

# Integracija umjetne inteligencije u medicinske sustave i inteligentne sustave vožnje

Daniel Hofman<sup>1</sup>, Martin Žagar<sup>2</sup>

<sup>1</sup>Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva, Unska 3, 10000 Zagreb

<sup>2</sup>RIT Croatia, Damira Tomljanovića Gavrana 15, 10000 Zagreb

**Sažetak:** U posljednjem desetljeću umjetna inteligencija (UI) sve se intenzivnije primjenjuje u dvjema tehnološki komplementarnim domenama: medicinskoj robotici i automobilskoj industriji. U medicinskom kontekstu, razvijen je sustav koji omogućuje kirurškom osoblju interakciju s medicinskim slikovnim prikazima putem beskontaktnih metoda upravljanja, temeljenih na prepoznavanju gesta i praćenju pokreta ruku. Opisani pristup integrira obradu DICOM podataka, računalni vid i heurističke modele stanja geste, s ciljem smanjenja rizika kontaminacije u operacijskoj dvorani te unapređenja prostornog razumijevanja anatomskih struktura primjenom tehnologija proširene i virtualne stvarnosti.

U domeni automobilske sigurnosti, razvijena je metoda detekcije mrtvog kuta temeljena na fuziji podataka širokokutnih kamera i radarskih senzora. Kombinirani pristup nadilazi sigurnosna ograničenja jednostavnijih sustava te vozaču pruža pouzdaniju situacijsku svjesnost u kritičnim prometnim situacijama.

**Cljučne riječi:** umjetna inteligencija, medicinsko slikovno procesiranje, beskontaktna interakcija, detekcija mrtvog kuta, senzorska fuzija

## 1. Uvod

U posljednjem desetljeću umjetna inteligencija (UI) prodire u dvije naizgled različite, ali po mnogim načinima komplementarne domene: medicinu i automobilsku industriju. U medicini, UI omogućuje napredne metode za vizualizaciju, planiranje i izvođenje zahvata, od precizne dijagnostike bez dodira (engl. *contactless*) do kontrole tijekom operacija. U automobilima, UI i senzorne metode podupiru sustave pomoći vozaču (ADAS) kao što su detekcija mrtvog kuta, praćenje vozila i nadzor okolnog prostora. U ovom radu prikazan je razvoj koncepta i implementacije sustava koji omogućuju kirurzima interakciju s medicinskim slikama i operativnim prikazima bez fizičkog dodira -

koristeći gestikulaciju, praćenje ruku i 3D prikaze DICOM podataka. Glavne prednosti ovog pristupa su smanjenje rizika kontaminacije u operacijskoj dvorani, mogućnost intuitivnijeg i bržeg pregleda složenih 3D struktura (npr. kod planiranja zamjene kuka) te integracija proširene/virtualne stvarnosti za bolje prostorno razumijevanje anatomije pacijenta. Kreirani modul za praćenje ruke i interpretaciju gesta omogućuje osnovne naredbe (rotacija, zum, selekcija) nad medicinskim prikazima bez fizičkog kontakta kombinirajući računalni vid, filtersku obradu signala i heurističke modele stanja geste. Ovaj rad ilustrira kako se postojeće standarde (npr. DICOM) može proširiti programskom podrškom koja UI čine dijelom kliničkog tijeka rada.

Slična se transformacija odvija i u automobilima, gdje se umjetna inteligencija postupno pretvara u ključni oslonac sigurnosti. Tijekom European Processor Initiative projekta razvijena je primjena UI na detekciju mrtvog kuta u vozilu. To je područje uz vozilo koje vozač ne može vidjeti, ali koje je redovito izvor najopasnijih prometnih situacija. Za razliku od tradicionalnih sustava koji se oslanjaju na jedan senzor, u ovom pristupu kombiniraju se širokokutne kamere i radarske jedinice, čime automobil dobiva dvostruku sigurnost pri odlučivanju. Kamere pružaju bogatstvo detalja, sposobnost prepoznavanja objekata i klasifikaciju, dok radari nude pouzdane podatke o udaljenosti i brzini drugih vozila. Kada automobil prepozna objekt u mrtvom kutu, ne radi to na temelju jedne slike ili jednog radarskog signala, već na temelju združene razumijevanja situacije. Zbog toga takav sustav nije samo tehnički dodatak vozilu, već inteligentni suradnik vozaču, upravo onakav kakvog kirurg ima u operacijskoj sali. I u jednom i u drugom slučaju UI postaje sigurnosna mreža odnosno dodatni osjet koji ljudskom oku ostaje skriven, ali koji može presudno utjecati na ishod.

Kada se pogleda u širem kontekstu, ovi primjeri otkrivaju fascinantnu srodnost među disciplinama. Kirurški zahvati i promet možda se odvijaju u različitim svjetovima, ali algoritmi koji pokreću obje domene dijele isto tehnološko srce: neuronske mreže koje prepoznaju obrasce, sustave fuzije podataka koji spajaju različite senzore, modele optimizirane za rad pod vremenskim ograničenjem i, iznad svega, potrebu za pouzdanjem u ambijentima u kojima pogreška nije dopuštena. Umjetna inteligencija u oba slučaja mora biti brza, robusna i iznimno predvidiva; mora djelovati neprimjetno, ali učinkovito; mora biti alat, a ne gospodar odluka. Zato sinergija između medicine i automobilske industrije nije slučajna.

## **2. Primjena umjetne inteligencije u medicinskim sustavima – analiza trenutnih metoda**

### **2.1 Kontekst i motivacija: od 2D prema 3D kirurškom okruženju**

Zamislite kirurga koji priprema složeni zahvat na paranazalnim sinusima. Pred njim se nalazi niz CT presjeka na ekranu. To su tanki, dvodimenzionalni slojevi anatomije

koje mora mentalno složiti u trodimenzionalnu cjelinu dok istovremeno planira svaki milimetar operacije. Upravo taj svakodnevni kognitivni napor koji se ponavlja od zahvata do zahvata predstavlja jedan od temeljnih i nedovoljno prepoznatih izvora kirurškog umora [1, 2]. Nije u pitanju nedostatak znanja ili iskustva; radi se o inherentnom nesrazmjeru između trodimenzionalne stvarnosti operativnog polja i dvodimenzionalnih alata kojima kirurg gradi svoju predodžbu o njemu. Taj jaz između percepcijskog ulaza i operativne stvarnosti izravno utječe na preciznost odlučivanja, posebice u dugotrajnim ili sekvencijalnim zahvatima.

