

Metodologija za avtomatsko zagotavljanje kakovosti na proizvodnji liniji

Methodology for automated quality assurance


Jani Bizjak
jani.bizjak@ijs.si
Jožef Stefan Institute
Mednarodna podiplomska šola
Ljubljana, Slovenia

Stefan Kalabakov
stefan.kalabakov@ijs.si
Jožef Stefan Institute
Mednarodna podiplomska šola
Ljubljana, Slovenia

Primož Kocuvan
primoz.kocuvan@ijs.si
Jožef Stefan Institute
Ljubljana, Slovenija

Jože Ravničar
joze.ravnicar@unior.com
Unior Kovaška industrija d.d.
Zreče, Slovenija

Matjaž Gams
matjaz.gams@ijs.si
Jožef Stefan Institute
Mednarodna podiplomska šola
Ljubljana, Slovenia



Slika 1: 3D laserski skenirni sistem

POVZETEK

V želji po višji proizvodnji kapaciteti in učinkovitosti se vse večji del proizvodnje linije avtomatizira. Naloge, ki so enostavne za izvedbo, že nekaj desetletij uspešno izvajajo roboti, dandanes lahko rečemo, da je velik del proizvodnje linije popolnoma avtomatiziran, ljudje so prisotni le za nadzor nad stroji ter kontrolo kakovosti. Ravno kontrola kakovosti je ena najpomembnejših delov proizvodnje, ki pa jo je izredno težko avtomatizirati zaradi množice različnih tipov napak, ki lahko nastanejo - narobe gre lahko vse. V tem prispevku je predstavljen pristop k reševanju avtomatske kontrole kakovosti na proizvodnji avtomobilskih vilic, metode ter orodja, ki močno olajšalo delo zaposlenim hkrati pa povečujejo zanesljivost pri zagotavljanju kontrole kakovosti.

KLJUČNE BESEDE

podatkovne množice, nevronske mreže, zaznavanje pogleda, označevanje besedil

ABSTRACT

Need for increased production capacity and efficiency has driven large amounts of production line to be automated with robots and special machines. Today, we can say that most of the production is already automated, automated quality control being the last bastion where almost 100% human presence is required. Because of specificity of the problem and requirements of precision, it is one of the hardest parts of production to automate. In this paper we present an approach to automation of quality control in production line of automobile forks.

KEYWORDS

computer vision, 3D modeling, error detection, automatic QA

1 UVOD

Zagotavljanje kakovosti (ang. quality control) je pomemben člen postopka izdelave izdelkov oz. polizdelkov. Vse pogosteje se dogaja, da naročnik zahteva 100% kontrolo kakovosti. To pomeni, da je potrebno vsak izdelek, ki pride iz proizvodnje, preveriti, ali

Permission to make digital or hard copies of part or all of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for third-party components of this work must be honored. For all other uses, contact the owner/author(s).

Information Society 2020, 5–9 October 2020, Ljubljana, Slovenia

© 2020 Copyright held by the owner/author(s).

je pravilen. Zaradi velikega števila izdelkov (tudi po več tisoč na izmeno/dan) je to dolgotrajen ter za ljudi dolgočasen/monoton postopek, kar pogosto privede do napak oz. napačne klasifikacije izdelka.

V tem prispevku opisujemo pristop k reševanju problema avtomatske kontrole kakovosti na polizdelku avtomobilskih vilic. Gre za izjemno zahteven proces kontrole [4], [8], saj so tolerance za napake majhne, oblika izdelka je kompleksna, napake pa so pogosto edinstvene, to pomeni, da je vsaka ožganina, odrgnina ali udrtina drugačna od prejšnje. Poleg naštetega je potrebno kontrolo izvesti v določeni časovni omejitvi, saj bi v nasprotnem proizvodnja zaostajala. V prispevku opišemo 3 pristope avtomatske detekcije napak, glede na katalog najpogostejših napak, pri proizvodnji avtomobilskih vilic.

2 TIPI NAPAK

Avtomatizacija prepoznavanje napak na avtomobilskih vilicah je težaven proces ter zahteva različna orodja za zajemanje podatkov, zaradi tega je napake potrebno razdeliti v več podskupin, katere prepoznavamo z različnimi pristopi in merilnimi orodji.

