



Značaj vizualnih tehnologija za praćenje progresu i procjene produktivnosti zemljanih radova

Prethodno priopćenje/ Preliminary communication

Primljen/Received: 5. 5. 2018.;

Prihvaćen/Accepted: 1. 6. 2018.

Martina Šopić, mag.ing.aedif.

Sveučilište u Rijeci, Građevinski fakultet

izv.prof.dr.sc. Mladen Vukomanović

Sveučilište u Zagrebu, Građevinski fakultet

prof.dr.sc. Diana Car-Pušić

Sveučilište u Rijeci, Građevinski fakultet

Sažetak: Praćenje progresu izvedbe zemljanih radova uz točnu procjenu produktivnosti građevinskih strojeva omogućuje detaljan uvid u tijek izvedbe, ranu detekciju slabe produktivnosti, kao i svih ostalih mogućih nedostataka, povratnu informaciju ispravnosti donesnih odluka te precizniji iskaz potrebnog vremena i troška aktivnosti. Ranim uočavanjem, i alarmiranjem, svih rizičnih, nepovoljnih radnji, pružene su mogućnosti za pravodobno poduzimanje odgovarajućih, korektivnih mjera i provedbu poboljšanja. Bežične tehnologije pružaju znatan potencijal za primjenu u svrhu praćenja progresu rada i procjene produktivnosti. Međutim, dosadašnja istraživanja ukazuju na nedostatke i ograničenja. Potrebna su daljnja istraživanja njihovih velikih potencijala, a moguće rješenje problematike i kompleksnosti u praćenju progresu rada i procjene produktivnosti predstavlja integracija različitih bežičnih tehnologija. Vizualne tehnologije su, pritom, neizostavno područje bežičnih tehnologija za razvoj odgovarajuće, pouzdane, vjerodostojne, brze i ekonomične metodologije za praćenje progresu izvedbe zemljanih radova uz točnu procjenu produktivnosti građevinskih strojeva.

Ključne riječi: vizualne tehnologije, progres, produktivnost, zemljani radovi

The importance of vision-based technologies for progress monitoring and productivity assessment of earthmoving operations

Abstract: Monitoring the progress of earthmoving operations while accurately estimating productivity of construction equipment provides a detailed insight into the performance, early detection of low productivity, as well as any other possible defects. It also provides feedback on the correctness of the decisions made and a more accurate report of the time and cost necessary for the activity. Early detection and warning of all the risky, unfavorable actions provides opportunities to timely take appropriate corrective measures and make improvements. Wireless technologies offer considerable potential for application in order to monitor work progress and evaluate productivity. However, the previous studies indicate shortcomings and limitations. Future research attention on their considerable potential is needed. The integration of various wireless technologies is a possible solution to the problem and complexity of monitoring work progress and productivity estimates. In this matter, vision-based technologies are an indispensable field of wireless technologies for the development of an appropriate, reliable, credible, fast and cost-effective methodology of monitoring the progress of earthmoving works with accurate estimation of the productivity of construction machines.

Key words: vision-based technologies, progress, productivity, earthmoving



1. UVOD

Praćenje progresa izvedbe zemljanih radova uz točnu procjenu produktivnosti građevinskih strojeva omogućuje detaljan uvid u tijek izvedbe, ranu detekciju slabe produktivnosti, kao i svih ostalih mogućih nedostataka, povratnu informaciju ispravnosti donesnih odluka te precizniji iskaz potrebnog vremena i troška aktivnosti. Ranim uočavanjem, i alarmiranjem, svih rizičnih, nepovoljnih radnji, pružene su mogućnosti za pravodobno poduzimanje odgovarajućih, korektivnih mjera i provedbu poboljšanja.

Ručno prikupljanje podataka na gradilištu i analize na temelju osobnog iskustva su zastarjele, dugotrajne i nedovoljno točne metode. Iz tog razloga, posebno je izražena potreba za ekonomičnim, pouzdanim i automatiziranim metodama, koje će moći podržati i obuhvatiti cijelokupan proces mjerjenja, vrednovanja, praćenja i kontrolu izvršenja radova na gradilištu, uz mogućnost primjene na različitim građevinskim projektima. (Golparvar-Fard i dr., 2013). Primjena i razvoj automatizacije ima izrazitu efikasnost jer doprinosi većoj produktivnosti, vodi smanjenju mogućnosti pogrešaka, omogućuje jednostavniji rad te ujedno osigurava veću vjerojatnost završetka građevinskog projekta na vrijeme i unutar planiranog proračuna, uz visoku kvalitetu izvedbe (Tajeen i Zhu, 2014).

