

SUSTAV UPOZORENJA ZA KRETANJE I POLOŽAJ TIJELA DJETETA

Martina Rončević, Ivan Šimac, Sabrina Šuman
Veleučilište u Rijeci

C▲SE 26

Sažetak

Uvod

Motivacija i cilj rada

Prikaz rezultata rada *Sustav upozorenja za kretanje i položaj tijela djeteta*

Razvoj mobilne aplikacije

Zaključak

Uvod

Roditelji male djece često su zabrinuti za sigurnost djeteta tijekom:

- spavanja
- igre
- učenja novih pokreta

Posebno u razdoblju kada dijete:

- počinje puzati
- sjediti
- stajati
- hodati

Pametni sustavi mogu pomoći u **automatskom nadzoru i ranom upozoravanju na opasne situacije.**

C▲SE 26

Motivacija i cilj rada

Motivacija za odabir teme:

- Osobno iskustvo (prvo dijete, neiskustvo, strah)
- Profesionalno: pedagog, rad s djecom u predškolskoj ustanovi

Cilj rada bio je razviti sustav koji:

- prepoznaje **položaj tijela djeteta**
- detektira **promjene u kretanju**
- koristi **model strojnog učenja**
- šalje **obavijest roditelju putem mobilne aplikacije**

Primjena sustava:

- u kućnom okruženju
- za povećanje sigurnosti male djece.

Sustav upozorenja za kretanje i položaj tijela djeteta

Rad obuhvaća:

- izradu vlastitog skupa podataka
- anotiranje podataka
- treniranje modela YOLOv5
- analizu rezultata treniranja
- razvoj mobilne aplikacije

Postojeći sustavi za nadzor djece

Na tržištu postoje različiti sustavi za nadzor djece:

- baby monitori s kamerama
- IoT sustavi za praćenje aktivnosti
- sustavi s umjetnom inteligencijom

Većina sustava:

- samo prikazuje video
- ne analizira položaj tijela djeteta

Korištene tehnologije

U radu su korištene sljedeće tehnologije:

- računalni vid (Computer Vision)
- detekcija objekata
- YOLOv5 model
- Google Colab
- Python
- Android Studio

Ove tehnologije omogućuju **detekciju objekata u stvarnom vremenu**.

C▲SE 26

YOLOv5 model

YOLO (You Only Look Once) je model za:

- detekciju objekata
- rad u stvarnom vremenu
- visoku brzinu i točnost

Prednosti:

- brza obrada slike
- jednostavna integracija
- mogućnost treniranja na vlastitim podacima.

Dataset

Za potrebe rada izrađen je vlastiti dataset.

Dataset sadrži:

- **400 slika**
- različite pozicije djeteta
- različite uvjete snimanja

Podaci su podijeljeni na:

- train
- validation
- test

Klase u datasetu

Model prepoznaje četiri položaja tijela:

- sjedenje
- puzanje
- stajanje
- Ležanje


Svaka slika je označena **bounding box metodom**.

Anotiranje

Za anotiranje korišten je alat: **CVAT (Computer Vision Annotation Tool)**

Postupak:

1. učitavanje slika
2. označavanje objekta
3. dodavanje klase
4. generiranje labela



Slika 1. CVAT primjer anotacije
Izvor: Autor

Google Colab

Model je treniran u **Google Colab okruženju**.

Prednosti:

- besplatan GPU
- rad u cloud okruženju
- jednostavna integracija s Python bibliotekama

C▲SE 26

Postupak treniranja modela

Model je treniran u tri faze:

- 10 epoha
- 50 epoha
- 70 epoha

Cilj:

- usporediti rezultate
- pronaći optimalan broj epoha

Metode evaluacije modela

Za analizu modela korištene su metrike:

- Precision
- Recall
- mAP50
- mAP50–95
- PR krivulja
- Confusion matrix
- F1 score

Rezultati – treniranje na 10 epoha

Precision: **32.4%**

Recall: **62.2%**

Model:

- pronalazi objekte
- često ih pogrešno klasificira

Potrebna dodatna optimizacija modela


Tablica 1. Tablični prikaz rezultata osnovnih metrika modela nakon 10 epoha

Klasa	Preciznost (P)	Odziv (R)	mAP50	mAP50-95
Sve klase	32.4%	62.2%	39.9%	21.5%
Sjedenje	22.4%	68.8%	25.7%	10.3%
Puzanje	43.8%	50%	52.7%	33.5%
Stajanje	33.1%	81.2%	43.5%	20.2%
Ležanje	30.3%	49%	37.8%	21.9%