Napake v grobem razdelimo v tri skupine:


- (1) *Merske napake*; to so napake, kjer so dimenzije izdelka izven toleranc (npr. obseg je prevelik)
- (2) *Vizualne napake*; to so napake, ki nastanejo zaradi različnih dejavnikov pri proizvodnji, prepoznavamo jih s pomočjo vizualnega pregleda izdelka (npr. nastanek rje, slabo pobrušena površina)
- (3) *Mehanske poškodbe*; to so napake, ki nastanejo zaradi mehanskih poškodb pri rokovanju z izdelkom (npr. okrušen rob, praska oz. udrtina)

Skozi raziskavo smo ugotovili, da je mogoče merske napake, ki imajo toleranco 0.1mm , mogoče prepoznati s pomočjo strojnega vida, medtem, ko je toleranca 0.05mm premajhna za zanesljivo uporabo. Tukaj je problem predvsem v resoluciji kamere, ki se uporablja za zajem slike / posnetka, načeloma bi se lahko z boljšo lečo to resolucijo izboljšalo a bi potek skeniranja objekta potekal prepočasi za uporabo na proizvodnji liniji. Vizualne napake so pogosto posledica mehanskih poškodb zato je strogo razlikovanje med njimi nesmiselno. Razlikujemo jih zato, ker se nekatere vizualne napake bolje prepoznavajo s pomočjo uporabe strojnega vida, medtem, ko so mehanske bolj vidne na 3D reliefu skeniranega izdelka.

3 MERILNI SISTEMI

3.1 Kamera

Uporaba kamere oz. fotoaparata je smotrna pri vizualnih tipih napak saj zagotavlja hitro skeniranje ter omogoča prepoznavanje velikega števila različnih napak. Testirali smo različne tipe (video)kamer, fotoaparatorov ter leč. Zaradi enostavnejšega postopka zajema in prenosa slik na računalnik, smo za raziskovalno pridobivanje posnetkov uporabili DSLR fotoaparator z vsaj 12MP resolucijo slik ter lečo z goriščno razdaljo nad 50mm. Preizkusili smo tudi *makro lečo 1:1* z goriščno razdaljo 100mm, s katero smo pridobili veliko boljšo kakovost slik. Po drugi strani visoka goriščna razdalja makro leče povzroči počasno skeniranje, saj je površina, ki jo zajamemo znotraj območja izostritve (DOF), zelo majhna. Če sliko z makro lečo 2 primerjamo s sliko z navadno lečo 1, lahko opazimo, da so podrobnosti na njej veliko jasnejše (ostre).




Slika 2: Primer posnetka narejenega z makro lečo.

Ugotovili smo, da je slikanje objektov z makro lečo prepočasno, saj v enem posnetku zajame premajhno površino objekta, z navadno pa premalo natančno za merske tipe napak. Zelo težavno je tudi prepoznavanje mehanskega tipa napak.

3.2 3D laser

Določene tipe mehanskih napak je nemogoče prepoznati vizualno, saj gre za majhne udrtine, ki so slabo vidne. Prepoznavanja takšnih napak smo se lotili s 3D senzorskim sistemom, ki ga sestavljata kamera ter laser z razpršilnikom žarka 1. Primer slike, ki nam jo poda sistem, je prikazan na 3. Sistem poleg globinske informacije poda tudi stopnjo odbojnosti (ang. reflectance), kar se lahko uporabi kot črno-belo sliko. Sistem je veliko natančnejši v primerjavi z fotoaparatom, saj dosega natančnost do 0.01mm , ponovno pa je resolucija odvisna od bližine objekta, torej za bolj natančne posnetke potrebujemo več časa.



Slika 3: Primer površine posnet s 3D laserjem. Z rumeno je označena udrtina, z modro pa šum, ki izgleda kot udrtina.


Ker nas zanima celoten 3D model objekta, je potrebno objekt pod kamero premikati, sistem pa mora dolžino premika upoštevati, ko združi slike enega posnetka v končni 3D model. To smo naredili na dva načina, prvi je z uporabo t.i. vozička, ki s pomočjo kodirnika zelo natančno prepozna dolžino premika, drugi je uporaba robotske roke, kjer se roka enakomerno pomika pod kamero.

