

# Ločevanje prosene kaše od neoluščenega prosa z enorazrednim zaznavanjem anomalij

Marko Brodarič, Marija Ivanovska, Janez Perš

Fakulteta za elektrotehniko, Univerza v Ljubljani, Tržaška cesta 25, 1000 Ljubljana  
E-pošta: marko.brodaric98@gmail.com, {marija.ivanovska, janez.pers}@fe.uni-lj.si

## Abstract


In this paper we present a holistic approach for the detection of unhusked buckwheat from a pearl barley production line. Our method is based on computer vision algorithms for quality control of industrial goods in one-class learning settings. First, we build a customized system for on-site image acquisition. Captured image data is then used for the evaluation of two commonly used anomaly detection models, i.e. PaDiM and CS-Flow. In our experiments, the latter was much more efficient, as it successfully removes unwanted unhulled buckwheat, while significantly reducing the necessity for manual inspection of discarded grains.

## 1 Uvod

Kvaliteto in varnost različnih kmetijskih izdelkov regulirajo standardi, ki se nenehno nadgrajujejo, delno tudi zaradi vse večje konkurenčnosti na prehranbenem trgu. Zadostitev tem standardom z ročnim ocenjevanjem kvalitete produktov je posledično zelo drago in časovno potratno delo. Ta problem je še posebej izražen v proizvodnji žit, kjer je potrebno vso pridelano zrnje pregledati in razvrstiti. V žitih, ki so pripeljana iz polja v mlin, se namreč nahajajo številni tujki kot so pesek, prah, slama, kamni, kovinski delci, poškodovana zrna in semena plevelov. V žitu pa se nahajajo tudi zrna, ki so jih prizadeli škodljivci in bolezni, ali pa so bila fizično poškodovana med žetvijo.

Z razvojem tehnologije in razširitvijo četrte industrijske revolucije (Industrija 4.0), je umetna inteligenca postala uveljavljeno orodje za optimizacijo industrijskih procesov. Računalniški vid kot področje umetne inteligence je zlasti uporaben pri kontroli kakovosti izdelkov, kjer zagotavlja konsistenten in učinkovit nadzor proizvodnih linij. V zadnjih letih so se tako pojavili številni algoritmi, ki naslavljajo problem avtomatiziranega sortiranja in čiščenja pridelanega zrnja z različnimi slikovnimi tehnologijami. Najbolj enostavni pristopi ponavadi analizirajo RGB barve zrn, pri zaznavi njihove oblike in teksture pa si pomagajo z morfološkimi operacijami [15, 4]. Kompleksnejše metode po drugi strani temeljijo na nevronskih mrežah, ki v splošnem

Soavtorji so bili sofinancirani iz naslednjih virov ARRS: projekti J2-2506 in J2-2501 (A) ter raziskovalni programi P2-0095 in P2-0250 (B).



Slika 1: Naš sistem predstavlja holističen pristop k odstranjevanju neželenih tujkov iz pridelanih žit. Podajalnik dozira zrnje, ki se snema s kamero z namenom analize slik in detekcije neželenih vzorcev. Zaznane tujke nato lahko izločimo s pnevmatskim aktuatorjem.

delujejo veliko bolj natančno, a so obenem tudi znatno počasnejše pri obdelavi slik [16, 7].

Ne glede na način izvajanja kontrole kakovosti, je algoritem ponavadi prilagojen specifičnim zahtevam proizvodnje, v katero je bil implementiran. Tako načrtovani algoritmi v splošnem niso prenosljivi in ne delujejo na vzorcih, ki se vsaj malo razlikujejo od učnih. To predstavlja velik problem tako pri detekciji neznanih vrst zrn, kot tudi pri zaznavanju delcev smeti, saj se njihov izgled lahko spremeni.