Bežične tehnologije pružaju znatan potencijal za automatizaciju u primjeni, u svrhu praćenja progresa rada i procjene produktivnosti. Međutim, dosadašnja istraživanja ukazuju na brojne nedostatke i ograničenja. Vizualne tehnologije su jedan od primjera bežičnih tehnologija koje imaju mogućnost zabilježbe i vizualne reprodukcije stvarnog, istinskog okruženja, u vremenu snimanja, u obliku digitalnih fotografija ili video zapisa.

Mnogi dosadašnji istraživački napor su vezani upravo za praćenje progresa i procjene produktivnosti izvršenja na gradilištu, uz popraćenost digitalnim fotografijama ili video zapisima, kako bi se razvila pouzdana metoda za istovremeno praćenje većeg broja resursa i kreiranja dnevnih izvještaja tijeka proteklih aktivnosti. (Bügler i dr., 2017). Također, kod praćenja izvršenja zemljanih radova, vizualne tehnologije predstavljaju relativno nove metode, sa znatnim potencijalom, posebno radi samih karakteristika zemljanih radova, odnosno radi pružanja jasnog, prostranog vidika i brzog uočavanja resursa (Rezazadeh Azar i dr., 2013).

Prednosti vizualnih tehnologija se ogledaju u tome da predstavljaju jednu od najekonomičnijih metoda za automatizaciju praćenja progresa izvršenja (Teizer, 2015), a u usporedbi s drugim bežičnim tehnologijama za praćenje resursa, poput osjetnih tehnologija, satelitskog radionavigacijskog sustava za određivanje trenutačnog položaja (eng. *Global Positioning System, GPS*), tehnologije koja putem radio valova ostvaruje komunikaciju između svojstvenih uređaja (eng. *Radio Frequency IDentification, RFID*) i dr., prednost im je jednostavnija implementacija (Memarzadeh i dr., 2013; Yang i dr., 2015), kao i vizualna reprodukcija stvarnog, istinskog prikaza odvijanja radova na gradilištu, u vremenu snimanja. Nedostaci vizualnih tehnologija su smanjena vidljivost i točnost podataka prilikom loših vremenskih uvjeta, poput kiše, snijega, jakog vjetra, magle, kao i u uvjetima slabe prirodne ili umjetne rasvjete. Osim toga, za vrijeme snimanja, prilikom odvijanja radova, može se dogoditi i preklapanje resursa u prikazu, što također može uzrokovati netočnu generaciju podataka. Stoga, s odabirom mjesta za snimanje, treba biti posebno oprezan. Investiranjem u opremu boljih performansi, donekle se može ublažiti utjecaj loših vremenskih uvjeta. Međutim, za vrijeme izrazito loših vremenskih uvjeta, najčešće se i zaustavlja sama izvedba građevinskih radova (Teizer, 2015).

Usprkos značajnom napretku u primjeni vizualnih tehnologija prilikom građenja, i dalje su potrebna mnoga daljnja istraživanja jer dosadašnji razvoj vizualnih tehnologija ukazuje na ograničenu upotrebu i potreban veliki broj ručnih radnji (Rezazadeh Azar i dr., 2013).

U radu autora Šopić i Vukomanović (2017) istaknut je potencijal bežičnih tehnologija za prikaz stvarnih uvjeta na gradilištu, točno praćenje kretanja i rada građevinskih strojeva bez da se remeti njihov normalan rad, veću produktivnost, brzu i točnu obradu velikih količina



Značaj vizualnih tehnologija...

podataka s gradilišta, znatno umanjen utjecaj ljudskog faktora i ljudske pogreške te u konačnici, njihovog potencijala za uspješno i kvalitetno izvršenje građevinskih projekata. Također, istaknuta je i velika važnost i potreba za integracijom bežičnih tehnologija, kojom bi se, zbog nedostataka i ograničenja svake pojedine bežične tehnologije, omogućilo da se nemogućnost rješavanja određenog problema primjenom jedne bežične tehnologije, uspješno izvrši primjenom drugih bežičnih tehnologija.

Vizualne tehnologije su, pritom, neizostavno područje bežičnih tehnologija za razvoj odgovarajuće, pouzdane, vjerodostojne, brze i ekonomične metodologije za praćenje progresa izvedbe zemljanih radova uz točnu procjenu produktivnosti građevinskih strojeva.

S tim u vezi, u nastavku je opisano istraživanje autora Bügler i dr. (2017) s primjenom vizualnih tehnologija, preciznije kombinacijom fotogrametrije i video analize, kao primjer obećavajućeg prijedloga za integraciju s ostalim bežičnim tehnologijama, posebno s tehnologijama RFID i GPS, kao i s naprednom digitalnom kartografijom (eng. *Geographic Information System, GIS*), mobilnim komunikacijskim sustavima (eng. *Global System for Mobile communications, GSM*), uz analizu naprednih mjernih sustava i softverskih rješenja tvrtki *Caterpillar, Komatsu, Trimble, Leica Geosystems, Topcon* i dr. Također, navedena su i najnovija istraživanja za praćenje rada građevinskog stroja, autora Yuan i dr. (2016) te Zhu i dr. (2016), u svrhu prikaza i ostalih, trenutačnih struja razvoja vizualnih tehnologija.