Iz telemedicinske perspektive, ovaj problem dobiva dodatnu dimenziju. Telemedicina, u najširem smislu, podrazumijeva prijenos medicinske stručnosti bez fizičke prisutnosti liječnika. Kada se ta paradigma primijeni na kirurgiju, pojavljuje se fascinirajuća mogućnost: virtualni kirurški prostor u kojemu kirurg i rekonstruirana pacijentova anatomija koegzistiraju u istom digitalnom okruženju, neovisno o geografiji ili fizičkim ograničenjima operacijske dvorane. Integracija UI-a u ovaj prostor nije puki tehnološki dodatak, ona mijenja samu prirodu kirurškog čina, preoblikujući kirurga od operatera koji reagira na fizičke uvjete u navigatora koji aktivno upravlja digitalnim modelom anatomije.

Ovo poglavlje sustavno prolazi kroz trenutne metode koje taj prijelaz čine mogućim. Posebno se usredotočujemo na tri međusobno isprepletana područja: beskontaktno upravljanje medicinskim prikazima putem prepoznavanja gesta i praćenja pokreta ruku; obradu i vizualizaciju DICOM podataka u 3D, VR i AR okruženjima; te modele dubokog učenja koji u stvarnom vremenu interpretiraju namjere korisnika.

## **2.2 Metode praćenja pokreta ruku i prepoznavanja gesta u kirurškom okruženju**

### ***2.2.1 Evolucija pristupa: od markerskih do sustava bez markera***

Ideja da kirurg može upravljati medicinskim prikazima pokretima ruku, bez dodirivanja tipkovnice, ekrana ili sterilnog instrumentarija, nije nova. Pionirski radovi s početka 2010-ih oslanjali su se na specijalizirani hardver: Leap Motion kontroler s infracrvenim senzorima koji prate 21 anatomska točka šake s latencijom ispod 10 milisekundi, te Intel RealSense kamere koje dubinskim senzorima rekonstruiraju trodimenzionalni položaj ruku u prostoru [3, 4]. Ti su sustavi bili tehnički impresivni, no klinička primjena otkrila je njihove granice: operacijska dvorana nije laboratorij. Reflektirajuće površine sterilnog instrumentarija, varijabilno kirurško osvjetljenje, a posebno kirurške rukavice koje mijenjaju optička svojstva kože, sve je to sustavno degradiralo performanse sustava koji su u kontroliranim uvjetima funkcionirali gotovo savršeno [4, 5].

Prijelomna točka nastupila je 2020. godine kada je Google objavio MediaPipe Hands, okvir koji iz jedne obične RGB kamere ekstrahira položaj 21 anatomske točke šake, bez ikakvog specijaliziranog hardvera, primjenom konvolucijskih neuronskih mreža u dva koraka: prvo detekcija dlana, zatim precizna estimacija položaja svih ključnih točaka [6]. Ono što je ranije zahtijevalo skupi senzor, sada je radio algoritam na standardnoj kameri. Sustavna medicinska validacija provedena na Politecnico di Torino (2023) pokazala je visoku konzistentnost MediaPipe okvira sa zlatnim standardima za hvatanje pokreta, uz prosječnu prostornu pogrešku od svega 3,1 mm [7]. No ista studija jasno je ukazala i na granice: fini pokreti prstiju ostaju metodološki izazov svuda gdje je potrebna submilimetarska preciznost [7, 8].

Opsežni sustavni pregled koji su Yangi i suradnici (2025) proveli pregledom 225 radova iz baza Medline, Scopus i Embase, uključivši 77 studija koje su prošle rigorozne kriterije odabira, zorno prikazuje kako se ovo polje razvijalo: do 2017. primjena AI u praćenju kirurških instrumenata i ruku bila je rubna pojava, a od 2018. bilježi eksponencijalni rast [9]. Algoritmi dubokog učenja (62 studije) daleko su nadmašili klasične pristupe strojnog učenja (15 studija), a primjena je najčešća u općoj kirurgiji, neurokirurgiji i oftalmologiji, pretežito u laparoskopskim i robotski asistiranim zahvatima [9].

### ***2.2.2 Metode dubokog učenja za klasifikaciju gesta***

Prepoznavanje gesta u kirurškom okruženju nije samo tehnički problem, već i semantički. Nije dovoljno znati gdje se ruka nalazi u prostoru; sustav mora razumjeti što kirurg namjerava učiniti. Taj skok od detekcije k interpretaciji namjere postignut je metodama dubokog učenja koje kombiniraju podatke iz više izvora: videozapise endoskopskih kamera, kinematske podatke robotskih sustava i, u nekim pristupima, čak i elektroencefalografske signale. DiPietro i suradnici demonstrirali su da rekurentne neuronske mreže (RNN) mogu prepoznati kirurške manevre s površinom ispod ROC krivulje od 0,88 za identifikaciju i 0,87 za klasifikaciju gesta šivanja što je postignuto na stvarnim snimkama robotski asistirane radikalne prostatektomije [10]. Kiyasseh i suradnici otišli su korak dalje, treniranjem vizualnog transformatora na kirurškim videozapisima iz više ustanova za disekcijske geste ovisno o specifičnoj proceduri [11].

Pri tome su obećavajući smjer hibridne arhitekture koje MediaPipe koriste samo kao prvi sloj obrade, a zatim te podatke prosljeđuju dubokim mrežama za vremensku analizu. Jedan takav trostruki model, koji integrira MediaPipe, Inception-v3 i LSTM mrežu za klasifikaciju sekvenci, postiže značajno poboljšanje točnosti nad jednodalnim pristupima, i to uz redukciju dimenzija okvira s 1600×900 na samo 50×60 piksela, što je računalna ušteda koja u realnom kirurškom okruženju znači razliku između prihvatljive i neprihvatljive latencije [12]. Ovaj kompromis između preciznosti i brzine oduvijek je temelj kirurške informatike.

Primjer iz prakse dolazi od Wang i suradnika (2023), koji su razvili sustav ljudsko-robotske suradnje za kiruršku navigaciju temeljen isključivo na prepoznavanju gesta ruku. Njihov rad posebno se bavi problemom koji je u laboratorijskim uvjetima lako zanemariti, no u operacijskoj dvorani postaje kritičan: kako razlikovati namjernu gestu od slučajnog pokreta kirurga koji se, recimo, miče da bi uočio bolje osvjetljenje polja? Smanjenje lažnih aktivacija nije samo pitanje ergonomije, u kirurškom kontekstu neželjeni pokreti slike mogu direktno ugroziti sigurnost zahvata [13].

### **2.2.3 Ograničenja i izazovi postojećih pristupa**

Detaljno razmatranje ove domene ne može zaobići njezine otvorene probleme. MediaPipe, unatoč svim prednostima, donosi nekoliko strukturnih ograničenja koja postaju vidljiva upravo u kliničkim uvjetima. Točnost sustava dokumentirano opada pri tamnijem tonu kože korisnika, što upućuje na pristranost u skupovima podataka za treniranje i zahtijeva aktivno ulaganje u reprezentativnije podatke [8]. Nadalje, MediaPipe generira tzv. "2.5D" estimaciju: z koordinata nije direktno izmjerena, nego izvedena iz 2D projekcije. Taj korak zahtijeva naknadne matematičke korekcije, rješavanje putem Perspective-n-Point problema, koje unose dodatno kašnjenje i potencijalnu pogrešku [9]. I naposljetku, svaki generički model treniran na laboratorijskim podacima mora proći specifično fino podešavanje za klinički kontekst operacijske dvorane, što je resursno intenzivan proces koji zahtijeva suradnju između inženjera i kliničara [5, 7].