V tem članku naslavljamo problem sortiranja pridelanega žita z namenom izločanja neželenih tujkov. Podrobneje, predstavljamo holističen pristop k ločevanju prosene kaše od neoluščenega prosa (Slika 1). V ta namen smo najprej zgradili sistem za doziranje prosa, ki simultano zajema barvne RGB slike žita. Zajete slike smo nato uporabili za razvoj algoritma za zaznavanje in lokalizacijo neoluščenih zrn. Z namenom pravočasnega in preciznega izpihovanja tujkov, pa smo v sistem vgradili tudi pnevmatske aktuatorje.

## 2 Sorodna dela

**Kontrola kakovosti zrnja.** Zagotavljanje kakovosti med pakiranjem zrnatih izdelkov v splošnem lahko

zajema razvrščanje posameznih pridelanih zrn glede na vnaprej določene kriterije kot so vrsta kulture, velikost zrn, njihova oblika itd. ali prečiščevanje produkta z izločanjem delcev smeti. Klasične metode strojnega vida v obeh primerih slonijo na analizi preprostih lastnosti kot so RGB barve delcev, njihova tekstura ali značilke izračunane z morfološkiimi operacijami [15, 4]. Bolj kompleksni algoritmi v ta namen uporabljajo tudi HOG [6] ali DSIFT [10] deskriptorje. Samo razvrščanje posameznih zrn ali detekcija tujkov se navadno izvajata z algoritmi, kot je metoda podprtih vektorjev (angl. SVM) [10] ali metoda  $k$  najbližjih sosedov (angl.  $k$ -Nearest Neighbors) [4]. Sodobni algoritmi po drugi strani temeljijo na luščenju samoučnih značilk. Ti pogosto predstavljajo različne konvolucijske nevronske mreže (angl. CNN) [16], ki zaradi izračuna bolj diskriminatorskih značilk ponavadi delujejo na principu prenosa znanja [7].


**Zaznavanje anomalij.** Računalniško podprto zaznavanje anomalij v slikah se običajno izvaja z različnimi diskriminatorskimi metodami, ki se učijo razlikovati dobre vzorce od slabih [17]. Čeprav takšne metode dosegajo zelo dobre rezultate pri evaluacijah na obstoječih primerih napak, pa natančno zaznavanje nepričakovanih odstopanj ni zagotovljeno, saj anomalije lahko s časom spreminjajo svoj izgled (obliko, barvo, teksturo itd.). Novejši, tako imenovani enorazredni pristopi, zato modelirajo le vzorce brez anomalij. Tovrstni modeli pogosto predstavljajo avtokodirnike različnih arhitektur, ki se učijo rekonstruirati le slike dobrih vzorcev [1, 9]. Napake se posledično preslikajo nepravilno, s precej večjo rekonstrukcijsko napako. Novejši pristopi poleg rekonstrukcijskega kriterija uporabljajo tudi pomožne učne naloge, kot na primer reševanje ugank [14], zapolnjevanje manjkajočih slikovnih elementov [18], ali razvrščanje vzorcev brez napak na osnovi njihovih lastnosti [2]. Z namenom luščenja čim bolj diskriminatorskih slikovnih značilk, se pogosto uporabljajo tudi prednaučene razvrševalne nevronske mreže [3, 13]. V tem primeru se namesto slik brez anomalij modelira distribucija njihovih izluščenih značilk.

### 3 Metodologija

Z namenom ločevanja prosene kaše od neoluščenega prosa smo zasnovali mehanski sistem, ki fizično upravlja z zrn in zajema slike potrebne za detekcijo neoluščenih zrn.

#### 3.1 Zajem slik

Naš sistem za zajem slik sestavljajo: 1) podajalnik zrn, 2) kamera s svetlobnimi viri in 3) aktuator za ločevanje pozitivnih in negativnih vzorcev (Slika 2). Podajalnik zrn je zgrajen iz zalogovnika, v katerem se nahajajo zrna, ki z vnaprej določeno frekvenco padajo na drčo. Drča je sestavljena iz sedmih ozkih kanalov, tako da po vsakem lahko drsi samo po eno zrno. Na koncu vsakega kanala se nahaja majhna luknjica, ki je namenjena izpihovanju zaznanih tujkov z odpiranjem pnevmatskih ventilov sapnice. Na drčo je pritrjen vibracijski zvočnik, ki skrbi za tresenje drče, tako da zrna enakomerno potujejo navzdol.