3.3 1D laser

Za merske napake, kjer je zahtevana toleranca manjša kot 0.05mm , noben od naštetih sistemov ni dovolj natančen. Ta problem smo rešili z uvedbo novega orodja: 1D laserskega merilnika razdalje, ki je natančen do 0.005mm . Slabost sistema je, da zajema razdaljo točkovno, torej z njim ni mogoče posneti celotnega objekta, ampak le določene točke.

4 ODPRAVLJANJE ŠUMA V PODATKIH

Šum se pojavlja pri vseh omenjenih načinih merjenja. Ker so predmeti, ki jih analiziramo kovinski, se tako pri vizualnih posnetkih kot pri uporabi 3D laserskega sistema največkrat pojavljajo problemi, povzročeni zaradi odsevov in odleskov. To je posebej opazno pri 3D laserskem sistemu, saj sistem za razdaljo potrebuje tanko, koncentrirano črto laserskega žarka, ki pa se zaradi odleskov razprši, to privede do napačne ugotovitve globine na določeni točki (4).




Slika 4: Šum, ki nastane zaradi odleskov iz metalne površine

Poleg šuma zaradi odleskov je prisoten tudi splošen (Gausov) šum zaradi senzorjev samih, ta je manj problematičen, a kljub vsemu vpliva na končno natančnost, ki jo sistem lahko zagotovi.

Tretja vrsta šuma je povzročena zaradi načina meritev. To je posebej opazno, ko objekte premika robot, saj je zaradi delovanja elektromotorjev ter dolge razdalje roke od centra mogoče opaziti izrazito valovanje na sicer ravni površini opazovanega predmeta (5).

Za zmanjšanje šuma smo uporabili 2 pristopa, ki se dopolnjujeta. Prvi se navezuje na izboljšanje pogojev, v katerih so posnetki zajeti, npr.: zatemnjeno okolje, boljša svetloba, uporaba boljše robotske roke. Drugi pristop je uporaba raznoraznih metod v po-procesiranju podatkov, ki pomagajo zmanjšati šum. Najprej smo iz podatkov odstranili šum, ki nastane zaradi odsevov. Ta se največkrat pojavlja kot skupek nepovezanih točk, ki se predmeta ne držijo, to je razvidno na sliki 4. Metoda deluje po principu gručenja. Točke v objektu združuje v gruče na podlagi dinamične razdalje do težišča posamezne gruče, v kolikor je razdalja prevelika, točka tvori novo gručo. Če je v gruči premalo točk, oz. je gruča preveč oddaljena od ostalih gruč, se privzame, da gre za šum ter se točke v njej izbrišejo. Drug pristop poskuša odpraviti napake zaradi šuma na senzorju, gre za t.i. glajenje. Algoritem

se sprehodi skozi vse točke ter povpreči vrednosti v določenem radiju oz. sferi.



Slika 5: Šum, ki nastane zaradi valovanja podlage

5 PORAVNAVA OBJEKTOV

Najlažji način prepoznavanja poškodovanih oz. napačnih objektov je primerjava le teh s pravilnimi oz. nepoškodovanimi objekti. Nemogoče je pričakovati, da bosta dva objekta poravnava na desetinko natančno ob zajemanju posnetka, že samo prah, ki je prisoten v prostorih, povzroči, da se pozicija opazovanega predmeta razlikuje za nekaj milimetrov.

Metoda, ki smo jo implementirali za poravnavo dveh objektov, deluje v dveh korakih. V prvem koraku se vsako točko oz. njeno okolico opiše s t.i. značilkami [9] (teh je 33), nato se z algoritmom RANSAC [7] izbere naključne točke ter poišče njim najbližje točke na drugem objektu. Sledi korak filtriranja, ki odstrani točke, ki se preveč razlikujejo. Na podlagi izbranih točk se izračuna transformacijska matrika, ki odraža preslikavo. Točke v ciljnem objektu se nato preslikajo v nov prostor s pomočjo transformacijske matrike.

V drugem koraku, ko je objekt že grobo poravnana, sledi fina poravnava. V tem koraku se vzame manjša površina objekta, vsaki točki iz izbrane površine se poišče korespondenčna točka v ciljnem objektu, nato pa se poišče takšno transformacijo, ki minimizira razdaljo med vsemi točkami.

