

Zaznava vdolbin na površjih z deflektometrijo in strojnim učenjem

Denis Kolednik, Borut Žalik

Fakulteta za elektrotehniko, računalništvo in informatiko, Univerza v Mariboru


E-pošta: denis.kolednik@um.si, borut.zalik@um.si

Dent detection on surfaces using deflectometry and machine learning

This paper presents an approach for dent detection on specular surfaces. Deflectometry is used for capturing geometry properties of the surface, using a stripe pattern projection. Dents on the surface deform the pattern. A machine learning approach is used to learn the shape of such deformations and to detect them. Results of testing show an average F-measure value of 0,88 and is therefore suitable for use in an industrial quality check image process.

1 Uvod


V industrijski proizvodnji se lahko na površju izdelkov, kot so kovinske in steklene plošče, pojavijo poškodbe v obliki vdolbin. Pravočasno odkritje takšnih poškodb pomeni zmanjšanje stroškov kasnejšega popravila. Ročno preverjanje kakovosti izdelkov poda subjektivno oceno škode in je časovno potratno. Z avtomatizirano zaznavo poškodb povečamo tako hitrost kot natančnost zaznave napak. Poškodbe na izdelkih, ki nastanejo bodisi zaradi naravnih dejavnikov (toča, kamenje), bodisi zaradi nepazljivega ravnanja uporabnika, se kažejo kot vdolbine. V primeru, da je material površja vsaj delno zrcalen, lahko za zaznavo omenjenih vdolbin izkoristimo lastnosti deflektometrije (*angl. deflectometry*) [4].



Slika 1: Skica postavitve scene za postopek deflektometrije.

Deflektometrija je postopek opazovanja odsevov okoli na zrcalnih površjih objektov. Ker se svetloba odbija

po načelu odbojnega zakona svetlobe, lahko v kontroliranem okolju pridobimo informacije o obliki opazovanega površja [12]. Okolje za zajemanje je sestavljeno iz vira svetlobe z referenčnim vzorcem, ki je usmerjen proti površju in kamere, usmerjene v isti del površja, kjer zajame odsevani vzorec. Postavitev takšnega okolja prikazuje slika 1. Najpogosteje uporabljen vzorec so vzporedno enakomerno porazdeljeni trakovi [10]. Zaradi geometrije površja so v zajetih slikah prisotne deformacije referenčnega vzorca (slika 2). Z analizo teh deformacij lahko sklepamo o morebitnih vdolbinah/poškodbah na površju.



Slika 2: Deformacija projiciranega vzorca.

Osnovna ideja projiciranja in analize vzorcev na vsaj delno zrcalna površja ni nova. S tem problemom so se ukvarjali predvsem v avtomobilski industriji. Lilienblum, Albrecht, Calow in Michaelis [7] so predlagali metodo za avtomatsko zaznavo majhnih vdolbin na karoserijah avtomobilov, ki tekom proizvodne linije niso vidne vse do postopka lakiranja. Postopek temelji na 3D rekonstrukciji podatkov iz dveh kamer in projiciranega vzorca na površje ter uporabo nevronske mreže. Le-te so naučene, kakšno mora biti površje brezhibnega izdelka ter vrnejo morebitno odstopanje ob zaznavi poškodovanega izdelka. Yogeswaran in Payeur [13] sta prav tako predlagala postopek za zaznavo deformacij na avtomobilskih delih v 3D prostoru. Za zajem podatkov o površju delov so uporabili laserske prebiričke. Analiza podatkov je obsegala segmentacijo morebitnih deformacij iz podatkov ter njihovo kasnejšo klasifikacijo. Karbacher, Babst, Häusler in Laboureux [5] so predstavili postopek vizualizacije in zaznave vdolbin na karoserijah avtomobilov. S tehnologijo daljinskega zaznavanja so pridobili 3D podatke o površju. Postopek izrabi lastnosti 3D geometrije in osvetlitve površja. S simulacijo luči se ob pravilni postavitvi

pojaviijo vidne sence v vdolbinah, ki jih je mogoče enostavno zaznati. Santamaria in Arkin [9] sta predstavila pristop za zaznavo vdolbin na industrijskih sodih. Postopek temelji na projiciranju laserskega žarka v obliki traku na površje. Pristop uporablja vrednost prvega odvoda krivulje projiciranega traku za določitev kandidatov za vdolbine površja. Denkena, Ahlers, Berg in Wolf [2] so predlagali metodo za zaznavo vdolbin, ki temelji na analizi razdalj med projiciranimi trakovi referenčnega vzorca.