Slika 2: Sistem za zajem slik sestavljajo: podajalnik zrn, kamera in pnevmatska sapnica za ločevanje izmeta od prosene kaše. Zaradi boljše preglednosti so prikazani samo ključni deli sistema. Nosilci, pnevmatske cevi, električni vodniki ter ostale elektronske komponente so izpušeni.


Kamera za zajem slik skupaj s tremi LED svetili je trdno nameščena nad drčo, tako da je vibracije drče ne stresajo.

Pri zajemu slik za učenje algoritma za detekcijo izmeta smo najprej posneli prazno drčo. V nadaljevanju smo ločeno posneli še doziranje neoluščenega prosa ter doziranje čiste prosene kaše.

#### 3.2 Detekcija izmeta

Zajeti posnetki so bili najprej obrezani tako, da predstavljajo le območje drče brez luknjic. Z izračunom mediane posnetka prazne drče smo nato ustvarili osnovno sliko ozadja. Za lokalizacijo posameznih zrn smo to sliko odšteli od slik posnetkov zrnja. Dobljene razlike smo uprakovili, pri čemer smo za izbiro pragu uporabili Otsujevo metodo [11]. Prisoten šum uprakovljenih slik smo odstranili z zaporedno uporabo morfoloških operacij odpiranja in zapiranja s strukturnim elementom v obliki diska z radijem 5 slikovnih točk. V nadaljevanju smo, z uporabo te maske zrn, vsako zrno locirali, izrezali in shranili v obliki slike velikosti  $100 \times 100$  slikovnih točk. Posnetke smo vzorčili tako, da smo vzeli le vsako 20. sliko posnetka. Tako pridobljena baza vsebuje 24.000 slik: 14.000 učnih in 5.000 testnih vzorcev čiste prosene kaše, ter 5.000 testnih vzorcev neoluščenega prosa (izmeta). Primeri vzorcev so prikazani na Sliki 3.

Na učni bazi vzorcev smo preizkusili delovanje dveh algoritmov za enorazredno zaznavanje anomalij: PaDiM [3] in CS-Flow [13]. Obe metodi modelirata distribucijo značilk vzorcev brez napak, izluščenih s prednaučeno nevronske mreže ResNet-18 [5]. Medtem ko PaDiM modelira značilke iz treh različnih nivojev mreže, se CS-Flow osredotoča na modeliranje značilk iz najvišjega nivoja. Pri tem pa kot vhodni podatek uporablja isto sliko s tremi različnimi resolucijami (originalno velikost in dvakrat podvzorčeno). Razlikujeta se tudi v načinu modeliranja značilk. PaDiM izračuna parametre multivariatne Gaussove distribucije, CS-Flow pa v ta namen uporablja nevronske mreže za normalizacijo tokov (angl. Normalizing Flows) [12]. Obe metodi v testni fazi ocenjujeta odstopanje vhodnih vzorcev od



Slika 3: Primeri vzorcev prosene kaše: (a)-(d) in neoluščenega prosa oz. izmeta: (e)-(h). (a) prikazuje tipično zrno prosene kaše, medtem ko je (b) bolj bele barve zaradi moke poškodovanih zrn. (c) je slabše osvetljen in zato zrno barvno odstopa od tipične kaše. (d) po obliki spominja na anomalijo. Tipično anomalijo predstavljata (e) in (f). Opazimo tudi, da sta si (c) in (g) podobna in oba odstopata od tipičnih vzorcev svojega razreda. Primer (h) je po barvi podoben proseni kaši.

modelirane distribucije pravih zrn.