Ove nalaze potvrđuju i radovi [4, 5] gdje su razvijeni modul za praćenje ruke i interpretaciju gesta u kontekstu beskontaktno kirurgije, ali se i navodi da DLIB i MediaPipe Hands u operacijskim uvjetima pokazuju ograničenja u brzini, točnosti i stabilnosti pri varijabilnom osvjetljenju. Upravo ta klinička iskustva motivirala su razvoj nadopunjenih rješenja koja kombiniraju računalni vid s filtriranjem signala i heurističkim modelima stanja geste, pristup koji je rezultat dijaloga između laboratorijskog istraživanja i operacijske prakse.

## **2.3 Obrada DICOM podataka i 3D vizualizacija u proširenoj i virtualnoj stvarnosti**

### **2.3.1 DICOM kao temelj medicinskog digitalnog ekosustava**

DICOM (engl. *Digital Imaging and Communications in Medicine*) je standard koji stoji iza gotovo svakog medicinskog skenera, svakog bolničkog sustava za pohranu slika, svakog radiologa koji pregledava CT na ekranu. Definiira format podataka, protokole prijenosa i pravila prikaza, čineći interoperabilnost između heterogenih uređaja i ustanova mogućom. No klasična DICOM vizualizacija ostaje fundamentalno pasivna i dvodimenzionalna: kirurg lista presjeke kao stranice knjige, a trodimenzi-

onalna anatomija postoji samo u njegovoj glavi. Taj jaz između bogatstva informacija skrivenih u DICOM datotekama i načina na koji se te informacije prezentiraju kirurgu, upravo je ono što moderni AI sustavi nastoje premostiti. Naši raniji radovi pokazali su da se efikasna obrada volumetrijskih podataka postiže kompresijom 4D medicinskih podataka (prostorno-vremenska redundancija) pomoću *motion estimation* i 3D *wavelet* transformacija, čime se omogućuje brža pohrana i prijenos dinamičkih medicinskih slika potrebnih za VR/AR navigaciju [14].

Suvremene platforme poput MedicalHolodeck i Medivis SurgicalAR idu korak dalje od običnog 3D renderiranja: one integriraju DICOM podatke s naglavnih AR uređaja, npr. HoloLens 2, Magic Leap, i holografski projiciraju pacijentovu anatomiju direktno u prostor operacijske dvorane, superponiranu na operativno polje [15]. Johns Hopkins University objavio je 2021. rezultate prvih kirurških zahvata vođenih takvom AR navigacijom, a Stanford Medicine je početkom 2024. demonstrirala primjenu AR-a za vizualizaciju podataka u stvarnom vremenu za vrijeme operacije [16]. Ove kliničke implementacije nisu dokazi koncepta, one su dokazi zrelosti tehnologije.

### **2.3.2 Proširena i virtualna stvarnost u preoperativnom planiranju i intraoperativnoj navigaciji**

Virtualna i proširena stvarnost u kirurgiji prešle su dug put od svojih začetaka u kasnim 1990-ima, kada su bile rezervirane za specijalizirane istraživačke centre. Sustavni pregled *Extended Reality* (XR) u kirurgiji, objavljen 2025. godine, dokumentira kako se ta evolucija odvijala: od prvih eksperimentalnih VR simulatora prema sofisticiranim *mixed reality* sustavima koji danas pokrivaju cijeli kirurški put, od preoperativnog planiranja i intraoperativne navigacije do postoperativne rehabilitacije [17]. U ortopediji, volumetrijski modeli izvedeni iz CT podataka omogućuju planiranje točnih trajektorija implantata i rano otkrivanje anatomske varijante koje bi mogle komplicirati zahvat. Temelj za takve modele čine metode segmentacije i klasifikacije 3D objekata koje razdvajaju scenu na značajne podregije na temelju oblika, teksture i konteksta, što je ključno za preciznu rekonstrukciju u VR/AR okruženjima [18]. U neurokirurgiji, BrainLab platforma već godinama koristi MRI slike za precizno mapiranje mozga i definiranje sigurnih kirurških koridora prema dubokim lezijama [19].

Intraoperativna AR navigacija pokazala je konkretne kliničke dobiti. Molina i suradnici dokumentirali su prvu kliničku primjenu AR stereotaktičke navigacije u kirurgiji kralježnice uz visoku kliničku točnost, dok je tim sa Sveučilišta u Pennsylvaniji pokazao kako HoloLens 2 smanjuje potrebu za rendgenskim ozračivanjem pri CT-vođenom ciljanju lezija [16]. U otorinolaringologiji, disciplini koja je bila pionir čitavog ovog polja, Žagar i suradnici (2022) implementirali su beskontaktno upravljanje 3D virtualnom endoskopijom s validiranom kontrolom rotacije, zumiranja i selekcije regija interesa putem gesta, čime su spojili DICOM ekosustav s VR okruženjem na klinički upotrebljiv način [5].

Vrijedi primijetiti strukturnu srodnost koja se ovdje pojavljuje: princip koji Liu i suradnici (2024) opisuju za evoluciju kirurških robotskih sustava, AI kao posrednik između senzornih podataka i donošenja odluka, koji integrira informacije iz kamera, radarskih senzora i medicinskih slika u kohezivnu situacijsku svjesnost [21], identičan je principu koji stoji u temelju sustava za detekciju mrtvog kuta u automobilima. Ta konvergencija nije slučajna; ona odražava duboku zajedničku logiku senzorske fuzije koja prožima suvremenu primijenjenu AI.

## **2.4 Uloga umjetne inteligencije u smanjivanju kirurškog umora i kognitivnih predrasuda**

Kada su Tversky i Kahneman još 1974. godine opisali kako ljudski mozak sustavno skraćuje putove pri donošenju odluka pod nesigurnošću [21], nisu imali na umu kirurge. No gotovo pola stoljeća istraživanja potvrdilo je da su kirurzi, unatoč visokom obrazovanju i strogoj selekciji, u toj neurofiziološkoj mjeri jednako ranjivi kao i svi ostali. Armstrong i suradnici (2023) proveli su sustavni pregled koji je obuhvatio 39 studija, više od 6.500 kirurga i 200.000 pacijenata, identificirajući čak 31 različitu vrstu kognitivne predrasude u kirurškim okruženjima; najčešće su pretjerano samopouzdanje i predrasuda potvrde [22]. Saposnik i suradnici (2016) u pregledu 20 studija s ukupno 6.810 liječnika pronašli su dijagnostičke greške u svim analiziranim studijama, a terapijske greške u pet od sedam [23]. Ove brojke nisu apstrakcija, problem je u tome što iza svake brojke stoji pacijent.

