

# Detekcija Napak na Industrijskih Izdelkih

## Defect Detection on Industrial Products

David Golob  
Institut Jožef Stefan  
Ljubljana, Slovenia  
david.golob@ijs.si

Janko Petrovčič  
Institut Jožef Stefan  
Ljubljana, Slovenia  
janko.petrovcic@ijs.si

Stefan Kalabakov  
Institut Jožef Stefan  
Ljubljana, Slovenia  
stefan.kalabakov@ijs.si

Primož Kocuvan  
Institut Jožef Stefan  
Ljubljana, Slovenia  
primož.kocuvan@ijs.si

Jani Bizjak  
Institut Jožef Stefan  
Ljubljana, Slovenia  
jani.bizjak@ijs.si

Gregor Dolanc  
Institut Jožef Stefan  
Ljubljana, Slovenia  
gregor.dolanc@ijs.si

Jože Ravničan  
UNIOR Kovaška industrija d.d.  
Zreče, Slovenia  
joze.ravnican@unior.com

Matjaž Gams  
Institut Jožef Stefan  
Ljubljana, Slovenia  
matjaz.gams@ijs.si

### POVZETEK

V članku predstavimo različne metode za detekcijo napak na industrijskih odkovkih. Raziskava je bila narejena v okviru projekta ROBKOCCEL. Napake, ki jih želimo zaznati, so manjši udarci ter poškodbe na struženi površini. V začetnih poskusih smo uporabili metode računalniškega vida ter metode zaznavanja napak iz tresljajev. Začetni rezultati niso zadovoljivi, vendar nekatere metode kažejo vzpodbudne rezultate, ki bi se jih dalo izboljšati s večjim naborom podatkov.

### KLJUČNE BESEDE

Detekcija napak, računalniški vid, tresljaji, industrijski izdelki

### ABSTRACT

In this paper different methods for error detection on industrial forks are presented. Part of the research was done for project ROBKONCEL. The types of errors that are detected are mostly scratches and dents on smooth metal surfaces. First a computer vision approach is used and then method for detecting errors from vibrations is discussed. Initial results are not encouraging, but could possibly be improved with larger dataset for training.

### KEYWORDS

Error detection, computer vision, vibrations, industrial products

## 1 UVOD

V zadnjem času so z napredkom strojnega učenja ter umetne inteligence napredovali tudi procesi kontrole kakovosti v industriji. Namen naše raziskave je razviti algoritem za

zaznavanje napak na industrijskih izdelkih/odkovkih za podjetje Unior d.d. Raziskave so bile narejene v okviru projekta ROBKONCEL ([1]), ki ga sofinancira Republika Slovenija iz Evropskega sklada za regionalni razvoj. Klasični pristopi, ki so uporabljeni za detekcijo napak na industrijskih objektih, temeljijo na računalniškem vidu ([2], [3], [4], [5]). V naši raziskavi uporabimo dva pristopa računalniškega vida, in sicer, detekcijo objektov (angl. »object detection«) ter segmentacijo slike (angl. »image segmentation«). Prav tako smo poskusili zaznati napake iz tresljajev izdelkov. Glede na inicialne eksperimente, ki niso dali optimalnih rezultatov, se v prihodnje usmerjamo na poskuse strojnega učenja z večjim naborom podatkov ter drugimi, konkretno laserskim čitalnikom, ki se trenutno kaže kot najbolj perspektivna možnost. Raziskave so zanimive predvsem zato, ker so pokazale določene težave v uporabi metod strojne inteligence pri delu z industrijskimi produkti.

