

# ZAZNAVANJE OSLONILNIH TOČK AORTNE ZAKLOPKE V CT SLIKAH S POSTOPKOM GLOBOKEGA UČENJA

LUKA ŠKRLJ,<sup>1</sup> MATIJA JELENC,<sup>2</sup> FRANJO PERNUŠ,<sup>1</sup>  
TOMAŽ VRTOVEC<sup>1</sup>

<sup>1</sup> Univerza v Ljubljani, Fakulteta za elektrotehniko, Ljubljana, Slovenia  
luka25.skrj1@gmail.com, franjo.pernus@fe.uni-lj.si, tomaz.vrtovec@fe.uni-lj.si

<sup>2</sup> Univerzitetni klinični center Ljubljana, Kirurška klinika, Klinični oddelek za kirurgijo  
srca in ožilja, Ljubljana, Slovenia  
matija.jelenc@kclj.si

**Sinopsis** Morfologija aortne zaklopke se v kardiovaskularni medicini uporablja za analizo bolezni srčnih zaklopk, za katero pa je potrebna natančna določitev značilnih anatomskih točk, tj. oslonilnih točk. V tej študiji preučujemo uporabo arhitekture globokega učenja, in sicer omrežje prostorskih konfiguracij, za zaznavanje oslonilnih točk na lističih zdrave aortne zaklopke v 120 koronarnih slikah, pridobljenih s tehniko računalniške tomografije. Na podlagi trikratnega prečnega preverjanja smo za šest oslonilnih točk, ki predstavljajo baze in komisure sinusov aortne zaklopke, z omenjeno metodo dobili povprečno napako zaznavanja  $1,45 \pm 0,82$  mm. Čeprav je dobljena natančnost primerljiva z obstoječimi metodami, bi lahko dodatne izboljšave v obliki predhodne oz. naknadne obdelave slik ali z uporabo naprednejših metodoloških konceptov izboljšale uspešnost zaznavanja oslonilnih točk.

#### **Ključne besede:**

zaznavanje  
oslonilnih točk,  
globoko učenje,  
aortna zaklopka,  
morfometrija,  
slike CT

# DEEP LEARNING-BASED AORTIC VALVE LANDMARK DETECTION IN CT IMAGES

LUKA ŠKRLJ,<sup>1</sup> MATIJA JELENC,<sup>2</sup> FRANJO PERNUŠ,<sup>1</sup>  
TOMAŽ VRTOVEC<sup>1</sup>

<sup>1</sup> University of Ljubljana, Faculty of Electrical Engineering, Ljubljana, Slovenia  
luka25.skrjl1@gmail.com, franjo.pernus@fe.uni-lj.si, tomaz.vrtovec@fe.uni-lj.si

<sup>2</sup> University Medical Center Ljubljana, Division of Surgery, Department of  
Cardiovascular Surgery, Ljubljana, Slovenia  
matija.jelenc@kclj.si

**Abstract** Aortic valve morphology is used in cardiovascular medicine to analyze the valvular heart disease, however, it requires an accurate identification of specific anatomical points, i.e. landmarks. In this study, we applied a deep learning method known as the spatial configuration network for the detection of landmarks on normal aortic cusps in 120 coronary computed tomography images. By performing three-fold cross-validation, we obtained a  $1.45 \pm 0.82$  mm mean detection error for six landmarks representing the nadirs and commissures of the aortic valve sinuses. Although the obtained accuracy is comparable to existing methods, additional improvements in the form of image pre/postprocessing or by relying on more advanced methodological concepts may result in an increase in the performance of landmark detection.