Kirurški umor ove tendencije ne uzrokuje, ali ih nedvojbeno pojačava. Janhofer i suradnici (2019) opisuju umor kao višedimenzionalan fenomen, fizički, kognitivni i emotivni, i ističu posebno prirodu mentalnog umora koji nastaje iz repetitivnog prevođenja 2D slika u 3D mentalne modele: kirurg ga ne doživljava kao problem, nego kao normalan dio radnog dana [24]. Park i suradnici (2017) pokazali su u svojoj studiji da kratke ciljane pauze s istezanjem statistički značajno poboljšavaju i fizičku funkciju i mentalnu fokusiranost kirurga [1]. No, koliko god korisne bile, te pauze ne adresiraju temeljni uzrok, kognitivni mehanizam koji umor generira.

Je li moguće taj mehanizam neutralizirati samim oblikovanjem radnog okruženja? Neurofiziološki dokazi sugeriraju da jest. fMRI studija Clemente i suradnika (2013) pokazala je da osjećaj prisutnosti u virtualnom okruženju negativno korelira s aktivacijom dorzolateralnog prefrontalnog korteksa, jednog od ključnih čvorišta kognitivnog napora [25]. Drugim riječima, u 3D prostoru mozak radi drugačije, i naizgled lakše. EEG studije koje uspoređuju 3D-VR i konvencionalna 2D iskustva konzistentno pokazuju višu globalnu mrežnu učinkovitost, jače emotivno uzbuđenje i veću beta-EEG snagu u VR uvjetima, što su sve zajedno indikatori povoljnijeg kognitivnog stanja [26, 27].

Istraživanje Gangemi i suradnika (2023), provedeno na pacijentima nakon moždanog udara koji su prolazili VR kognitivni trening, otkriva još intrigantnu mogućnost: da VR okruženje aktivno potiče neuroplastičnost pri čemu je povećanje alfa snage u okcipitalnim i beta snage u frontalnim područjima dokumentirano kao znak funkcionalne reorganizacije mozga [28]. Iz toga se otvara pitanje kojim se naš tim već bavi: može li beskontaktna kirurgija u VR okruženju ne samo smanjiti umor, nego i dugoročno poboljšati kognitivne kapacitete kirurga? To nije špekulacija nego hipoteza koja zahtijeva longitudinalna istraživanja, ali koja ima solidnu fiziološku osnovu.

## 2.5 Robotski asistirani kirurški sustavi s AI integracijom: trenutno stanje

Robotska kirurgija najzrelija je grana primjene AI-a u medicini, ona ima kliničku povijest, regulatorne okvire i mjerljive ishode. Liu i suradnici (2024) u opsežnom pregledu evolucije kirurških robotskih sustava identificiraju AI integraciju kao ključni razvojni vektor koji adresira ograničenja koja su godinama bila Ahilova peta ovog polja: ograničenu autonomiju, odsutnost haptičke povratne informacije i slabu adaptabilnost na neočekivane intraoperativne situacije [20]. Meta-analiza 25 studija iz 2024. i 2025. godine kvantificira učinak AI-asistiranih robotskih operacija, 25 % skraćeno trajanje zahvata i 30 % smanjenje intraoperativnih komplikacija u usporedbi s manualnim metodama [29]. Ove su brojke dovoljno robusne da u kliničkim krugovima mijenjaju pitanje s “treba li” na “kako i kada”.

Napredniji robotski sustavi danas integriraju nekoliko AI slojeva istovremeno: računalni vid za segmentaciju tkiva i prepoznavanje kritičnih anatomskih struktura, planiranje trajektorija instrumenta, prediktivnu analitiku komplikacija i poluautonomno izvođenje pojedinih faza zahvata. Stanford University razvio je sustav koji kombinira računalni vid s algoritmima pojačanog učenja za dinamičnu prilagodbu kirurških trajektorija u stvarnom vremenu; u istraživanju s 120 operacija kralježnice postignut je pad od 42 % u vremenu postavljanja pedikulskih vijaka uz stopu komplikacija ispod 0,8 % [30]. Morris i suradnici (2024) jasno formuliraju suštinu ovog razvoja: strojni vid robotskim sustavima ne daje samo preciznost, nego im daje i situacijsku svjesnost [31].

Za telemedicinski kontekst posebno je važna priča o latenciji. Suvremene telekirurške platforme ciljaju kašnjenja ispod 10 milisekundi što je fiziološki prag ispod kojeg kirurg ne percipira razliku u odgovoru sustava. Primjena 5G mreža i *edge computing* učinila je ovaj cilj ostvarivim u urbanim sredinama, a istraživanje ga aktivno gura prema ruralnim i resursno siromašnim okruženjima. Ovi sustavi ne demokratiziraju samo pristup visokokvalitetnoj kirurškoj skrbi, nego transformiraju i sam model obrazovanja kirurga, omogućavajući iskusnim kirurzima da u stvarnom vremenu asistiraju i mentoriraju kolege na geografski udaljenim lokacijama [29, 31].

## 2.6 Sinteza: konvergentne i divergentne karakteristike trenutnih metoda

Kad sagledamo cjelinu dosad analiziranih metoda, uočavamo nekoliko jasnih silnica koje oblikuju razvoj AI-podržanih kirurških sustava. Dominira pomak od jednododalnih prema multimodalnim sustavima koji podatke iz kamera, senzora dubine, kinematskih senzora i medicinskih slika stapaju u jedinstvenu reprezentaciju kirurškog polja. Arhitekture dubokog učenja, posebno konvolucijske mreže za prostornu analizu i rekurentne ili transformatorske mreže za vremensku sekvencijalnu analizu, postale su *de facto* standard, potiskujući klasične pristupe strojnog učenja. I sve je glasnjiji zahtjev za kliničkom validacijom i regulatornom prihvatljivošću, koji zahtijeva rigorozne studije i dugotrajna longitudinalna praćenja.

Divergencije pak odražavaju specifičnosti primjene. Sustavi za beskontaktnu navigaciju stavljaju u prioritet nisku latenciju i otpornost na nepredvidive uvjete okruženja gdje se ni jedan kirurški prikaz ne smije “zamrznuti” u kritičnom trenutku. Robotski kirurški sustavi pak mogu si priuštiti nešto više računalne složenosti u zamjenu za preciznost i predvidivost u kontroliranim uvjetima. No oba smjera suočavaju se s istim temeljnim izazovom: jaz između laboratorijskih performansi i kliničke svakodnevice ne smanjuje se sam od sebe. U operacijskoj dvorani nepredvidivost je pravilo, a ne iznimka.

