisaju vsebinskega dela.

Literatura

- [1] Ö. Çelik, “A Research on Machine Learning Methods and Its Applications”, sep. 2018, doi: 10.31681/jetol.457046.
- [2] X. Yao, S. Li, in A. Zhang, “Equipment Condition Monitoring and Diagnosis System Based on Evidence Weight”, International Journal of Online Engineering (iJOE), let. 14, str. 143, feb. 2018, doi: 10.3991/ijoe.v14i02.7731.
- [3] V. Meyer Zu Wickern, “Challenges and Reliability of Predictive Maintenance”. 2019. doi: 10.13140/RG.2.2.35379.89129.
- [4] A. Bhaduri, Mechanical Properties and Working of Metals and Alloys, vol. 264. Springer Singapore, 2018
- [5] J. Ringwood, “Shape control systems for Sendzimir steel mills”, Control Systems Technology, IEEE Transactions on, vol. 8, str. 70–86, feb. 2000.
- [6] J. Han in M. Kamber, Data Mining : Concepts and Techniques. San Francisco [u.a.]: Kaufmann, 2005.
- [7] D. Zwillinger in S. Kokoska, CRC standard probability and statistics tables and formulae. Boca Raton: Chapman & Hall/CRC, 2000.
- [8] I. Basheer in M. N. Hajmeer, „Artificial Neural Networks: Fundamentals, Computing, Design, and Application“, Journal of microbiological methods, let. 43, str. 3–31, jan. 2001, doi: 10.1016/S0167-7012(00)00201-3.
- [9] T. Robič in B. Filipič, “Večkriterijsko optimiranje z genetskimi algoritmi in diferencialno evolucijo”, IJS-DP 9065, Jozef Stefan Institute, 2005.