**Keywords:**

landmark  
detection,  
deep learning,  
aortic valve,  
morphometry,  
CT images

## 1 Uvod

Bolezni srčne zaklopke so vse bolj razširjene zaradi boljšega diagnosticiranja ter staranja prebivalstva, zato je njihovo zdravljenje pomembna tema kardiovaskularne medicine (Coffey in dr., 2021). Sodobno kirurško zdravljenje aortnih zaklopk zahteva temeljito morfološko razumevanje njihove tridimenzionalne (3D) anatomije (Tretter in dr., 2021), za morfološko analizo pa se kot dopolnilna tehnika slikovnega zajema uveljavlja predvsem računalniška tomografija (CT) (Tretter in dr., 2021). Izhodišče za morfologijo aortne zaklopke je natančna določitev značilnih anatomskih točk, tj. oslonilnih točk, kot so baze in komisure sinusov aortnih lističev (slika 1(a)). Ker je njihovo ročno določanje na CT slikah težavno, lahko samodejna analiza medicinskih slik zagotovi natančnejšo in zanesljivejšo morfološko analizo. Napredek na področju globokega učenja za samodejno analizo medicinskih slik je vplival tudi na področje kardiovaskularne medicine, na primer, konvolucijske nevronske mreže (CNN) (Yu in dr., 2021) so že bile uporabljene tudi za samodejno zaznavanje oslonilnih točk aortne zaklopke (Noothout in dr., 2020; Aoyama in dr., 2022). V tej študiji bomo obravnavali uporabo CNN arhitekture (Payer in dr., 2019) za zaznavanje oslonilnih točk aortne zaklopke v koronarnih CT slikah.

## 2 Metodologija

Za zaznavanje oslonilnih točk aortne zaklopke smo uporabili CNN arhitekturo, znano pod imenom omrežje prostorskih konfiguracij (Payer in dr., 2019), ki temelji na predstavitvi vsake oslonilne točke s porazdelitvijo verjetnosti, tj. toplotno sliko, in oblikovanju prostorskih konfiguracij med oslonilnimi točkami (slika 1(b)).

### 2.1 Toplotne slike oslonilnih točk


Najprej ustvarimo 3D toplotno sliko  $g_i$  za vsako  $i$ -to oslonilno točko na vsaki sliki, ki sledi Gaussovi porazdelitvi in predstavlja verjetnost, da se ta točka nahaja na trenutnem položaju (Payer in dr., 2019):

$$g_i(\mathbf{x}, \sigma_i) = \frac{\gamma}{(\sigma_i \sqrt{2\pi})^3} e^{-\frac{\|\mathbf{x} - \hat{\mathbf{x}}_i\|^2}{2\sigma_i^2}}, \quad (1)$$

kjer sta  $\mathbf{x} = (x, y, z)$  in  $\mathbf{x}_i = (x_i, y_i, z_i)$  poljubne in referenčne 3D koordinate  $i$ -te oslonilne točke,  $\|\cdot\|$  je evklidska razdalja,  $\sigma_i$  je standardni odklon Gaussove funkcije,  $\gamma$  pa parameter povečave. Za izdelavo toplotnih slik nato naučimo omrežje U-Net (Ronneberger in dr., 2015), pri čemer kot parameter uporabimo  $\sigma_i$ . Omrežje se nauči sočasno regresirati vse toplotne slike z minimizacijo izgube  $L$  med napovedano in referenčno toplotno sliko  $h_i$  oz.  $g_i$ :

$$L(\mathbf{w}, \boldsymbol{\sigma}) = \sum_{i=1}^N \|h_i(\mathbf{x}, \mathbf{w}) - g_i(\mathbf{x}, \sigma_i)\|^2 + \alpha \|\boldsymbol{\sigma}\|^2 + \lambda \|\mathbf{w}\|^2, \quad (2)$$

kjer je  $N$  število oslonilnih točk,  $\boldsymbol{\sigma} = \{\sigma_i\}$  je vektor Gaussovih standardnih odklonov za vse oslonilne točke (1),  $\mathbf{w}$  so uteži omrežja,  $\alpha$  oz.  $\lambda$  pa določata pripadajoče prispevke. Napovedane koordinate  $\mathbf{x}'_i = (x'_i, y'_i, z'_i)$  za  $i$ -to oslonilno točko pridobimo iz lokacije največje vrednosti v  $h_i$ .