Največje težave takšnih metod za zaznavo predstavljajo območja, ki močno deformirajo vzorec, vendar niso vdolbine. Primer le-teh so valovita in upognjena površja ter površja z oblikovalskimi linijami in raznimi dodatki na površju. V ta namen mora metoda upoštevati določene značilnosti, ki veljajo le za vdolbine. V članku bomo predstavili metodo za zaznavo vdolbin na vsaj delno zrcalnih površjih brez predhodnega znanja o obliki površja.

2 Zaznava vdolbin


V tem poglavju opišemo metodo zaznave vdolbin v simuliranem okolju. Na površje projiciramo vzorec vzporedno ponavljajočih se trakov, ki jih ob odboju zajamemo s kamero. Zaznavo vdolbin izvedemo s kaskadnim klasifikatorjem (*angl. cascade classifier*), ki smo ga naučili vzorce, ki predstavljajo vdolbine. Celoten postopek je sestavljen iz treh korakov, ki so podrobneje opisani v naslednjih podpoglavjih.

2.1 Snemanje površja

Snemanje površja smo opravili s simuliranjem deflektometrije. Vir svetlobe, sestavljen iz vzporednih svetlobnih trakov, ki so med seboj enakomerno razmaknjeni, projicira vzorec na površje. Svetloba vzorca se odbije z enakim kotom kot je vstopni in ga zajame kamera. Na podlagi deformacij vzorca opravimo analizo, opisano v naslednjih podpoglavjih. Takšna postavitev scene za snemanje lahko povzroči negotovost v kasnejši zaznavi vdolbin. Zgodi se lahko namreč, da vzorec pade na površje tako, da določenih vdolbin ni mogoče zaznati. Razlog je lahko premajhna vdolbina za določen vzorec ali pa kot snemanja ne daje željenih rezultatov. To težavo smo odpravili s postopnim snemanjem površja. Če se predmet premika in ga snemamo v dovolj majhnem časovnem intervalu, obstaja več možnosti, da je vdolbina zaznana nekje na poti premika. Primer simulacije posnetega površja lahko vidimo na sliki 3.


2.2 Razpoznavna vzorcev

Deformacije vzorca predstavljajo spremembe geometrije na površju. Cilj je izmed vseh deformacij izluščiti le tiste, ki predstavljajo vdolbine. V ta namen smo uporabili strojno učenje, natančneje, postopek, ki sta ga predlagala Viola in Jones [11] ter kasneje izboljšala Lienhart in Maydt [6] in temelji na razpoznavi objektov s Haarovimi značilkami. Predlagan klasifikator je potrebno najprej naučiti vzorce, ki jih mora zaznavati. Iz učne množice smo izluščili Haarove značilke, s katerimi opišemo vhodne podatke učenja. Postopek zaznave poteka tako, da



Slika 3: Primer posnetka ukrivljenega površja s projiciranim vzorcem trakov. Iz deformacije vzorcev so vidne vdolbine.

klasifikator iz vhodnih podatkov poskuša najti vzorce Haarovih značilk, najbolj podobnih učni množici. Ker je uporabljen klasifikator večstopenjski, v prvih stopnjah išče z zelo majhnim številom značilk ter tako hitro izloči območja na sliki, ki zagotovo ne predstavljajo iskanega objekta. Bolj ko se stopnja viša, več značilk uporablja in je zaznava vedno bolj natančna. Ker so v prvih stopnjah izločena območja z velikim odstopanjem, je takšen postopek časovno zelo učinkovit.



Slika 4: Primeri različnih tipov deformacij, ki nastanejo pri vdolbinah.

Za namen zaznavanja vdolbin na površju je potrebno klasifikator naučiti iskanja zgolj deformacij vzorca, ki karakterizirajo vdolbine. Učna množica klasifikatorja je sestavljena iz tako imenovanih pozitivnih in negativnih primerov. Pozitivni primeri predstavljajo objekte, ki jih iščemo, kar v našem primeru predstavljajo izseki posnetkov z deformiranim vzorcem. Negativni primeri predstavljajo objekte, ki jih ne iščemo. V slednjo skupino sodijo predvsem izseki posnetkov, kjer vzorec ni deformiran. S takšnim sistemom dvojnih vzorcev za učenje se klasifikator v primeru dvoumnosti zaznanega objekta boljše odloči, če zaznavo sprejme ali ovrže. Empirična analiza posnetkov je pokazala, da se vdolbina lahko pokaže v treh osnovnih oblikah deformacije vzorca (slika 4). Ker klasifikator zaznava glede na naučeno obliko, so te tri oblike deformacij med seboj preveč različne za učenje zgolj enega klasifikatorja. Iz tega razloga smo uporabili tri ločene. Slike smo pred obdelali s klasičnimi postopki obdelave slik s ciljem zmanjšati vpliv šuma in povečati karakteristike oblike vzorca pri fazi učenja.