## 2 PRISTOP RAČUNALNIŠKEGA VIDA

V tem pristopu se napake na izdelkih zaznavajo iz navadnih slik. Podani so primeri brezhibnih izdelkov in primeri z napakami, tipično poškodbami na struženi površini. Algoritmi, ki zaznavajo napake, temeljijo na podpodročju strojnega učenja, to je globokem učenju. V zadnjih nekaj letih je področje globokega učenja doseglo izjemne rezultate na področju računalniškega vida, kot npr. detekcija objektov, segmentacija slik ter klasifikacija slik. Pomanjkljivost globokega učenja je, da zahteva velik nabor učnih podatkov. V naših poskusih smo, kot rečeno, uporabili dva (pod) pristopa, to sta, detekcija objektov (angl. »object detection«) ter segmentacija slike (angl. »image segmentaion«). Nekaj primerov detekcije napak iz industrijskih

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).

izdelkih z uporabo računalniškega vida je opisanih v [2], [3], [4] ter [5].

## 2.1 Detekcija Objektov

V pristopu detekcije objektov tipično skušamo poiskati izbrani objekt (to je lahko npr. avto, pešec, kolo, prometni znak itd.). V našem problemu je izbrani objekt napaka na industrijskem odkovku. Za ta pristop smo imeli na razpolago 9 izdelkov, iz katerih smo naredili nabor 46 slik.

Nabor slik smo nato ločili na učno in testno množico. Delitev je narejena tako, da se isti izdelek ne pojavi v različnih množicah. Na vsaki sliki v učni množici je bilo potrebno ročno označiti napako/napake s pravokotniki. Ko imamo označene slike, jih lahko uporabimo za učenje globoke nevronske mreže, ki je sposobna prepoznavanja objektov (napak) v slikah.

Nevronska mreža je na začetku sestavljena iz več t.i. konvolucijskih slojev (angl. »convolution layers«), na koncu pa imamo par polno povezanih slojev (angl. »fully connected layers«). Konvolucijski sloji so sposobni kreiranja uporabnih značilk (kot npr. razni robovi in oblike na sliki), ki so nato uporabljene v polno povezanih slojih (glej sliko za primer). V primeru detekcije objektov nevronska mreža v prvem delu odkrije t.i. regije zanimanja (angl. »regions of interest«) na sliki, le te regije so v obliki pravokotnikov. Vsaka regija zanimanja je nato vhodni podatek v drugi del nevronske mreže, katere naloga je klasifikacija dane regije (glej sliko 2) V našem primeru smo uporabili že v naprej zgrajeno in naučeno nevronska mrežo, ki smo jo nato »naučili« prepoznavati naše objekte (napake). Nevronska mrežo, ki smo jo uporabili, se imenuje »Faster RCNN inception« in je bila naučena na podatkovni množici imenovani »COCO« [6]. Ta nevronska mreža je prosto dostopna ter podprta s strani python knjižnice *tensorflow* [7].

Ko imamo naučeno nevronska mrežo, klasificiramo določeno sliko kot »napako«, v primeru da mreža zazna napako z več kot 40% verjetnostjo (glej sliko 3 za primer). Tako dobimo sledeče rezultate.

**Tabela 1: Učna množica: 27 slik, 26 z napako, 1 brez.**

**Točnost: 81%, priklic: 81%, natančnost: 100%.**


TP	FP	TN	FN
21	0	1	5

**Tabela 2: Testna množica: 19 slik, 18 z napako, 1 brez.**


**Točnost: 10%, priklic: 5%, natančnost: 100%**

TP	FP	TN	FN
1	0	1	17


Opazimo, da na učni množici dobimo zadovoljivo natančnost, vendar model ni sposoben generalizacije, kar se vidi v slabih rezultatih na testni množici. Za boljše rezultate bi očitno potrebovali več slik in več različnih napak.



**Slika 1: Globoka nevronska mreža s konvolucijami, vir: [8]**



**Slika 2: Nevronska mreža za prepoznavanje objektov, vir: [9]**



**Slika 3: Detekcija napak s prepoznavanjem objektov**

## 2.2 Segmentacija Slike

V segmentaciji slike klasificiramo vsako slikovno točko v določen razred (glej sliko 4 za primer). V našem primeru imamo samo dva razreda, to sta, »napaka« in »ne-napaka«. Tudi v tem pristopu uporabimo (globoke) nevronske mreže za segmentacijo in klasifikacijo.