Slika 1: (a) Oslonilne točke aortne zaklopke: R, L ter N – baza desnega, levega ter nekoronarnega sinusa; RLC, RNC ter LNC – komisura med desnim in levim, desnim in nekoronarnim ter levim in nekoronarnim sinusom. (b) Omrežje prostorskih konfiguracij (Payer in dr., 2019) sestoji iz komponente lokalne pojavnosti in komponente prostorske konfiguracije, z njuno združitvijo pa pridobimo končne toplotne slike.

Vir: lasten.

## 2.2 Prostorska konfiguracija

Omrežje prostorskih konfiguracij (Payer in dr., 2019) sestoji iz dveh povezanih komponent. Prva komponenta  $h_i^{LA}$  modelira lokalno pojavnost oslonilnih točk in zagotavlja lokalno natančne, vendar potencialno dvoumne napovedi, ki so podobne

Gaussovi funkciji v okolici oslonilnih točk. To doseže z večnivojsko strukturo zaporednih konvolucijskih slojev, kjer izhod na vsakem nivoju predstavlja ostanek za naslednji nižji nivo, tako da se vmesne toplotne slike postopoma izboljšujejo ob povečevanju ločljivosti, dokler se ne obnovi osnovna ločljivost. Druga komponenta  $h_i^{SC}$  modelira prostorsko konfiguracijo oslonilnih točk in razlikuje med lokalno natančnimi, vendar potencialno dvoumnimi vhodnimi toplotnimi slikami. Prostorske konfiguracije oslonilnih točk so modelirane z vrsto konvolucijskih slojev, ki implicitno vključujejo geometrijski model vseh oslonilnih točk in zagotavljajo odpornost proti napačnemu zaznavanju z omejevanjem odzivov samo na verjetne konfiguracije. Z množenjem obeh komponent po slikovnih elementih pridobimo končno toplotno sliko  $h_i = h_i^{LA} \odot h_i^{SC}$  za vsako  $i$ -to oslonilno točko.

### 3 Eksperimenti in rezultati

#### 3.1 Zbirka slik

Uporabili smo 120 koronarnih kontrastnih CT slik v končni diastolični fazi oseb z zdravimi aortnimi zaklopkami. Slike so bile pridobljene s CT napravo Somatom Force (Siemens Healthineers, Erlangen, Nemčija) in imajo velikost  $512 \times 512 \times 229\text{--}574$  slikovnih elementov, z velikostjo slikovnega elementa  $0,4 \times 0,4 \times 0,6 \text{ mm}^3$ . Z uporabo programske opreme Mimics (Materialise NV, Leuven, Belgija) je izkušeni kardiovaskularni kirurg na vsaki sliki ročno označil  $N = 6$  anatomskih oslonilnih točk aortne zaklopke (slika 1(a)), tj. baze desnega, levega ter nekoronarnega sinusa (R, L ter N) in komisure med desnim in levim, desnim in nekoronarnim ter levim in nekoronarnim sinusom (RLC, RNC ter LNC).

#### 3.2 Eksperimenti

Uporabili smo javno dostopno kodo<sup>6</sup> omrežja prostorskih konfiguracij (Payer in dr., 2019). Vrednotenje smo izvedli preko trikratnega prečnega preverjanja, torej smo v vsakem od treh eksperimentov za učenje uporabili 80 slik (66,6 %), za testiranje pa 40 slik (33,3 %). Slike so bile spremenjene na velikost  $96 \times 96 \times 128$  slikovnih elementov z velikostjo slikovnega elementa  $1 \times 1 \times 1 \text{ mm}^3$ , intenzitete pa so bile normalizirane na območje  $[-1, 1]$ . Bogatenje podatkov smo izvedli z naključnim