Guni i suradnici (2024) u European Surgical Research artikuliraju konsenzus koji se sve jasnije ocrta u literaturi: AI za kirurgiju prešla je kritičnu točku, a napredak algoritama i operacionalizacija sustava otvaraju vrata transformaciji cijelog kirurškog puta pacijenta, od rane dijagnostike do postoperativnog praćenja [32]. No možda je najvažniji zaključak ovog pregleda upravo onaj manje tehnički: sustavi koji zaista mijenjaju kliničku praksu nisu oni koji se razvijaju u izolaciji laboratorija, nego oni koji nastaju iz stvarnog dijaloga između inženjera i kirurga koji stoji pred pacijentom. Taj dijalog, s kojim je naš tim počeo još 2017. godine, i dalje je najvažniji metodološki alat koji imamo.

## 3. Primjena umjetne inteligencije u inteligentnim sustavima vožnje: analiza trenutnih metoda

### 3.1 Od asistencije do autonomije: razvojni put inteligentnih vozila

Razvoj autonomnih vozila jedan je od najambicioznijih tehnoloških razvoja suvremenog doba. Ne odvija se linearno, nego kroz postupno osvajanje razina autonomije koje je Society of Automotive Engineers (SAE) definirao skalom od 0 do 5, od potpuno ručne vožnje do potpune autonomije bez ljudske intervencije [33]. Danas su komercijalno dostupni sustavi uglavnom na razinama 2 i 3, gdje vozilo može

preuzeti kontrolu u ograničenim uvjetima, no zahtijeva stalnu vozačevu pažnju kao sigurnosnu mrežu [34]. Taj prijelaz s razine 2 na razinu 3 i dalje nije samo inženjerski problem. On je i regulatorni, etički i epistemološki: kako projektirati sustav koji zna granice vlastite pouzdanosti i koji zna kada predati kontrolu čovjeku? Upravo tu umjetna inteligencija prestaje biti puki alat obrade podataka i postaje arhitekt odluka pod nesigurnošću.

Senzorska arhitektura suvremenih autonomnih vozila tipično kombinira LiDAR, radar i kamerom bazirane sustave računalnog vida, čija se komplementarna osjetljivost na različite uvjete vidljivosti, osvjetljenja i brzine stapaju algoritmima senzorske fuzije u jedinstvenu situacijsku sliku okoline vozila [35]. Kamere pružaju gustu semantičku informaciju i fine vizualne detalje, LiDAR generira precizne 3D oblake točaka za geometrijsku rekonstrukciju scene, dok radar nudi pouzdane podatke o udaljenosti i brzini objekata u svim vremenskim uvjetima, uključujući kišu, maglu i snijeg koji degradiraju performanse ostalih senzora [35, 36].

Duboke konvolucijske neuronske mreže i transformatorski modeli preuzeli su dominantnu ulogu u obradi vizualnih podataka od detekcije i klasifikacije objekata (pješači, biciklisti, semafori, privremene prepreke) do semantičke segmentacije prometne scene u stvarnom vremenu [37, 38].

Pritom je ključni izazov koji razdvaja laboratorijsku demonstraciju od prometne primjenljivosti isti kao i u kirurgiji: sustav mora biti robustan na uvjete koji nisu zastupljeni u skupovima podataka za treniranje, uključujući neobične konfiguracije raskrižja, rijetke, ali kritične prometne situacije, te degradiranu kvalitetu senzorskog signala uslijed nepovoljnih vremenskih uvjeta [35]. Taj jaz između kontroliranih uvjeta validacije i nepredvidivosti stvarnog prometa temeljni je razlog zašto je razvoj autonomnih vozila razine 4 i 5 sporiji od ranih prognoza i zašto se fokus industrije i regulatora sve više premješta prema hibridnim pristupima koji ne eliminiraju vozača, nego mu pružaju sve sofisticiranije alate za donošenje odluka [34, 36].

### **3.2 Detekcija mrtvog kuta kao primjer primjene umjetne inteligencije u sustavima potpore vozaču**

Jedan od najilustrativnijih primjera primjene umjetne inteligencije u sustavima potpore vozaču jest detekcija mrtvog kuta koji predstavlja područja uz bočne strane vozila koje vozač ne može vidjeti ni izravno ni u retrovizorima, a koja su redovito izvor najopasnijih prometnih situacija (Slika 1).



**Slika 1:** Prikaz detekcije vozila u mrtvom kutu

U sklopu European Processor Initiative (EPI) projekta razvijen je i validiran sustav detekcije mrtvog kuta koji počiva na principu višemodalne senzorske fuzije: dvije širokokutne *fish-eye* kamere rezolucije  $1280 \times 960$  piksela, postavljene lijevo i desno od vozila, pružaju vizualnu informaciju o prometnoj situaciji, dok radarski senzori smješteni na stražnjem dijelu vozila paralelno i neovisno prate objekte u kritičnoj zoni [39]. Ključna arhitekturna odluka pritom nije bila izbor pojedinog senzora, nego upravo njihova komplementarnost: kamera pruža bogatu semantičku informaciju i omogućuje klasifikaciju objekata, dok radar osigurava pouzdane podatke o udaljenosti i brzini čak i pri nepovoljnim uvjetima vidljivosti.

Obrada slike odvija se kroz Jaguar okvir za procesiranje i detekciju objekata, koji koristi kvantiziranu i optimiziranu inačicu MobileNet-V2 arhitekture prilagođenu *fish-eye* ulazu, treniranu na Woodscape skupu podataka pri čemu je sustav postigao propusnost od 29 sličica u sekundi na GPU platformi, a nakon integracije s radarskim podacima na R-Car-H3 platformi čitavi senzorski lanac radi na razini iznad 30 sličica u sekundi, što zadovoljava zahtjeve automobilske primjene u stvarnom vremenu [39].

Taj primjer zorno ilustrira širu logiku multimodalne percepcije u autonomnoj vožnji: ni jedna senzorska modalnost sama po sebi nije dovoljna za pouzdanu situacijsku svjesnost, ali njihovom fuzijom na razini visoke apstrakcije sustav dobiva robusnost koja nadilazi mogućnosti svakog pojedinog senzora. To je analogno načelu kojim kirurški sustavi opisani u prethodnom poglavlju spajaju podatke iz kamera, dubinskih senzora i medicinskih slika u jedinstvenu reprezentaciju operativnog polja.

### 3.3 Trenutni razvojni status autonomnih vozila i perspektive komercijalizacije

Komercijalna stvarnost autonomnih vozila krajem 2025. godine zrcali isti jaz koji smo u medicinskom kontekstu opisali između laboratorijskih performansi i kliničke primjene: tehnološka mogućnost i tržišna stvarnost odvajaju se širim jazom nego što su rane prognoze sugerirale. Kompanija Waymo koja je pionir komercijalne autonomne vožnje isporučila je više od 14 milijuna vožnji u 2025. godini, tri puta više nego godinu ranije, te je operativno prisutna u 10 američkih gradova sa flotom od oko 2.500 robotaksija koji rade bez sigurnosnog vozača [40].