6 METODOLOGIJA

6.1 Primerjava

Določene tipe napak lahko ugotovimo z enostavno primerjavo poškodovanega objekta z objektom, oz. več objekti, ki niso poškodovani [2]. Tu gre predvsem za določene merske napake ter določene tipe prask in odrgnin, odvisno kje na objektu se poškodba nahaja.

Algoritem za primerjavo dveh objektov je relativno enostaven: če sta objekta poravnana, se sprehodi skozi vse točke ter preverja povprečno vrednost točk v okolici.


Določene površine zaradi svoje ukrivljenosti oz. obdelane površine niso primerne za primerjavo, saj so na njih prisotni določeni vzorci, ki niso enaki na vseh objektih, niso pa smatrani kot poškodbe.

6.2 Merjenje razdalj

Zaradi majhnih toleranc pri merjenju razdalje (dolžine) pristop s primerjavo ni primeren, saj privede do n -krat več šuma (2 objekta, napake se načeloma seštevata). Za določene površine je mogoče enostavno izmeriti razdaljo na podlagi podanih točk.

Merjenje razdalje med dvema točkama je enostavno, problem nastane zaradi šuma, saj je včasih težko določiti, kje se rob sploh


začne ter kako izbrati točke, med katerimi se bo izmerila razdalja. To rešujemo tako, da poskušamo aproksimirati premico, ki predstavlja rob. Cilj je poiskati takšno premico, ki minimizira razdaljo do vseh točk. Ker gre za premico, smo za to uporabili pristop linearne regresije [5]. Točke, ki so bile potencialno robne, pa so bile izbrane po principu naključnega izbiranja (ang. random sampling).



Slika 6: Zaradi šuma (glej notranji rob), je težko določiti, kje se objekt konča.

Opisan postopek se lahko uporabi na različnih delih objekta, pomembno je le, da znamo površino matematično opisati.

Na podoben način smo izmerili radij krožnega dela, ki nakazuje določeno napako. Zaradi načina aproksimacije krožnice ter same specifikacije skeniranja (bolj kot se laser pomika proti robu, bolj je razpršen, torej večji je šum), smo prilagodili način izbiranja točk (ang. sampling) tako, da le te niso izbrane s pomočjo Gausove metode izbiranja, ampak je bilo vzorčenje gostejše na področjih, kjer so bile meritve boljše.




Slika 7: Z linearno regresijo poiščemo takšno premico, ki minimizira razdaljo točk na robu.

6.3 Prepoznavanje prask in udrtin

Omenili smo, da se določen tip napak (npr. praske) lahko prepozna na dva načina, s pomočjo 3D skenerja ter vizualno. Preizkusili smo oba načina.

Za vizualni način prepoznavanja napak smo uporabili algoritem za prepoznavanje robov (Canny edge detector [1]). Algoritem s pomočjo odvajanja in glajenja slike ugotovi, kje na sliki se pojavljajo robovi. Načeloma se na nobeni površini, ki jih opazujemo, ne bi smeli pojavljati robovi, zato bi prepoznavale teh nakazovala na prasko, a se zaradi šuma predvsem na konveksnih predelih objekta pojavlja močan odlesk (razvidno na sliki 8), ki ga algoritem prepozna kot rob. Zaradi tega tudi pri teh primerih primerjamo pozicijo prepoznanih robov s pozicijo prepoznanih robov na objektu brez napake.



Slika 8: 3D scratch

Večina tovrstnih napak nastane zaradi mehanskih poškodb, zato so le te vidne tudi v skeniranem 3D modelu. Na sliki 3 in 8 je primer takšnega tipa poškodb. Za prepoznavanje tega tipa poškodb najprej izračunamo določene značilke, ki opisujejo posamezno točko, oz. okolico točke na modelu. Te značilke so npr. povprečna višina točk, standardni odklon, ukrivljenost, refleksija ipd. nato z uporabo odločitvenih dreves in najbližjih sosedov (kNN) model naučimo prepoznavati poškodbe na določenih površinah.

V primeru, da se poškodbe nahajajo na površinah, ki jih je relativno enostavno opisati z matematično funkcijo (ravnina, krožnica), lahko preskočimo korak s strojnimi učenjem ter na modelu direktno poiščemo območja, ki odstopajo od povprečja. Izkaže se, da je ta pristop zaradi šuma v podatkih slabši, a bi se morda izkazal za učinkovitejšega (hitrejši, natančnejši) v primeru izboljšanih posnetkov.

