

Izvirni znanstveni
članek

TEHNIKA –
elektronske kompo-
nente in tehnologije

Datum prejema:
3. februar 2020

ANALI PAZU
10/2020/1-2: 24-27
www.anali-pazu.si

Analiza topografije robotsko lasersko kaljenih materialov s pomočjo strojnega učenja

Analysis topography of robot laser hardened materials by using machine learning method

Matej Babič^{1,*}

¹Fakulteta za informacijske študije, Novo mesto, Slovenija

E-mail: babicster@gmail.com

*Avtor za korespondenco;

Povzetek: Laserska obdelava materialov, vključno s toplotno obdelavo, temelji na uporabi laserskega sevanja, ki vam omogoča, da na zelo majhni površini ustvarite visoke gostote toplotnega polja, potrebne za intenzivno segrevanje ali taljenje. V članku je predstavljen vpliv parametra robotske laserske celice na topografijo materialov. S pomočjo metod strojnega učenja je predstavljeno, kako parametri robotske laserske celice vplivajo na trdoto in hrapavost kaljenega materiala, ter kakšna je povezava med trdoto in hrapavostjo.

Ključne besede: laser, robot, strojno učenje.

Abstract: Laser treatment of materials, including heat treatment, is based on the use of laser radiation, which allows you to create, on a very small surface, the high thermal field densities required for intense heating or melting. The article presents the influence of the robot laser cell parameter on the material topography. Machine learning methods show how the parameters of a robot laser cell affect the hardness and roughness of the hardened material, and the relationship between hardness and roughness.

Key words: laser, robot, machine learning.

1. Uvod

Robotsko lasersko kaljenje materialov je po analogiji z drugimi vrstami kaljenja tvorba v fazi segrevanja avstenitne strukture in njena nadaljnja preobrazba v martenzit med fazo hlajenja. Po robotski laserski toplotni obdelavi dobimo utrjen trak na površini zlitine. Pri kaljenju velikih površin zlitin se kaljenje izvaja v trakovih, medtem ko je priporočljivo, da se med temi letvami naredijo majhne vdolbine, da se prepreči pojav mehkih madežev (kaljenje cone).

Robotsko lasersko kaljenje (ali termična toplotna obdelava) je sestavljeno iz hitrega segrevanja kovinske površine z laserskim žarkom in njegovega naknadnega intenzivnega hlajenja zaradi odvajanja toplote znotraj materiala.

Lasersko kaljenje ima kar precej prednosti. Te so:

- manjši stroški obdelave,
- ni potrebe po hlajenju,
- visoka fleksibilnost,
- možnost avtomatizacije v proizvodni proces,
- izjemna obrabna obstojnost kaljene površine,
- kaljenje kompliciranih geometrijskih oblik,
- točkovno kaljenje,
- ni lokalnega taljenja materiala,
- zelo majhne deformacije materiala,
- visoka natančnost in prilagodljivost,
- običajno ni dimenzijskih odstopanj,
- ni sprememb hrapavosti površine (Ra in Rz),
- enakomerna trdota po celotni površini kaljenja,
- uporabna za vse kaljive materiale,
- kaljenje različnih 3D geometrijskih oblik,
- spremljanje in reguliranje temperature kaljenja,
- dvo-žarkovno lasersko kaljenje,
- kaljenje s prekrivanim žarkom,
- ni potrebe po 3D CAD risbah.

Površinska topografija je opredeljena s površinsko usmerjenostjo in hrapavostjo, značilna pa je zaporedje vrhov in dolin. Površinska hrapavost je indikator, ki kaže določeno količino podatkov, ki označuje stanje površinskih nepravilnosti, merjenih z izjemno majhnimi segmenti. Med procesom robotskega laserskega kaljenja se na površini materiala oblikujejo nepravilnosti - odstopanja od geometrijske oblike, ki določajo topografijo površine in pomembno vplivajo na medsebojno delovanje trdnih snovi med zunanjim trenjem in obrabo. Trdota v znanosti o materialih pomeni lastnost trdne snovi, da se upira stalni deformaciji (obrabi).

Strojno učenje je le poskus, da se stroj naredi iz lastnih izkušenj. Danes domnevamo, da je razvoj takšnih strojev najhitrejši način za ustvarjanje prave umetne inteligence. Da pa bo računalnik postal inteligenten, se mora zgoditi preboj na stičišču znanosti in umetnosti. Strojno učenje je novo orodje, nov način inženiringa. Strojno učenje se ukvarjamo v dveh smereh: izboljšujemo svoje izdelke - na primer iskalnik, temelj našega poslovanja - in gradimo povsem nove izdelke, ki so bili prej preprosto nemogoči. Danes se uporablja več metod strojnega učenja.