Taj podatak, međutim, valja staviti u perspektivu: Waymo trenutno pokriva otprilike 3 % američke populacije, unatoč više od desetljeća intenzivnog razvoja i ulaganja koja premašuju 100 milijardi dolara u čitavom sektoru [40]. Tesla slijedi bitno drukčiju strategiju sa sustavom koji se oslanja isključivo na kamere i duboke neuronske mreže umjesto skupih LiDAR senzora, no njezin pilot program u Austinu, pokrenut sredinom 2025., i dalje radi uz nazočnost sigurnosnog operatera u vozilu, što ga svrstava na razinu 2 prema SAE klasifikaciji [40].

Ta razlika u pristupu između Waymovog senzorski bogatog sustava i Teslinog vizijskog modela nije samo tehnički detalj već ona odražava temeljno različite pretpostavke o tome koje su minimalne senzorske modalnosti dostatne za sigurnu autonomnu vožnju u nepredvidivim urbanim uvjetima. Prognoza S&P Global Mobility iz prosinca 2025. snažno relativizira ambiciozne industrijske narative: američko tržište autonomnih lakih vozila dosegnut će prema njihovim procjenama oko 85.000 jedinica godišnje do 2035. godine, što odgovara udjelu od oko 0,5 % ukupne prodaje [40].

Istovremeno, AAA istraživanje provedeno početkom 2025. bilježi da 61 % američkih vozača osjeća strah, a dodatnih 26 % nesigurnost prema autonomnim vozilima [41]. Taj podatak podsjeća da tehnička robusnost sustava i javno povjerenje u njega nisu ista varijabla, baš kao što ni prihvaćanje kirurške robotike u kliničkoj zajednici nije automatski slijedilo iz tehničke izvedivosti.

Kineski sektori razvijaju se brže zahvaljujući povoljnijem regulatornom okruženju: Baiduov Apollo Go sustav dostigao je 250.000 autonomnih vožnji tjedno samo u Kini do listopada 2025., što jasno pokazuje kako regulatorna politika, a ne isključivo tehnološka zrelost, određuje brzinu komercijalizacije [40]. Sve ove silnice zajedno upozoravaju na paradoks koji karakterizira suvremeni razvoj autonomne vožnje: algoritmi su dovoljno zreli da vožnju u određenim uvjetima obavljaju sigurnije od prosječnog ljudskog vozača, ali su istodobno nedovoljno robusni za rubne slučajeve koji se u stvarnom prometu pojavljuju nepredvidivo i nerijetko.

Upravo taj jaz između demonstracijske izvrsnosti i operativne pouzdanosti ostaje ključni neriješeni problem, jednak onome s kojim se suočavaju i kirurški AI sustavi.

## 4. Zaključak

Analiza obiju primjena ukazuje na zajedničko tehnološko ishodište koje nadilazi slučajnu srodnost dviju naizgled odvojenih disciplina. I kirurški sustavi za beskontaktnu navigaciju medicinskim prikazima i sustavi za detekciju mrtvog kuta u autonomnoj vožnji dijele isti temeljni arhitekturni obrazac: duboke neuronske mreže za prepoznavanje uzoraka u vizualnim podacima, višesenzorsku fuziju koja komplementarne modalnosti spaja u jedinstvenu situacijsku predodžbu, te optimizaciju modela za rad u uvjetima strogih vremenskih ograničenja.

U oba slučaja umjetna inteligencija djeluje kao pouzdani pomoćni sustav koji povećava sigurnost bez preuzimanja autonomije u donošenju odluka. Upravo je ta ograničena, ali visoko specijalizirana uloga ključ za razumijevanje trenutne i buduće vrijednosti ovih sustava.

Konvergencija koju ovaj rad prikazuje nije samo tehnička: ona je i epistemološka. I kirurgija i autonomna vožnja suočavaju se s istim temeljnim pitanjem, a to je kako izgraditi sustav koji u ambijentima gdje pogreška nije dopuštena djeluje dovoljno brzo da bude koristan, a dovoljno oprezno da ne postane opasan.

Odgovor koji oba područja nude konvergentan je: ne potpunom autonomijom, nego hibridnim modelima u kojima umjetna inteligencija preuzima kognitivno najzahtjevnije zadatke percepcije i obrade podataka, dok konačna odgovornost za odluku ostaje na čovjeku, kirurgu koji drži skalpel ili vozaču koji prati promet.

Taj princip komplementarnosti, a ne zamjene, nije privremeni kompromis na putu prema potpunoj autonomiji: on je, prema svemu što suvremena literatura sugerira, optimalni model za primjene u kojima su posljedice pogreške ireverzibilne.

Budući razvoj u oba područja slijedi nekoliko zajedničkih vektora. Modeli će postajati više multimodalni, integrirajući sve širi spektar senzorskih ulaza i kontekstualnih informacija u jedinstvenu reprezentaciju okoline. Zahtjevi za energetskom učinkovitošću koji su posebno izraženi u ugradbenim odnosno mobilnim sustavima, potaknut će daljnju optimizaciju i specijalizaciju hardverskih platformi.

Regulatorni okviri, koji u oba područja zaostaju za tempom tehnološkog razvoja, postupno će sazrijevati i time otvarati prostor za širu kliničku i prometnu primjenu validiranih sustava. Iznimno važan, a često nedovoljno naglašen vektor je pitanje objašnjivosti: kirurg i vozač trebaju razumjeti zašto je sustav donio određenu odluku, ne samo što je ta odluka bila.

XAI (engl. *Explainable Artificial Intelligence*) pristupi, koji opravdanje za ishode modela čine interpretabilnima za ljude koji su za te ishode odgovorni, postaju stoga ne opcijskim dodatkom već regulatornim i etičkim preduvjetom primjene u visokokritičnim domenama.

Konačno, iskustvo koje ovaj rad sintetizira sugerira metodološku pouku koja nadilazi oba konkretna slučaja: sustavi umjetne inteligencije koji zaista mijenjaju praksu nisu oni koji nastaju iz čiste tehničke izvrsnosti, nego oni koji nastaju iz dijaloškog procesa između inženjera koji razumiju mogućnosti i praktičara koji razumiju potrebe. Beskontaktna kirurgija razvijena je u dijalogu s otorinolaringolozima dok je detekcija mrtvog kuta validirana na stvarnom BMW X5 testnom vozilu u realnim prometnim uvjetima.

Oba puta vode do iste spoznaje: umjetna inteligencija nije cilj sam sebi, nego sredstvo kojim stručnjaci, primjerice kirurzi i vozači, liječnici i inženjeri, mogu djelovati preciznije, sigurnije i s većom sigurnošću da će njihove odluke biti podržane najboljim raspoloživim znanjem o situaciji u kojoj se nalaze.