6.4 Prepoznavanje ožganin

Za prepoznavanje ožganin oz. drugih vizualnih napak na površinah, kjer je to mogoče (površina je dovolj homogena), se enostavno uporablja primerjava med dvema objektoma [6], [3]. V kolikor so zagotovljeni dovolj enakomerni pogoji (svetlobni), primerjava deluje zanesljivo ter zanesljivo prepozna tudi nove tipe še ne vidnih primerov napak. Ker pri teh tipih napak dve napaki nikoli ne bosta enaki (vizualno), je ta pristop primernejši od uporabe strojnega učenja, kjer bi model naučili prepoznati določeno (obliko) napake.

6.5 Rezultati

Osnovni problem, ki ga rešujemo v prispevku, je zagotavljanje kontrole kakovosti na proizvedenih izdelkih. Pomembno je, da noben izdelek z napako ni klasificiran kot pravilen (specifičnost),

obratno pa ne predstavlja velikega problema. Zato smo vse opisane pristope obtežili na iskanju napak. Povprečna specifičnost opisanih algoritmov, kjer za vsak tip napake uporabimo vse primerne pristope, dosega 95%, na (učnih) primerih, ki jih imamo na voljo.

7 ZAKLJUČEK

V prispevku smo predstavili različne pristope k prepoznavanju napak na avtomobilskih vilicah podjetja Unior. Zaradi kompleksnosti problema ter zahtevne oblike objekta, ki ga opazujemo, je objekt potrebno razbiti na več podskupin / površin, ki se analizirajo na različne načine. Na kakšen način se določena površina analizira, je odvisno od tipa napake, ki se lahko pojavi na tej površini ter same geometrije površine. Ugotovili smo, da veliko večino napak lahko prepoznavamo z zgoraj opisanimi metodami in merilnimi sistemi, ter dosežemo visoko (zadostno) specifičnost, da je pristop potencialno uporaben na proizvodnji liniji. V naslednjih korakih projekta bomo sistem testirali v poizkusni proizvodnji.

ACKNOWLEDGMENTS

Del raziskave je bil financiran s strani projekta ROB KONCEL (OP20.03530). Zahvaljujemo se vsem, ki so s svojim znanjem, predlogi in pomočjo pomagali pri nastanku te raziskave.

LITERATURA

[1] Paul Bao, Lei Zhang in Xiaolin Wu. 2005. Canny edge detection enhancement by scale multiplication. *IEEE transactions*

- on pattern analysis and machine intelligence*, 27, 9, 1485–1490.
- [2] Mario M De Gasperi, Antonio Racciu in Dario Nari. 1984. Method and apparatus for real time detection of faults in industrial objects. US Patent 4,433,385. (1984).
- [3] Vito Di Gesu in Valery Starovoitov. 1999. Distance-based functions for image comparison. *Pattern Recognition Letters*, 20, 2, 207–214.
- [4] Imke Durre, Matthew J Menne, Byron E Gleason, Tamara G Houston in Russell S Vose. 2010. Comprehensive automated quality assurance of daily surface observations. *Journal of Applied Meteorology and Climatology*, 49, 8, 1615–1633.
- [5] Douglas C Montgomery, Elizabeth A Peck in G Geoffrey Vining. 2012. *Introduction to linear regression analysis*. Zvezek 821. John Wiley & Sons.
- [6] Jean-Michel Morel in Guoshen Yu. 2009. Asift: a new framework for fully affine invariant image comparison. *SIAM journal on imaging sciences*, 2, 2, 438–469.
- [7] Ruwen Schnabel, Roland Wahl in Reinhard Klein. 2007. Efficient ransac for point-cloud shape detection. V *Computer graphics forum* številka 2. Zvezek 26. Wiley Online Library, 214–226.
- [8] John J Stapleton in Christopher Lord. 1998. Automated quality assurance image processing system. US Patent 5,832,140. (1998).
- [9] Cha Zhang in Tsuhan Chen. 2001. Efficient feature extraction for 2d/3d objects in mesh representation. V *Proceedings 2001 International Conference on Image Processing (Cat. No. 01CH37205)*. Zvezek 3. IEEE, 935–938.