<sup>6</sup> <https://github.com/christianpayer/MedicalDataAugmentationTool-HeatmapRegression>

množenjem oz. premikom intenzitet za  $[0,75, 1,25]$  oz.  $[-0,25, 0,25]$  ter z naključno translacijo, rotacijo oz. povečavo za  $[-25, 25]$  slikovnih elementov,  $[-15^\circ, 15^\circ]$  oz.  $[0,5, 1,5]$ . Uporabljeno metodo globokega učenja smo nato učili preko 80.000 iteracij, napako zaznavanja  $i$ -te oslonilne točke pa vrednotili z evklidsko razdaljo  $d_i = \|\mathbf{x}'_i - \hat{\mathbf{x}}_i\|$  med napovedanimi in referenčnimi 3D koordinatami  $\mathbf{x}'_i$  oz.  $\hat{\mathbf{x}}_i$ .

**Tabela 1: Napaka zaznavanja oslonilnih točk aortne zaklopke (povprečje  $\pm$  stand. odklon).**

Oslonilna točka	Oznaka	Napaka (mm)
Baza levega sinusa	R	$1.39 \pm 0.61$
Baza desnega sinusa	L	$1.32 \pm 0.62$
Baza nekoronarnega sinusa	N	$1.27 \pm 0.83$
Komisura med levim in desnim sinusom	RLC	$1.50 \pm 0.62$
Komisura med desnim in nekoronarnim sinusom	RNC	$1.82 \pm 1.11$
Komisura med levim in nekoronarnim sinusom	LNC	$1.31 \pm 0.87$
<b>Skupaj</b>		<b><math>1.45 \pm 0.82</math></b>


### 3.3 Rezultati

Z uporabo opisanega omrežja prostorskih konfiguracij (Payer in dr., 2019) za zaznavanje  $N = 6$  oslonilnih točk aortne zaklopke smo za 120 koronarnih CT slik ob trikratnem prečnem preverjanju dobili povprečno napako zaznavanja  $1,45 \pm 0,82$  mm. Za posamezne oslonilne točke je napaka zaznavanja podana v tabeli 1, medtem ko je primer izbrane koronarne CT slike prikazan na sliki 2.

## 4 Diskusija

V tej študiji smo uporabili obstoječo arhitekturo za zaznavanje točk aortne zaklopke na koronarnih CT slikah. S hkratno optimizacijo komponent lokalne pojavnosti in prostorske konfiguracije smo problem zaznavanja oslonilnih točk razdelili na dva preprostejša podproblema (Payer in dr., 2019) ter dosegli relativno majhno napako zaznavanja baz in komisur sinusov srčne zaklopke, ki je primerljiva z obstoječimi pristopi na podlagi globokega učenja. Noothout in dr. (2020) so uporabili CNN-je za nadgradnjo približnega z bolj natančnim zaznavanjem, s čimer so dosegli mediano napake zaznavanja baz in komisur 1,87 mm za 672 koronarnih CT slik. Aoyama in dr. (2022) so isto omrežje prostorskih konfiguracij uporabili v kaskadni obliki, pri čemer so najprej izvedli približno zaznavanje in ga uporabili za segmentacijo aortne zaklopke, nato pa natančneje zaznali oslonilne točke na 138 koronarnih CT slikah

normalnih oseb in bolnikov s kalcifikacijo z napako zaznavanja baz in komisur  $1,57 \pm 1,34$  mm. V izvorni študiji o omrežju prostorskih konfiguracij so Payer in dr. (2019) poročali o napaki  $0,66 \pm 0,74$  mm pri zaznavanju 37 oslonilnih točk na 895 dvodimenzionalnih rentgenskih slikah dlani,  $0,84 \pm 0,62$  mm pri zaznavanju 28 točk na 60 3D magnetno-resonančnih (MR) slikah dlani ter  $6,2 \pm 9,9$  mm oz.  $2,9 \pm 4,4$  mm pri zaznavanju 26 oslonilnih točk na 224 oz. 60 3D CT slikah hrbtenice. V naši študiji smo dobili povprečno napako zaznavanja  $1,45 \pm 0,82$  mm za šest oslonilnih točk v 120 3D koronarnih CT slikah. V primerjavi s študijo Aoyama in dr. (2022) so naši rezultati nekoliko boljši, vendar v naši zbirki slik ni bilo bolezenskih primerov (npr. kalcifikacij). Po drugi strani pa rezultati, o katerih poročajo Payer in dr. (2019), zlasti tisti za 3D MR slike dlani, kažejo na to, da so pri uporabi predlaganega omrežja prostorskih konfiguracij še vedno mogoče izboljšave.