## 5. Literatura

- [1] Park, A.E.; Zahiri, H.R., Hallbeck, M.S., Augenstein, V., Sutton, E., Yu, D., Lowndes, B. R., Bingener, J.: Intraoperative Micro Breaks With Targeted Stretching Enhance Surgeon Physical Function and Mental Focus: A Multicenter Cohort Study, *Annals of Surgery*, **265** (2017) 2, 340-346, <https://doi.org/10.1097/SLA.0000000000001665>
- [2] Žagar, M.; Klapan, I., Mutka, A., Majhen, Z.: Contactless Interface for Navigation in Medical Imaging Systems, *Intelligent Systems and Applications. IntelliSys 2021. Lecture Notes in Networks and Systems*, **295** (2022), [https://doi.org/10.1007/978-3-030-82196-8\\_3](https://doi.org/10.1007/978-3-030-82196-8_3)
- [3] Marin, G.; Dominio F., Zanuttigh P.: Hand Gesture Recognition with Leap Motion and Kinect Devices, *Proc IEEE Int Conf Image Processing (ICIP)*, (2014) 1565-1569, <https://doi.org/10.1109/ICIP.2014.7025313>
- [4] Žagar, M.; Mutka, A., Klapan, I., Majhen, Z.: Hand and gesture module for enabling contactless surgery, *Trends in Telemed & e-Health*, **3** (2021) 1, 1-5, <https://doi.org/10.31031/TTEH.2021.03.000553>
- [5] Žagar, M.; Klapan, I., Mutka, A., Majhen, Z.: Implementation Details for Controlling Contactless 3D Virtual Endoscopy, *Applied Sciences (MDPI)*, **12** (2022) 11, 5757, <https://doi.org/10.3390/app12115757>
- [6] Zhang, F.; Bazarevsky, V., Vakunov, A., Tkachenka, A., Sung, G., Chang, C., Grundmann, M.: MediaPipe Hands: On-device real-time hand tracking, (2020), arXiv:2006.10214 [cs.CV], <https://doi.org/10.48550/arXiv.2006.10214>
- [7] Amprimo, G.; Masi, G., Pettiti, G., Olmo, G., Priano, L., Ferraris, C.: Hand tracking for clinical applications: validation of the Google MediaPipe Hand (GMH) and the depth-enhanced GMH-D frameworks, *Biomed Signal Process Control*, **96** (2024) 106508, <https://doi.org/10.1016/j.bspc.2024.106508>
- [8] Budzinski, C.; Wu, H., Sarraf, E., Miller, S., Moore, J.: Accuracy of Mediapipe Visual Hand Tracking for use in Medical Training Procedures, *Proc ASME Design of Medical Devices Conf.*, (2024), V001T08A004, <https://doi.org/10.1115/DMD2024-1039>

- [9] Yangi K.; On, T.J., Xu, Y., Gholami, A.S., Hong, J., Reed, A.G., Puppalla, P., Chen, J., Tangsrivimol, J.A., Li, B., Santello, M., Lawton, M.T., Preul, M.C.: Artificial intelligence integration in surgery through hand and instrument tracking: a systematic literature review, *Front. Surg.*, **12** (2025) 1528362, <https://doi.org/10.3389/fsurg.2025.1528362>
- [10] DiPietro, R.; Ahmidi, N., Malpani, A., Waldram, M., Lee, G. I., Lee, M. R., Vedula, S. S., Hager, G. D.: Segmenting and classifying activities in robot-assisted surgery with recurrent neural networks, *International Journal of Computer Assisted Radiology and Surgery*, **14** (2019) 11, 2005-2020, <https://doi.org/10.1007/s11548-019-01953-x>
- [11] Kiyasseh, D.; Ma, R., Haque, T. F., Miles, B. J., Wagner, C., Donoho, D. A., Anandkumar, A., Hung, A. J.: A vision transformer for decoding surgeon activity from surgical videos, *Nature Biomedical Engineering*, **7** (2023) 6, 780-796, <https://doi.org/10.1038/s41551-023-01010-8>
- [12] Yaseen; Kwon, O.J., Kim, J., Jamil, S., Lee, J., Ullah, F.: Next-Gen Dynamic Hand Gesture Recognition: MediaPipe, Inception-v3 and LSTM-Based Enhanced Deep Learning Model, *Electronics*, **13** (2024) 16, 3233, <https://doi.org/10.3390/electronics13163233>
- [13] Wang, J.; Zhang, X., Chen, X., Song, Z.: A touch-free human-robot collaborative surgical navigation robotic system based on hand gesture recognition, *Frontiers in Neuroscience*, **17** (2023) 1171233, <https://doi.org/10.3389/fnins.2023.1200576>
- [14] Žagar, M.; Kovač, M., Hofman, D.: Framework for 4D medical data compression, *Tehnički vjesnik*, **19** (2012) 1, 99-105, <https://hrcak.srce.hr/79164>
- [15] MedicalHolodeck: Medical AI, auto segmentation, surgical planning, and medical education in AR/VR, *Dostupan na:* <https://www.medicalholodeck.com>, *Pristupljeno:* 2026-03-01
- [16] Molina, C.A.; Sciubba, D.M., Greenberg, J.K., Khan, M., Witham, T.: Clinical Accuracy, Technical Precision, and Workflow of the First in Human Use of an Augmented-Reality Head-Mounted Display Stereotactic Navigation System for Spine Surgery, *Operative Neurosurgery*, **20** (2021) 3, 300-309, <https://doi.org/10.1093/ons/opaa398>
- [17] Yujia, G.: Extended reality in surgery - past, present, and future, *Surgery (Oxford)*, **43** (2025) 3, 140-145, <https://doi.org/10.1016/j.mpsur.2024.12.003>
- [18] Žagar, M.; Kovač, M., Knezović, J., Mlinarić, H., Hofman, D.: 3D Object Classification and Segmentation Methods, *High-Quality Visual Experience*, Springer, Berlin, Heidelberg, (2010) 331-347, [https://doi.org/10.1007/978-3-642-12802-8\\_14](https://doi.org/10.1007/978-3-642-12802-8_14)
- [19] Klapan, I.; Majhen, Z., Žagar, M., Trampuš, Z., Klapan, L., Berlengi, N., Zemba, M., Ljubičić, A., Ešler, M.: Utilization of 3-D medical imaging and touch-free navigation in endoscopic surgery, *Biomedical Journal of Scientific & Technical Research*, **22** (2019) 1, 16336-16344, <https://doi.org/10.26717/bjstr.2019.22.003691>
- [20] Liu, Y.; Wu, X., Sang, Y., Zhao, C., Wang, Y., Shi, B., Fan, Y.: Evolution of Surgical Robot Systems Enhanced by Artificial Intelligence: A Review, *Advanced Intelligent Systems*, **6** (2024) 5, 2300268, <https://doi.org/10.1002/aisy.202300268>
- [21] Tversky, A.; Kahneman, D.: Judgment under Uncertainty: Heuristics and Biases, *Science*, **185** (1974) 4157, 1124-1131
- [22] Armstrong, B.A.; Dutescu, I.A., Tung, A., Carter, D.N., Trbovich, P.L., Wong, S., Saposnik, G., Grantcharov, T.: Cognitive biases in surgery: systematic review, *British Journal of Surgery*, **110** (2023) 6, 645-654, <https://doi.org/10.1093/bjs/znad004>