Namen članka je predstaviti uporabo metode strojnega učenja v praktični aplikaciji, natančneje pri topografiji materialov obdelanih z lasersko


tehnologijo. S pomočjo metod strojnega učenja je predstavljeno kako parametri robotske laserske celice vplivajo na trdoto in hrapavost kaljenega material, ter kakšna je povezava med trdoto in hrapavostjo.

2. Metodologija

Študija je bila izvedena s standardnim orodnim jeklom z oznako EN 100083 - 1. Orodje jeklo je bilo kaljeno z robotsko lasersko celico z različnimi hitrostmi in različnimi močmi. Na laserski celici je bila spremenjena hitrost $v \in [2,5]$ mm / s in temperatura $T \in [800, 2000]$ ° C. Vsak vzorec je bil jedkan in poliran (IMT, Inštitut za kovine in tehnologijo Ljubljana, Slovenija). Na IJS, Institut Jožef Stefan so bile izvedene meritve trdote in hrapavosti (profilometer).

Slika 1 prikazuje hrapavost in trdoto robotsko lasersko kaljenega vzorca s temperaturo 1400°C in hitrostjo 3 mm/s. Puščica prikazuje smer potovanja robotskega laserskega žarka. Hrapavost pred kaljenjem (hrapavost vzorca) je 4.4 nm, trdota pred kaljenjem 34.5 HRC

Slika 1: Hrapavost in trdota robotsko lasersko kaljenega vzorca s temperaturo 1400°C in hitrostjo 3 mm/s



Modeliranje topografije (hrapavosti) smo uporabili metodo genetskih algoritmov.

Genetsko programiranje (GP) je podobno genetskemu algoritmu in se razlikuje le glede na način predstavitev. Posamezniki v genetskih algoritmihih so predstavljeni z zaporedjem števil, posameznik v genetskem programiranju pa z računalniškim programom. GP samodejno piše program glede na naravo naravne selekcije (evolucije). Na začetku imamo nekaj naključno napisanih programov, ki predstavljajo začetno populacijo. Nato s križanjem in selekcijo dobimo naslednjo generacijo. Uporabljen je bila genetska operacija reprodukcije in križanje.

Tabela 1. Parametri genetskega programiranja.

Velikost populacije	500
Največje število v generaciji	100
Verjetnost križanja	0.4
Prehodna verjetnost	0.6
Največja dovoljena globina pri ustvarjanju populacije	6
Največja dovoljena globina po operaciji križanja dveh organizmov	10
Najmanjša dovoljena globina organizmov pri nastajanju novih organizmov	2
Velikost turnirja, ki se uporablja za izbiro organizmov	7

Multipla (večkratna) linearna regresija (MR) je najpogostejša oblika analize linearne regresije. Kot napovedna analiza se za razlago razmerja med eno stalno odvisno spremenljivko in dvema ali več neodvisnimi spremenljivkami uporablja več linearna regresija. Model zapišemo z enačbo $Y=b_0+b_1 \times X_1+b_2 \times X_2+\dots+b_n \times X_n$.

3. Rezultati in diskusija

Tabela 1 prikazuje parametre robotske laserske celice. Stolpec S predstavlja oznako vzorca od P1 do P20. Parameter X_1 predstavlja temperaturo kaljenja ($v^\circ C$), parameter X_2 predstavlja hitrost kaljenja ($v\text{ mm/s}$), parameter X_3 predstavlja trdoto materiala v HRC in zadnji stolpec Y predstavlja topografsko lastnost hrapavost ($v\text{ nm}$). Pod tabelo 2 je predstavljen linearni model in model GP. Tabela 3 prikazuje eksperimentalne in modelirane podatke. Stolpec E prikazuje eksperimentalne vrednosti, stolpec GP predstavlja modelirane vrednosti z metodo GP in stolpec MR predstavlja modelirane vrednosti z metodo MR. Vzorec P1 ima najvišjo trdoto po kaljenju 60 HRC, najnižjo vrednost trdote po kaljenju pa ima vzorec P17, 52 HRC. Vzorec P13 ima najvišjo hrapavost Ra, 2350 nm, najnižjo vrednost hrapavosti pa ima vzorec P4, 76,3 nm. Model genetskega programiranja nam da natančnost 15,98 %, kar pomeni, da je odstopanje med eksperimentalnimi in modeliranimi vrednostmi 84,02 %. Model multiple regresije nam da natančnost 31,88 %, kar pomeni, da je odstopanje med eksperimentalnimi in modeliranimi vrednostmi 68,12 %.