V fazi zaznavanja smo uporabili dodatne kriterije za potrditev pravilnosti zaznave. En izmed njih je omejitev spodnje in zgornje meje velikosti zaznave. S tem kriterijem se znebimo lažnih zaznav zelo majhnih deformacij, ki so lahko posledica šuma v podatkih, in zelo velikih, ki so lahko rezultat globalne ukrivljenosti celotnega površja. Naslednji kriterij je minimalno število sosednjih zaznav. Na območju, kjer se nahaja vdolbina, bo klasifikator javil pozitiven rezultat. Ob premiku iskalnega okna za en piksel, bo oblika deformacije še vedno dovolj podobna, da bo na enakem območju klasifikator spet javil pozitivno zaznavo. Z minimalnim številom zahtevanih sosednjih zaznav zvišamo verjetnost pravilne zaznave. S ciljem povečati število zaznav vsake vdolbine pri zaporednih posnetkih, smo vse tri klasifikatorje uporabili še nad inverznimi slikami. Tako zamenjamo svetel in temen predel vzorca, kar omogoča zaznavo vdolbin še med osvetljenimi trakovi.

2.3 Interpolacija vdolbin

Kljub dodatnim korakom izboljšave zaznave vdolbin se lahko zgodi, da nekaterih vdolbin klasifikator ne zazna. V tem primeru izkoristimo prednosti zaporednega zajema slik premikajočega se objekta. S spremljanjem zaporedja se bo vsaka vdolbina na posnetkih pojavila večkrat v različnih položajih na vzorcu in bo tako vsakič tvorila drugačno deformacijo vzorca. Predpostavljamo, da bo vdolbina razpoznavna na večih slikah in da se na posnetkih premika po premici v enako smer s konstantno hitrostjo. Iz dovolj velikega števila zaznanih vdolbin na takšni premici lahko interpoliramo položaje nezaznanih vdolbin.

Enak pristop uporabimo tudi za izločanje napačno zaznanih vdolbin. Če na premici vdolbine ni dovolj zaznav, lahko sklepamo, da je šlo zgolj za napačno zaznavo in jo ovržemo.


3 Rezultati

Predlagani postopek zaznave vdolbin smo implementirali v programskem jeziku C++ z ogrodjem Qt 5.1. Testiranje smo opravili na namiznem računalniku s procesorjem Intel i5-3570K in 16GB DDR3 sistemskega pomnilnika. Podatke za učenje in testiranje smo generirali z modelirnikom Cinema 4D [1]. Odboje svetlobe smo realizirali s fotorealistično metodo metanja žarka. Velikost slik je bila 640×480 pikslov. Premikanje površja smo razdelili na 100 časovnih okvirjev.


Tabela 1: Rezultati testiranja natančnosti.

Testni podatki	Natančnost	Občutljivost	F-merjenje
Ravno površje	0,93	0,96	0,95
Valovito površje	0,84	0,92	0,88
Upognjeno površje	0,79	0,90	0,81
Povprečje	0,85	0,93	0,88


Za vrednotenje rezultatov testiranja smo uporabili uveljavljene metrike [8], in sicer: natančnost (angl. *precision*), občutljivost (angl. *recall*) in F-meritev (angl. *F-*



(a) Ravno površje.



(b) Valovito površje.



(c) Ukrivljeno površje.

Slika 5: Nabor testnih podatkov.

measure). Prva metrika določa koliko od zaznanih vdolbin je bilo pravilno zaznanih. Druga metrika je koeficient med pravilno zaznanimi vdolbinami glede na vse vdolbine na sliki. F-merjenje predstavlja harmonično povprečje [3] obeh prej predstavljenih metrik.

Za učenje klasifikatorja smo pripravili učno množico pozitivnih in negativnih primerov. Pozitivni primeri predstavljajo deformacije in so glede na obliko bili razdeljeni v tri skupine. Vsaka skupina je vsebovala 200 primerov deformacij ter bila uporabljena za učenje drugega klasifikatorja. Zraven vsakega učenja se je uporabila še

množica 1500 negativnih primerov. Ti so predstavljali tako nedeformirane vzorce kot tudi deformirane, ki so nastali ob raznih robovih ali ukrivljenih področjih in niso smatrani kot vdolbine. Vsak posnetek iz te množice je bil uporabljen z različnimi stopnjami dodanega šuma ter zrcaljenjem.