Za arhitekturo nevronske mreže smo uporabili arhitekturo, ki je bila uporabljena za podoben problem (glej [5] za podrobnosti). Arhitektura je vidna sliki 5. Nevronska mreža je sestavljena iz dveh delov, in sicer, segmentacijskega dela ter klasifikacijskega dela. Vhodni podatek v segmentacijski del je črno-bela slika objekta, klasifikacijski del pa ima dva vhodna podatka (tenzorja) in sicer gre za dva tenzorja iz segmentacijske mreže. Prvi tenzor je segmentacija (pomajšane) slike objekta, (na sliki 5 je označen kot »segmentation output«) to je tenzor debeline 1, kjer vsak element (ki se ga lahko predstavlja kot slikovno točko) predstavlja verjetnost napake. Drugi tenzor pa je predzadnji tenzor v segmentacijski mreži.

Izhodni tenzor za klasifikacijsko nevronska mrežo je verjetnost, ali slika vsebuje izdelek z napako, za segmentacijsko nevronska mrežo pa je segmentacija pomajšane slike objekta.

Segmentacijski del se uči ločeno od klasifikacijskega. In sicer, se uči iz ročno označenih slik segmentacije. Klasifikacijski del pa se uči iz binarnih oznak (1 pomeni, da ima objekt napako in 0 pomeni, da slika nima napake).

V tem pristopu razdelimo podatke na učno, validacijsko ter testno množico (kjer noben izdelek ne more biti v dveh množicah). Nato vsako slikovno točko v sliki označimo, kot napako ali ne-napako. To naredimo za vsako sliko v učni množici in validacijski.

Nevronska mreža nam poda segmentacijo slike ter klasifikacijo slike (glej sliko 4 za primer segmentacije slike).

Na validacijski množici smo določili število epoh za učenje mreže in sicer smo za segmentacijsko mrežo uporabili 2900 epoh in za klasifikacijsko nevronske mreže 200 epoh. Za treniranje mreže je bil uporabljen gradientni spust (angl. Gradient Descent) algoritem z parametrom hitrost učenja (angl. »learning rate«)  $10^{-3}$ .

**Tabela 3: Učna množica: 43 slik, 29 z napako, 14 brez napake. Točnost: 100%, prikljic: 100%, natančnost: 100%**

TP	FP	TN	FN
29	0	14	0

**Tabela 4: Validacijska množica: 25 slik, 21 z napako, 4 brez napake. Točnost: 64%, prikljic: 66,7%, natančnost: 87,5%**

TP	FP	TN	FN
14	2	2	7


**Tabela 5: Testna množica: 28 slik, 21 slik z napako, 7 brez napake. Točnost: 71,4%, prikljic: 81%, natančnost: 81%**

TP	FP	TN	FN
17	4	3	4


Vidimo, da se je nevronska mreža sposobna naučiti s 100% točnostjo, vendar ima, podobno kot prejšnji pristop, problem z generalizacijo.