- [23] Saposnik, G.; Redelmeier, D., Ruff, C.C., Tobler, P.N.: Cognitive biases associated with medical decisions: a systematic review, *BMC Medical Informatics and Decision Making*, **16** (2016) 1, 138, <https://doi.org/10.1186/s12911-016-0377-1>
- [24] Janhofer, D.E.; Lakhiani, C., Song, D.H.: Addressing surgeon fatigue: Current understanding and strategies for mitigation, *Plastic and Reconstructive Surgery*, **144** (2019) 693-699, <https://doi.org/10.1097/PRS.0000000000006075>
- [25] Clemente, M.; Rey, B., Rodriguez-Pujadas, A., Barros-Loscertales, A., Baños, R.M., Botella, C., Alcañiz, M., Ávila, C.: An fMRI Study to Analyze Neural Correlates of Presence during Virtual Reality Experiences, *Interacting with Computers*, **26** (2014) 3, 269-284, <https://doi.org/10.1093/iwc/iwt037>
- [26] Yu, M.; Li, Y., Tian, F.: Responses of functional brain networks while watching 2D and 3D videos: An EEG study, *Biomedical Signal Processing and Control*, **68** (2021) 102613, <https://doi.org/10.1016/j.bspc.2021.102613>
- [27] Tian, F.; Hua, M., Zhang, W., Li, Y., Yang, X.: Emotional arousal in 2D versus 3D virtual reality environments, *PLoS ONE*, **16** (2021) 9, e0256211, <https://doi.org/10.1371/journal.pone.0256211>
- [28] Gangemi, A.; De Luca, R., Fabio, R. A., Lauria, P., Rifichi, C., Pollicino, P., Marra, A., Olivo, A., Quartarone, A., Calabrò, R. S.: Effects of Virtual Reality Cognitive Training on Neuroplasticity: A Quasi-Randomized Clinical Trial in Patients with Stroke, *Biomedicines*, **11** (2023) 12, 3225, <https://doi.org/10.3390/biomedicines11123225>
- [29] Wah, J.N.K.: The rise of robotics and AI-assisted surgery in modern healthcare, *Journal of Robotic Surgery*, **19** (2025) 1, 311, <https://doi.org/10.1007/s11701-025-02485-0>
- [30] Han, F.; Huang, X., Wang, X., Chen, Y. F., Lu, C., Li, S., Lu, L., Zhang, D. W.: Artificial Intelligence in Orthopedic Surgery: Current Applications, Challenges, and Future Directions, *MedComm*, **6** (2025) 7, e70260, <https://doi.org/10.1002/mco2.70260>
- [31] Morris, M.X.; Fiocco, D., Caneva, T., Yiapanis, P., Orgill, D.P.: Current and future applications of artificial intelligence in surgery: implications for clinical practice and research, *Frontiers in Surgery*, **11** (2024) 1393898, <https://doi.org/10.3389/fsurg.2024.1393898>
- [32] Guni, A.; Varma, P., Zhang, J., Fehervari, M., Ashrafiyan, H.: Artificial Intelligence in Surgery: The Future is Now, *European Surgical Research*, **65** (2024) 1, 22-39, <https://doi.org/10.1159/000536393>
- [33] SAE International: Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles, SAE Standard J3016, (2021), *Dostupan na*: [https://www.sae.org/standards/j3016\\_202104-taxonomy-definitions-terms-related-driving-automation-systems-road-motor-vehicles](https://www.sae.org/standards/j3016_202104-taxonomy-definitions-terms-related-driving-automation-systems-road-motor-vehicles), *Pristupljeno*: 2026-03-01
- [34] Yeong, D.J.; Panduru, K., Walsh, J.: Exploring the Unseen: A Survey of Multi-Sensor Fusion and the Role of Explainable AI (XAI) in Autonomous Vehicles, *Sensors*, **25** (2025) 3, 856, <https://doi.org/10.3390/s25030856>
- [35] Qian H.; Wang M., Zhu M., Wang H.: A Review of Multi-Sensor Fusion in Autonomous Driving, *Sensors*, **25** (2025) 19, 6033, <https://doi.org/10.3390/s25196033>

- [36] Wu, D.; Yang, F., Xu, B., Liao, P., Liu, B.: A Survey of Deep Learning Based Radar and Vision Fusion for 3D Object Detection in Autonomous Driving, *arXiv Computer Vision and Pattern Recognition*, (2024), <https://doi.org/10.48550/arXiv.2406.00714>
- [37] Elhassan, M.A.M.; Zhou, C., Khan, A., Benabid, A., Adam, A.B.M., Mehmood, A., Wambugu, N.: Real-time semantic segmentation for autonomous driving: A review of CNNs, Transformers, and Beyond, *Journal of King Saud University - Computer and Information Sciences*, **36** (2024) 10, 10226, <https://doi.org/10.1016/j.jksuci.2024.102226>
- [38] Contreras, A.; Jain, A., Bhatt, P., Banerjee, N., Hashemi, E.: A survey on 3D object detection in real time for autonomous driving, *Frontiers in Robotics and AI*, **11** (2024) 1212070, <https://doi.org/10.3389/frobt.2024.1212070>
- [39] Hofman, D.; Brcic, M., Kovac, M., Hotfilter, T., Becker, J., Reinhardt, D., Grigorescu, S. M., Stevens, R., Vo, T. T.: European Processor Initiative Demonstration of Integrated Semi-Autonomous Driving System, 2023 IEEE 36th International System-on-Chip Conference (SOCC) proceedings, Andrew Marshall, 1.-6., Santa Clara, 2023, Institute of Electrical and Electronics Engineers (IEEE), <https://doi.org/10.1109/socc58585.2023.10257105>
- [40] S&P Global Mobility. Autonomous ride-hailing grows in key US markets. Automotive Insights Blog, *Dostupan na*: <https://www.spglobal.com/automotive-insights/en/blogs/2025/12/autonomous-ride-hailing-grows-key-us-markets>, *Pristupljeno*: 2026-03-01
- [41] Brittany Moyer. 2025. AAA: Fear in Self-Driving Vehicles Persists. AAA, *Dostupan na*: <https://newsroom.aaa.com/2025/02/aaa-fear-in-self-drivingvehicles-persists/>, *Pristupljeno*: 2026-03-01