## 4 Eksperimenti

**Tehnične podrobnosti.** Z namenom zajema čimbolj kvalitetnih slik, smo mehanski sistem, predstavljen v pod poglavju 3.1, najprej parametrizirali. Enakomerno gibanje zrnja po drči smo zagotovili z vibracijskim zvočnikom Monacor EX-40/8, ki smo ga krmilili z zvočno kartico TDA7498, pri čemer smo uporabljali sinusni signal frekvence 44 Hz in amplitude  $-18$  dB. Drča je osvetljena s tremi LED svetili trikotno postavljenimi okrog kamere, vsako s svetilnostjo 1000 lm. Posnetke zajemamo z Raspberry Pi kamero s časom osvetlitve (angl. shutter speed)  $1/500$  s. Število slik na sekundo posnetka (angl. frame rate) smo nastavili na 11, format shranjevanja pa na MJPEG. Zaradi zajema čimbolj naravnih barv smo s parametrom za ročno izravnavo beline (angl. white balance) ojačali rdeči barvni kanal z vrednostjo 1.7, modri kanal pa z vrednostjo 1.8. Kompenzacijo osvetlitve (angl. exposure compensation) smo nastavili na  $-8$ , ker so bile v osnovi slike presvetle in smo s tem izgubili veliko informacij o barvi in obliki zrn.

Za učenje in testiranje algoritmov smo uporabljali centralno procesno enoto Intel(R) Core(TM) i9-12900K (12th Gen), 27 GB pomnilnika RAM in grafično kartico NVIDIA GeForce RTX 3090. Pri tem smo uporabljali javno dostopno kodo modelov PaDiM<sup>1</sup> in CS-Flow<sup>2</sup>.

**Evalvacija.** Oba algoritma za zaznavanje anomalij pri inferenci z določenim testnim vzorcem vrmeta verjetnost, da je ta brez anomalije (idealna vrednost verjetnosti je enaka 0), ali predstavlja anomalijo. Ker je naša testna množica uravnovešena, smo najprej uspešnost binarnega razvrščanja ovrednotili z izrisom ROC krivulje (angl. Receiver Operating Characteristic Curve)

<sup>1</sup><https://github.com/youngjae-avikus/PaDiM-EfficientNet>

<sup>2</sup><https://github.com/marco-rudolph/cs-flow>

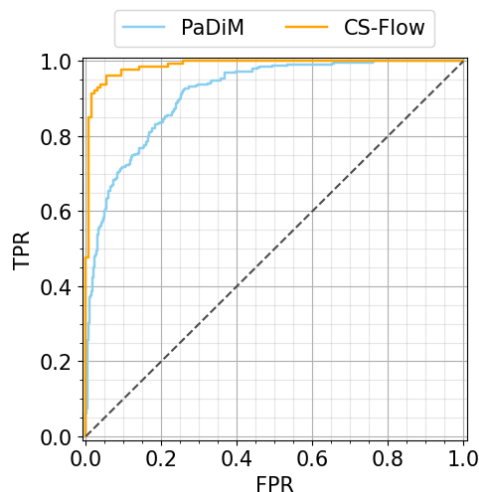
in izračunom ploščine pod to krivuljo. V praksi, se uspešnost razvrščevalnikov ocenjuje v izbrani delovni točki krivulje. Pri tem se moramo zavedati, da je število dobrih vzorcev v proizvodnjah veliko večje od števila anomalij. Iz tega razloga smo dodatno ocenili tudi uspešnost delovanja metod pri izbranem pragu verjetnostne vrednosti. V industrijskih aplikacijah imamo namreč vnaprej določen maksimalni delež nezaznanih napak med vzorci brez anomalij [8]. Poleg tega si želimo tudi čimmanj dobrih zrn med izločenim izmetom. Ob upoštevanju teh zahtev smo torej ovrednotili delež čistih zrn razvrščenih med anomalije  $FPR$  (angl. False Positive Rate). Z izbranim pragom binarnega razvrščanja dopuščamo, da je največ 1% anomalij (neoluščenih zrn) med sortirano proseno kašo:

$$\frac{FN}{TN + FP} \cdot 100\% = 1\% \quad (1)$$

kjer je  $FN$  (angl. False Negatives) število nezaznanih anomalij,  $TN$  (angl. True Negatives) število pravilno zaznanih vzorcev brez napak in  $FP$  (angl. False Positives) število dobrih vzorcev, zaznanih kot anomalije.