**Slika 4: Primer segmentacije slike, vir: [10]**



**Slika 5: Arhitektura**



**Slika 6: Primer segmentacije slike. Levo: original, sredina: ročna segmentacija, desno: modelska segmentacija.**

### 3 PRISTOP S TRESLJAJI

Eden izmed "alternativnih", vendar potencialno obetavnih pristopov je analiza na osnovi oscilatornega vzbujanja pomika. Eksperiment je potekal v laboratoriju odseka E2 na IJS. Pozitiv izdelka (dejanski odkovek) smo postavili v negativ (stojalo za odkovke – glej sliko 9) ter generirali oscilatorni pomik negativa (stojala) s pomočjo generatorja vibracij. Zanimalo nas je, ali bi utegnile poškodbe izdelka na naležni površini s stojalom (negativom) kakorkoli vplivati na sklopitev med izdelkom in stojalom. V ta namen smo opazovali dva signala: vzbujevalni signal pomika stojala in izmerjeni signal pomika izdelka ter opazovali odnos med obema. Za vzbujanje pomika negativa (stojala) smo uporabili sinusni vzbujevalni signal. Meritve pomika izdelka smo opravili z laserskim merilnikom razdalje z visoko natančnostjo. Merilnik kontinuirano meri razdaljo do izdelka, ter nato z numeričnim odvajanjem izračuna hitrost, ki je izhodni signal. Za osnovni preizkus smiselnosti metode smo na enem od izdelkov simulirali napako tako, da smo na naležno površino prilepili droben kos izolacijskega traku. Izkazalo se je, da le-ta bistveno vpliva na sklop izdelek-negativ in to nam je dalo upanje, da bi utegnile tudi poškodbe naležne površine izdelka vplivati na sklopitev in s tem na relacijo med pomikom negativa in izdelka.

Posnetki meritve izhodnega signala so dolgi 10s. Meritve smo opravili pod 4 različnimi nastavitvami vhodnega signala, in sicer:


- Nastavitev 1: Amplituda: 0,389 Vpp frekvenca: 50Hz
- Nastavitev 2: Amplituda: 0,389 Vpp; frekvenca: 60Hz
- Nastavitev 3: Amplituda: 0,2026 Vpp; frekvenca: 60Hz
- Nastavitev 4: Amplituda: 0,2026 Vpp; frekvenca 50Hz

Nastavitve so bile izbrane na podlagi izhodnega signala, izkaže se, da za višje amplitude izhodni signal postane šumen.

Za ta pristop imeli na voljo 24 izdelkov.

Preizkusili smo sledeče možne pristope detekcije napak iz signalov:

- Ekspertno izbrane značilke ter uporaba klasičnih metod strojnega učenja.
- Računalniško generirane značilke ter uporaba 2-slojne nevronske mreže



**Slika 9: Meritev vibracij**

### 3.1 Ekspertno Izbrane Značilke ter Uporaba Klasičnih Metod Strojnega Učenja

V tem pristopu so značilke, uporabljane v algoritmih strojnega učenja, izbrane na podlagi dobrih izkušenj. Značilke, ki so bile izbrane, so se namreč izkazale kot dobre v drugi aplikaciji strojnega učenja. Izbranih značilk je 22 in uporabljajo osnovne značilke signala iz časovnega ter frekvenčnega spektra, npr. 3 najvišji vrhovi spektralne gostote ter njihove frekvence, energija spektralne gostote, itd.

Vsak posnetek odkovka je razdeljen na 10 kosov, kjer je vsak kos 1s dolg posnetek. Za vsak kos se nato izračuna ekspertno izbrane značilke. Tako za vsak vzorec dobimo 10 podatkovnih točk z 22 značilkami.

Uporabljen model je sestavljen iz dveh modelov. In sicer iz osnovnega ter končnega modela. Osnovni model za vsako podatkovno točko izračuna verjetnost, da ta točka pripada produktu z napako. Ker imamo za vsak produkt 10 podatkovnih točk, dobimo z osnovnim modelom 10 verjetnosti za vsak produkt. Končni model potem klasificira produkt v »odkovek z napako« ali »odkovek brez napake«. Vhodni podatek v končni model je 10 verjetnosti, dobljenih iz osnovnega modela.

Preizkusili smo več možnih algoritmov, in sicer algoritem podpornih vektorjev (angl. »support vector classifier«), algoritem naključnih gozdov, logistično regresijo, algoritem »AdaBoost« ter algoritem »XGBoost«. Te algoritme smo preizkušali tako za osnovni kot končni model.

V prvem poskusu, so bili podatki razdeljeni na učno ter testno množico. Na učni množici smo z 8 delnim prečnim preverjanjem izbrali optimalne parametre za osnovni ter končni model. Nato smo celoten model testirali na testni množici.

Uporabljena je bila nastavitvev 2 vhodnega signala, kjer je bila amplituda 0,389 Vpp s frekvenco 60 Hz.