Za testiranje smo pripravili 3 nabore testnih podatkov (slika 5). Podatki predstavljajo delno zrcalno površje, ki je v prvi množici ravno, v drugi valovito, v tretji pa močno ukrivljeno navznoter. Vsak nabor je sestavljen iz 100 posnetkov. Površina je bila upodobljena z materialom, ki simulira polakirano kovino z določeno stopnjo grobosti in šumom.

Rezultati testiranja so prikazani v tabeli 1. Iz rezultatov lahko vidimo, da se metoda najbolje odreže na ravнем površju. Takšno delovanje je bilo pričakovano, saj se takšno površje ne deformira nikjer drugje kot zgolj pri vdolbinah. Pri valovitem površju se deformira celoten vzorec, vendar so črte še vedno dovolj podobne osnovni obliki, da ne prihaja do prevelikega števila napačnih zaznav. Rezultati kažejo, da se postopek dobro odreže tudi na ukrivljenih površjih, kjer so deformacije vzorcev velike. Pri slednjem prihaja do največ napak pri obeh navpično ukrivljenih predelih (slika 5c). Tukaj je ukrivljenost površine dovolj velika, da lahko prikrije vzorec vdolbine.

4 Sklep

V članku smo predstavili metodo za zaznavo vdolbin na vsaj delno zrcalnih površjih. Metoda temelji na opazovanju površja s postopkom deflektometrije in strojnega učenja. Natančnost delovanja smo demonstrirali na treh naborih podatkov, ki simulirajo različno ukrivljenost površja. Rezultati testiranja kažejo na vrednost F-merjenja 0,95 na ravnem površju in 0,81 na zelo ukrivljenem. Iz te ocene lahko sklepamo, da je metoda uspešna tako na ravnih kot močno valovitih površjih.

Literatura

- [1] Maxon computer. Cinema 4D. <http://www.maxon.net/products/cinema-4d-studio>, 21.7.2014.
- [2] B. Denkena, H. Ahlers, F. Berg, T. Wolf, and H.K. Tönshoff. Fast inspection of larger sized curved surfaces by stripe projection. *CIRP Annals - Manufacturing Technology*, 51(1):499 – 502, 2002.
- [3] W. M. Douglas. More on spreads and non-arithmetic means. *The Mathematical Gazette*, 88(511):142–144, 2004.
- [4] S. Kammel and L. F. Puente. Head-mounted display for interactive inspection of painted free-form surfaces. In *Helmet and Head-Mounted Displays VIII: Technologies and Applications*, volume 5079, pages 254–264. SPIE, September 2003.
- [5] S. Karbacher, J. Babst, G. Häusler, and X. Laboureux. Visualization and detection of small defects on car-bodies. In *Vision modelling and visualization*, pages 1–8, November 1999.
- [6] R. Lienhart and J. Maydt. An extended set of Haar-like features for rapid object detection. In *International Conference on Image Processing*, volume 1, pages 900–903. IEEE, September 2002.
- [7] T. Lilienblum, P. Albrecht, R. Calow, and B. Michaelis. Dent detection in car bodies. In *15th International Conference on Pattern Recognition*, volume 4, pages 775–778, September 2000.
- [8] D.M.W. Powers. Evaluation: from precision, recall and f-measure to roc, informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2(1):37–63, 2011.
- [9] J. C. Santamaría and Arkin R. C. Structured light systems for dent recognition: Lessons learned. In *Mobile Robots*, volume 2591, pages 240–259. SPIE, October 1995.
- [10] Z. Sárosi, W. Knapp, A. Kunz, and K. Wegener. Detection of surface defects on sheet metal parts by using one-shot deflectometry in the infrared range. In *InfraMation proceedings*, pages 243–254. IWF, ETH Zurich, November 2010.
- [11] P. Viola and M. Jones. Rapid object detection using a boosted cascade of simple features. In *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, volume 1, pages 511–518. IEEE, December 2001.
- [12] S. Werling, M. Mai, M. Heizmann, and J. Beyerer. Inspection of specular and partially specular surfaces. *Metrology and measurement systems*, 16(3):415–431, 2009.
- [13] A. Yogeswaran and P. Payeur. 3D surface analysis for automated detection of deformations on automotive body panels. In *New Advances in Vehicular Technology and Automotive Engineering*, pages 303–332. InTech, August 2012.