## 5 Rezultati

**Kvantitativna evalvacija.** Modela za ločevanje čiste prosene kaše od neoluščenega prosa smo najprej evaluirali kvantitativno. Primerjava ROC krivulj obeh algoritmov je prikazana na Sliki 4. Kot je razvidno iz grafa, binarni razvrščevalnik, ki temelji na metodi CS-Flow, deluje bolj natančno v primerjavi s PaDiM, saj doseže  $TPR = 1$  pri precej nižji vrednosti  $FPR$ .



Slika 4: ROC krivulji modelov PaDiM [3] in CS-Flow [13], generirani na testni podatkovni bazi ob preizkusu delovanja algoritmov z namenom detekcije neoluščenega prosa. Opazimo, da je delovanje binarnega razvrščevalnika, ki temelji na CS-Flow bolj natančno v primerjavi s PaDiM.

Čprav oba modela dosežeta  $AUC$  rezultat večji od 0.9, je delež čiste prosene kaše med anomalijami ob dovoljenem 1% anomalij med sortirano proseno kašo  $FPR@1\%OA$  (angl. False Positive Rate at 1% Output Anomalies) občutno višji pri metodi PaDiM (Tabela 1).




V praksi to pomeni, da gre 76.09% čistega zrnja v izmet. S tem algoritmom za avtomatizirano detekcijo anomalij smo torej delo povezano z ročnim pregledovanjem izločenega zrnja zmanjšali le za slabih 24%. CS-Flow po drugi strani zavrže le 21.88% dobrih zrn.

Metoda	AUC	FPR@1%OA [%]
PaDiM [3]	0.9139	76.09
CS-Flow [13]	0.9878	21.88

Tabela 1: Kvantitativna ocena delovanja modelov PaDiM in CS-Flow z izračunom površine pod ROC krivuljo (AUC) in izračunom deleža čiste prosene kaše med anomalijami ob 1% anomalij med čistim zrnjem (FPR@1%OA).

**Kvalitativna evalvacija.** Da bi boljše razumeli natančnost delovanja algoritma CS-Flow, smo med testnim zrnjem poiskali neuspešno zaznane primere. Izbrani vzorci so prikazani na Sliki 5. Kot je razvidno iz slike, so čista prosena zrna, ki so bila zaznana kot anomalije (Slika 5a), po obliki bolj podobna neoluščenemu zrnju. Nezaznane anomalije pa odstopajo od tipičnih anomalij tako po obliki kot tudi po teksturi in barvi (Slika 5b). Vse lažne detekcije so večkrat tudi posledica slabe osvetlitve.



Slika 5: Primeri dobrih zrn, zaznanih kot anomalije (a) in anomalij zaznanih kot dobra zrna (b). Glavni razlog za neuspešno razvrščanje vzorcev je odstopanje njihovega izgleda od tipičnih primerov razreda kateremu pripadajo.

## 6 Zaključek

Predstavili smo holističen pristop k ločevanju prosene kaše od neoluščenega prosa z enorazrednim zaznavanjem anomalij v slikah. Naši eksperimenti so pokazali, da je metoda CS-Flow zelo uspešna pri zaznavi neželenih zrn, pri čemer učinkovito zmanjša potrebo po dodatnem ročnem pregledovanju zrnja sortirano kot izmet. V prihodnosti se bomo osredotočili na razvoj lastnega algoritma, ki bi še bolj natančno zmanjšal delež lažnih napak. Razvili bomo tudi postopek izpihovanja neželenih tujkov.