**Osnovni model:** XGBoost

**Končni model:** Naključni gozdovi

**Tabela 6: Učna množica: 19 produktov: 12 z napako, 7 brez napake. Točnost: 100%, priklic: 100%, natančnost: 100%.**

TP	FP	TN	FN
7	0	12	0

**Table 7: Testna množica: 5 produktov: 2 z napako, 3 brez napake. Točnost: 100%, priklic: 100%, natančnost: 100%.**

TP	FP	TN	FN
3	0	2	0

Da se izognemo naključnemu dobremu rezultatu na testni množici, uporabimo še drug poskus. In sicer, uporabimo metodo prečnega preverjanja za določanje učne in testne množice. Konkretno uporabimo 5-delno prečno preverjanje, kjer so podatki razdeljeni na 5 delov. Naš postopek ima 5 iteracij, na vsaki iteraciji je en del podatkov izbran kot testna množica, ostali štirje deli pa so izbrani kot učna množica. Na vsaki iteraciji na učni množici z 8 delnim prečnim preverjanjem izberemo optimalne parametre in naučimo model na učni množici, nato pa ocenimo model na testni množici. Ker uporabljamo 5 delov, dobimo 5 ocen točnosti, priklica ter natančnosti, iz katerih nato izračunamo povprečje. (uporabljena je bila nastavitvev 2

vhodnega signala, kjer je bila amplituda 0,389 Vpp s frekvenco 60 Hz.)

Dobimo sledeče najboljše testne rezultate:

**Tabela 6: Osnovni model: logistična regresija. Končni model: AdaBoost**

Točnost	Priklic	Natančnost	F1
68 %	85 %	76 %	73 %

### 3.2 Računalniško Generirane Značilke ter Uporaba 2-slojne Nevronske Mreže

Za avtomatsko generacijo značilk smo uporabili za to namenjeno knjižnico. Pri nastavljenem parametru FDR (False Discovery Rate) na privzeto vrednost, ki je 0,05 po statističnem testu, nismo dobili nobene značilke, ki bi bila relevantna za klasifikacijo. Ker knjižnica uporablja statistično analizo za ocenjevanje relevantnosti značilk, torej ni nujno, da niso pomembne pri strojnem učenju, zato smo dvignili prag FDR na začetku na 0,5 in nato še na 0,99. Pri tem smo pri vrednosti 0,5 FDR dobili le eno značilko. Ta je 50. Fourierjev koeficient oziroma pri nastavitvi 2 in 3 smo dobili 60. Fourierjev koeficient. Slednja vrednost je seveda osnovni harmonik vzbujalnega signala. Pri nekaterih nastavitvah in pri večji vrednosti FDR smo dobili nekatere Fourierjeve koeficiente v okolici 50. in 60. koeficienta, kar je smiselno, ker je odziv odkovka različen glede na poškodbo. Zaradi tega smo sklenili, da izračunamo Fourierjeve koeficiente v okolici 50. in 60. in jih uporabimo za klasifikacijo. Hevristično smo določili, da izračunamo prvih 256 koeficientov. S tem smo zajeli vse koeficiente v okolici 50. in 60. Izračun preveliko število koeficientov pomeni, da lahko porabimo vse vire, ki so na voljo nevronske mreži, prav tako pa uradni viri [11] v tem primeru navajajo 28 x 28 točk oziroma vhodnih nevronov.

Nevronska mreža je sestavljena iz vhodne plasti, ki ima 256 nevronov, nato sledita dve skriti plasti, prva z 16 nevroni, ter druga z 8. Zadnja izhodna plast je sestavljena iz 2 nevronov, ta predstavljata poškodovan ali nepoškodovan odkovek. Takšne nastavitve smo dobili od večkratnega testiranja modela (optimizacija hiperparametrov). Za razliko od prejšnjega pristopa smo uporabili celoten 10-sekunden posnetek za izračun koeficientov.