S	X_1	X_2	X_3	Y
P1	1000	2	60	201
P2	1000	3	58,7	171
P3	1000	4	56	109
P4	1000	5	56,5	76,3
P5	1400	2	58	1320
P6	1400	3	57,8	992
P7	1400	4	58,1	553
P8	1400	5	58,2	652
P9	1000	2	57,4	337
P10	1000	3	56,1	307
P11	1000	4	53,8	444
P12	1000	5	56	270
P13	1400	2	55,3	2350
P14	1400	3	57,2	1900
P15	1400	4	57,8	661
P16	1400	5	58	759
P17	800	0	52	183
P18	1400	0	57	1330
P19	2000	0	56	1740
P20	950	0	58	502

Tabela 2. Parametri robotske laserske celice.

Model MR

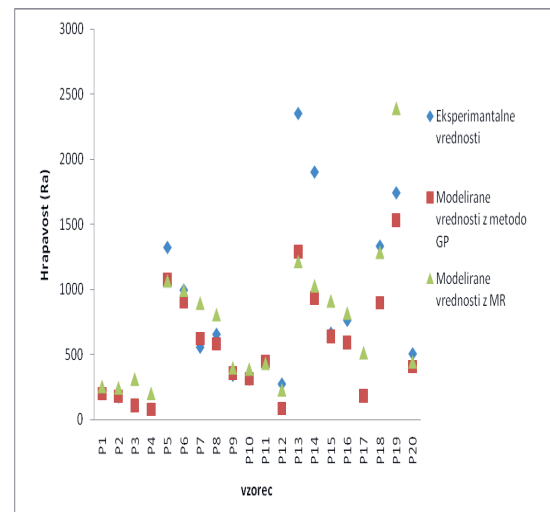
$$Y=1.75 \times X_1 - 82.62 \times X_2 - 55.62 \times X_3 + 2001.87$$

Model GP

$$\frac{X_1 - 0.264682 X_3^2 - \frac{7.55623 X_3}{1 - X_1 - 0.264682 X_2 X_3}}{X_3} - \left(-0.21725 (0.4340478 + X_1) - \frac{0.264682 (X_3 - 0.264682 X_2 X_3)}{X_3} \right) / \left(1.64082 + X_1 - 1.68769 X_3 - 0.264682 X_3^2 + \frac{17.39061}{X_1 + X_3} + \frac{1.64082 - 0.264682 X_3^2 + \frac{0.07006 X_2 X_3^2}{X_1 - \frac{17311}{X_3} X_3 - 0.264682 X_2 X_3 - 0.264682 X_3^2}}{X_2} \right)$$

S	E	GP	MR
P1	201	198.173	254.9741
P2	171	179.002	244.6663
P3	109	108.801	312.2361
P4	76,3	76.4217	201.8142
P5	1320	1073.66	1067.4144
P6	992	902.488	995.9125
P7	553	622.442	896.6018
P8	652	582.532	808.4165
P9	337	357.065	399.6038
P10	307	311.393	389.2964
P11	444	445.726	434.6151
P12	270	84.2454	229.6134
P13	2350	1290.83	1217.602
P14	1900	932.973	1029.289
P15	661	636.694	913.2898
P16	759	591.64	819.5418
P17	183	183.365	514.6434
P18	1330	895.599	1288.282
P19	1740	1530.65	2395.682
P20	502	406.221	443.8253

Tabela 3. Eksperimentalni in modelirani podatki.



Slika 2: Eksperimentalni in modelirani podatki.

4. Zaključki

V članku je predstavljena uporaba strojnega učenja v strojništvu, konkretnije pri modeliranju topografije robotsko lasersko kaljenih materialih. Strojno učenje, zadeva gradnjo in preučevanje sistemov, ki se lahko učijo iz podatkov. Učenje je temeljni in najpomembnejši element biološko inteligentnih sistemov. V industrijskem postopku uporabljamo metode inteligentnega sistema. Članke povezuje znanstvene discipline matematike, fizike, računalništva in strojništva.

Literatura

1. Steiner Petrovič Darja; Šturm Roman. Fine-structured morphology of a silicon steel sheet after laser surface alloying of Sb powder. *Strojniški vestnik*, Jan. 2014, vol. 60, no. 1, pp. 5-11.
2. Kovačič, Miha, Mihevc, Andrej, Terčelj, Milan. Roll wear modeling using genetic programming - industry case study = Modeliranje obrabe valjev z genetskim programiranjem - primer iz industrije. *Materiali in tehnologije*, ISSN 1580-2949. [Tiskana izd.], 2019, letn. 53, št. 3, str. 319-325, ilustr. <http://mit.imt.si/Revija/izvodi/mit193/kovacic.pdf>, doi: 10.17222/mit.2018.104.