**Slika 2: Primer zaznavanja oslonilnih točk v čelnih prerezih CT slike: R, L ter N – baza desnega, levega ter nekoronarnega sinusa; RLC, RNC ter LNC – komisura med desnim in levim, desnim in nekoronarnim ter levim in nekoronarnim sinusom.**

Vir: lasten.

Morebitne izboljšave bi se lahko izvedle z nastavitvijo parametrov ali predobdelavo oz. poobdelavo slik, ki v tej študiji ni bila uporabljena. Naše prihodnje delo bo zato osredotočeno na segmentacijo aorte (Chen in dr., 2020), vključitev slik bolezenskih

primerov ter uporabo naprednejših mehanizmov, ki lahko pomagajo pri zaznavanju oslonilnih točk, kot je na primer spodbujevalno učenje (Bekkouch in dr., 2022).

## Opombe

To študijo je podprla Javna agencija za raziskovalno dejavnost Republike Slovenije (ARRS) v okviru projekta P2-0232.

## Literatura

- Aoyama, G., Zhao, L., Zhao, S., in dr. (2022). Automatic aortic valve cusps segmentation from CT images based on the cascading multiple deep neural networks. *Journal of Imaging*, 8, 11. doi:10.3390/jimaging8010011
- Bekkouch, I.E.I., Maksudov, B., Kiselev, S., Mustafae, T., Vrtovec, T., Ibragimov, B. (2022). Multi-landmark environment analysis with reinforcement learning for pelvic abnormality detection and quantification. *Medical Image Analysis*, 78, 102417. doi:10.1016/j.media.2022.102417
- Chen, C., Qin, C., Qiu, H., in dr. (2020). Deep learning for cardiac image segmentation: a review. *Frontiers in Cardiovascular Medicine*, 7, 25. doi:10.3389/fcvm.2020.00025
- Coffey, S., Roberts-Thomson, R., Brown, A., in dr. (2021). Global epidemiology of valvular heart disease. *Nature Reviews Cardiology*, 18, 853–864. doi:10.1038/s41569-021-00570-z
- Noothout, J.M.H., de Vos, B.D., Wolterink, J.M., in dr. (2020). Deep learning-based regression and classification for automatic landmark localization in medical images. *IEEE Transactions on Medical Imaging*, 39, 4011–4022. doi:10.1109/TMI.2020.3009002
- Payer, C., Štern, D., Bischof, H., Urschler, M. (2019). Integrating spatial configuration into heatmap regression based CNNs for landmark localization. *Medical Image Analysis*, 54, 207–219. doi:10.1016/j.media.2019.03.007
- Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional neural networks for biomedical image segmentation. V: *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*, LNCS, 9351, 234–241 (Springer). doi:10.1007/978-3-319-24574-4\_28
- Tretter, J.T., Izawa, Y., Spicer, D.E., in dr. (2021). Understanding the aortic root using computed tomographic assessment: a potential pathway to improved customized surgical repair. *Circulation: Cardiovascular Imaging*, 14, e013134. doi:10.1161/CIRCIMAGING.121.013134
- Yu, H., Yang, L.T., Zhang, Q., Armstrong, D., Deen, M.J. (2021). Convolutional neural networks for medical image analysis: state-of-the art, comparisons, improvement and perspectives. *Neurocomputing*, 444, 92–110. doi:10.1016/j.neucom.2020.04.157