Kot v predhodnem primeru smo na začetku uporabili optimizacijo hiperparametrov na učni množici. To pomeni, da smo z izbranimi parametri, ki so dosegli najvišjo točnost pri modelu nevronske mreže uporabili za učenje modela. Vseh 24 učnih primerov smo razdelili na učno (19 primerov) in testno (5 primerov). Uporabili smo 5-delno prečno preverjanje kot v prejšnjem primeru. Ker dobimo 5 vrednosti posameznih metrik, na koncu izračunamo povprečje.

**Tabela 7: Točnost priklic in natančnost brez F1 metrike**

Točnost	Priklic	Natančnost
48 %	42 %	91 %

## 4 ZAKLJUČEK

V tem prispevku so opisani pristopi ter modeli za detekcijo napak na industrijskih izdelkih - odkovkih.

Rezultati za detekcijo napak z uporabo računalniškega vida in segmentacije slike so se izkazali kot nezadovoljivi za praktično uporabo, kjer se zahtevata visoka točnost in priklic. Rezultati z uporabo računalniškega vida in detekcije objektov so nezadovoljivi najbrž zato, ker so napake na kovini podobne temnim lisam na kovini, ki jih je polno na odkovkih.

Rezultati za detekcijo napak z uporabo treslajev so vzpodbudni, ampak nezadovoljivi.

Glavni razlog za slabše rezultate je pomanjkanje podatkov ter zajem podatkov v nekontroliranem okolju. Menimo, da ko bo na voljo več podatkov, se bodo rezultati izboljšali.

## 5 BIBLIOGRAFIJA

- [1] „ROBKONCEL,“ SMM, January 2019. [Elektronski]. Available: [http://www.smm.si/?post\\_id=4682](http://www.smm.si/?post_id=4682). [Poskus dostopa 30 January 2020].
- [2] M. El-Agamy, M. A. Awad in H. A. Sonbol, „Automated inspection of surface defects using machine vision,“ v *17th Int. AMME Conference*, Cairo, 2016.
- [3] C. Ming , B.-C. Chen , L. G. Jacque in C. Ming-Fu, „Development of an optical inspection platform for surface defect detection in touch panel glass,“ *International Journal of Optomechatronics*, Izv. 10, št. 2, pp. 63-72, 2016.
- [4] X. Sun, J. Gu, S. Tang in J. Li, „Research Progress of Visual Inspection Technology of Steel Products—A Review,“ *Applied sciences*, Izv. 8, št. 11, 2018.
- [5] D. Tabernik, Š. Samo , J. Skvarč in D. Skočaj, „Segmentation-based deep-learning approach for surface-defect detection,“ *Journal of Intelligent Manufacturing*, 2019.
- [6] [Elektronski]. Available: <http://cocodataset.org/#home>.
- [7] Tensorflow, „Tensorflow home page,“ [Elektronski]. Available: <https://www.tensorflow.org/>. [Poskus dostopa 30 January 2020].
- [8] [Elektronski]. Available: <https://towardsdatascience.com/mnist-handwritten-digits-classification-using-a-convolutional-neural-network-cnn-af5fafbc35e9>.
- [9] U. Farooq, 15 February 2018. [Elektronski]. Available: [https://medium.com/@umerfarooq\\_26378/from-r-cnn-to-mask-r-cnn-d6367b196cfd](https://medium.com/@umerfarooq_26378/from-r-cnn-to-mask-r-cnn-d6367b196cfd).
- [10] J. Jordan, „Jeremy Jordan,“ 30 March 2018. [Elektronski]. Available: <https://www.jeremyjordan.me/evaluating-image-segmentation-models/>.
- [11] [Elektronski]. Available: <https://www.tensorflow.org/tutorials/keras/classification>. [Poskus dostopa 2019].
- [12] M. Gjoreski, S. Kalabakov, M. Luštrek in H. Gjoreski, „Cross-dataset deep transfer learning for activity recognition,“ v *Proceedings of the 2019 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2019 ACM International Symposium on Wearable Computers*, 2019.