## Literatura

- [1] S. Akcay, A. Atapour-Abarghouei, and T. P. Breckon. GA-Nomaly: Semi-supervised Anomaly Detection via Adversarial Training. In *Asian Computer Vision Conference (ACCV)*, pages 622–637, 2019.
- [2] L. Bergman and Y. Hoshen. Classification-Based Anomaly Detection for General Data. In *International Conference on Learning Representations (ICLR)*, pages 1–12, 2020.
- [3] T. Defard, A. Setkov, A. Loesch, and R. Audigier. PaDiM: A Patch Distribution Modeling Framework for Anomaly Detection and Localization. In *International Conference on Pattern Recognition (ICPR)*, pages 475–489, 2021.
- [4] F. Guevara-Hernandez and J. Gomez-Gil. A Machine Vision System for Classification of Wheat and Barley Grain Kernels. *Spanish Journal of Agricultural Research*, 9(3):672–680, 2011.
- [5] K. He, X. Zhang, S. Ren, and J. Sun. Deep Residual Learning for Image Recognition. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [6] N. Hong Son and N. Thai-Nghe. Deep Learning for Rice Quality Classification. In *International Conference on Advanced Computing and Applications (ACOMP)*, pages 92–96, 2019.
- [7] S. Huang, X. Fan, L. Sun, Y. Shen, and X. Suo. Research on Classification Method of Maize Seed Defect Based on Machine Vision. *Journal of Sensors*, 2019.
- [8] M. Ivanovska, J. Perš, D. Tabernik, and D. Skočaj. Evaluation of Anomaly Detection Algorithms for the Real-World Applications. In *International Conference on Pattern Recognition (ICPR)*, pages 6196–6203, 2021.
- [9] M. Ivanovska and V. Struc. Y-GAN: learning dual data representations for efficient anomaly detection. *arXiv:2109.14020*, abs/2109.14020, 2021.
- [10] M. Olgun, A. O. Onarcan, K. Özkan, Şahin Işık, O. Sezer, K. Özgüşi, N. G. Ayter, Z. B. Başçiftçi, M. Ardiç, and O. Koyuncu. Wheat Grain Classification by Using Dense Sift Features With Svm Classifier. *Computers and Electronics in Agriculture*, 122:185–190, 2016.
- [11] N. Otsu. A Threshold Selection Method From Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics (TSMC)*, 9(1):62–66, 1979.
- [12] D. J. Rezende and S. Mohamed. Variational Inference with Normalizing Flows. In *International Conference on International Conference on Machine Learning (ICML)*, page 1530–1538, 2015.
- [13] M. Rudolph, T. Wehrbein, B. Rosenhahn, and B. Wandt. Fully Convolutional Cross-Scale-Flows for Image-Based Defect Detection. In *Winter Conference on Applications of Computer Vision (WACV)*, pages 1088–1097, 2022.
- [14] M. Salehi, A. Eftekhari, N. Sadjadi, M. H. Rohban, and H. R. Rabiee. Puzzle-ae: Novelty detection in images through solving puzzles, 2020.
- [15] P. M. Szczypiński, A. Klepaczko, and P. Zapotoczny. Identifying Barley Varieties by Computer Vision. *Computers and Electronics in Agriculture*, 110:1–8, 2015.
- [16] H. O. Velesaca, R. Mira, P. L. Suárez, C. X. Larrea, and A. D. Sappa. Deep Learning based Corn Kernel Classification. In *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pages 294–302, 2020.
- [17] H. Xu, C. Caramanis, and S. Sanghavi. Robust PCA via Outlier Pursuit. *IEEE Transactions on Information Theory*, 58(5):3047–3064, 2012.
- [18] V. Zavrtnik, M. Kristan, and D. Skočaj. DRÆM – A Discriminatively Trained Reconstruction Embedding for Surface Anomaly Detection. In *International Conference on Computer Vision (ICCV)*, pages 8330–8339, 2021.