Izvor: Autor

Rezultati – treniranje na 10 epoha

Predikcije nakon 10 epoha



Izvor: Google Colab, trenirani model

C▲SE 26

Rezultati – treniranje na 50 epoha

Precision: **73%**

Recall: **73.4%**

Značajno poboljšanje:

- bolja detekcija objekata
- manje pogrešnih klasifikacija

Tablica 2. Tablični prikaz rezultata osnovnih metrika modela nakon 50 epoha

Klasa	Preciznost (P)	Odziv (R)	mAP50	mAP50-95
Sve klase	73%	73.4%	79.5%	51.3%
Sjedenje	61.6%	56.2%	68.7%	33.4%
Puzanje	77.6%	68.8%	85.2%	59.3%
Stajanje	65.4%	75%	69.1%	51.2%
Ležanje	87.4%	93.8%	94.9%	61.3%

Izvor: Autor

Rezultati – treniranje na 50 epoha

Predikcije nakon 50 epoha



Izvor: Google Colab, trenirani model

C▲SE 26

Rezultati – treniranje na 70 epoha

Precision: **62.4%**

Recall: **81.2%**

Uočeno:

- veći odziv
- pad preciznosti
- više lažno pozitivnih detekcija


Tablica 3. Tablični prikaz rezultata osnovnih metrika modela nakon 70 epoha

Klasa	Preciznost (P)	Odziv (R)	mAP50	mAP50-95
Sve klase	62.4%	81.2%	75.8%	51.1%
Sjedenje	46.1%	75%	55.4%	33.6%
Puzanje	64.9%	75%	74%	49.1%
Stajanje	70.5%	75%	74.6%	54.5%
Ležanje	68.2%	100%	99.1%	67%

Izvor: Autor

Rezultati – treniranje na 70 epoha

Predikcije nakon 70 epoha



Izvor: Google Colab, trenirani model

C▲SE 26

Usporedba rezultata

Najbolji rezultati postignuti su s:
50 epoha

Razlozi:

- optimalna ravnoteža između
 - preciznosti
 - odziva
 - stabilnosti modela

Tablica 4. Skupni prikaz rezultata nakon treniranja modela

Klasa	Broj epoha	Preciznost (P)	Odziv (R)	mAP50	mAP50-95
Sve klasa	10	32.4%	62.2%	39.9%	21.5%
	50	73%	73.4%	79.5%	51.3%
	70	62.4%	81.2%	75.8%	51.1%
Sjedenje	10	22.4%	68.8%	25.7%	10.3%
	50	61.6%	56.2%	68.7%	33.4%
	70	46.1%	75%	55.4%	33.6%
Puzanje	10	43.8%	50%	52.7%	33.5%
	50	77.6%	68.8%	85.2%	59.3%
	70	64.9%	75%	74%	49.1%
Stajanje	10	33.1%	81.2%	43.5%	20.2%
	50	65.4%	75%	69.1%	51.2%
	70	70.5%	75%	74.6%	54.5%
Ležanje	10	30.3%	49%	37.8%	21.9%
	50	87.4%	93.8%	94.9%	61.3%
	70	68.2%	100%	99.1%	67%

Izvor: Autor

C▲SE 26

Usporedba rezultata

Model uspješno prepoznaje:

- sjedenje
- puzanje
- stajanje
- ležanje

U nekim slučajevima dolazi do zbunjenosti između:

- sjedenja
- puzanja

Razvoj mobilne aplikacije

Razvijena je jednostavna aplikacija koja:

- koristi trenirani model
- analizira položaj tijela
- šalje obavijest korisniku

Tehnologije:

- Python
- Android Studio

Razvoj mobilne aplikacije



Izvor: Autor (aplikacija)



Funkcionalnosti aplikacije:

- detektira dijete na slici
- klasificira položaj tijela
- šalje obavijest roditelju

Primjena:

- nadzor djeteta u stvarnom vremenu

C▲SE 26

Poboljšanja sustava

U budućnosti sustav može uključivati:

- veći dataset
- video analizu u stvarnom vremenu
- bolju optimizaciju modela
- dodatne klase pokreta
- integraciju s pametnim kamerama

Zaključak

Razvijen je sustav koji:

- prepoznaje položaj tijela djeteta
- koristi model YOLOv5
- može upozoriti roditelje na promjene položaja

Najbolji rezultati postignuti su treniranjem modela na 50 epoha.

Rad pokazuje da računalni vid može biti koristan alat za povećanje sigurnosti djece i predstavlja dobru osnovu za daljnji razvoj pametnih sustava nadzora

Hvala na pozornosti!

C▲SE 26