2. VIZUALNE TEHNOLOGIJE

2.1 Fotogrametrija i video analiza

Fotogrametrija je znanost, tehnika i umjetnost definiranja forme, obrisa, oblika, prostornog položaja, značenja, veličine, strukture, kao i mogućnost dobivanja informacija o promjenama unutar određenog vremenskog razdoblja, nekog promatranog fizičkog objekta, procesom snimanja, mjerjenja i interpretacije fotografskih snimaka, snimljenih uz pomoć specijalnih, kalibriranih fotografskih kamera. S obzirom na položaj fotografskih kamera, razlikujemo aerofotogrametriju te terestričku fotogrametriju. Aerofotogrametrija podrazumijeva snimanje objekata iz zraka, odnosno preko kamera postavljenih na letjelicu, dok terestrička fotogrametrija podrazumijeva snimanje objekata s tla. Obuhvat snimke aerofotogrametrijom je puno veći nego obuhvat snimke terestričkom fotogrametrijom. Fotogrametrija ima široku primjenu. Posebno je važna njena primjena u geodeziji i inženjerstvu, kao i u arheologiji, geografiji, geologiji, kulturi, arhitekturi te u novije vrijeme u medicini i industriji.

Autori Bügler i dr. (2017) su predstavili metodologiju za praćenje progresa i procjenu produktivnosti zemljanih radova primjenom dviju različitih, individualnih, vizualnih tehnologija, preciznije kombinacijom fotogrametrije i video analize. Prednost primjene fotogrametrije je točna informacija volumena iskopanog i uklonjenog, odnosno odvezenog materijala s gradilišta (Slika 1.), dok je prednost primjene video analize, vizualna reprodukcija stvarnog, istinskog prikaza odvijanja radova i interakcije strojeva na gradilištu, u vremenu snimanja. Kombinacija ovih dviju vizualnih tehnologija, prema autorima Bügler i dr. (2017), rezultira moćnim alatom za praćenje progresa i procjenu produktivnosti zemljanih radova u kratkim vremenskim intervalima.

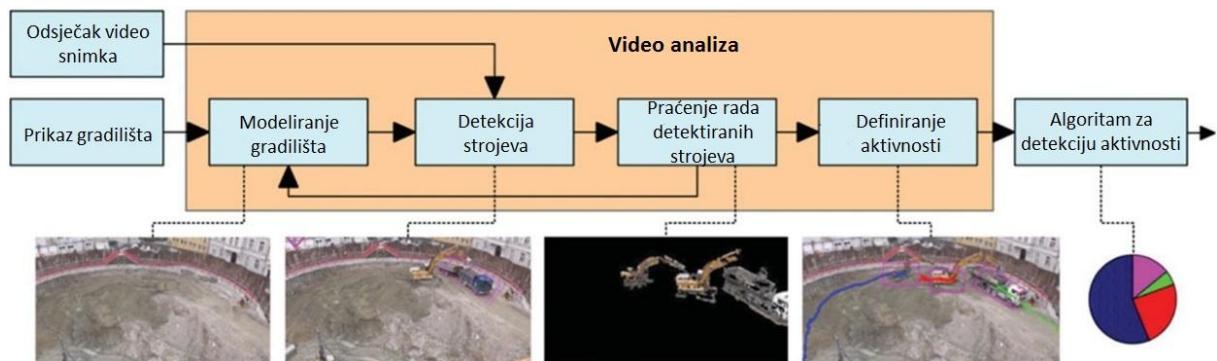
Fotogrametrijom se, dakle, uz pomoć fotografskih snimaka, može kreirati 3D prikaz prostora gradilišta te kvantificirati volumen iskopanog materijala. U tu svrhu, pripadajući algoritmi fotogrametrije najprije trebaju locirati karakteristične točke na pojedinim fotografskim snimkama. Karakteristične točke pojedinih fotografskih snimaka se zatim trebaju uskladiti. Potrebna su barem tri fotografске snimke s karakterističnim točkama, koje pripadajući algoritmi fotogrametrije, nakon lociranja i usklajivanja, koriste za povezivanje i kreiranje 3D prikaza prostora gradilišta. Općenito, karakteristične točke formiraju 3D „oblak točaka“ (eng. *point cloud*), a uz pomoć algoritama fotogrametrije mogu se i dodavati informacije ili se dobivati detaljniji prikazi površina.



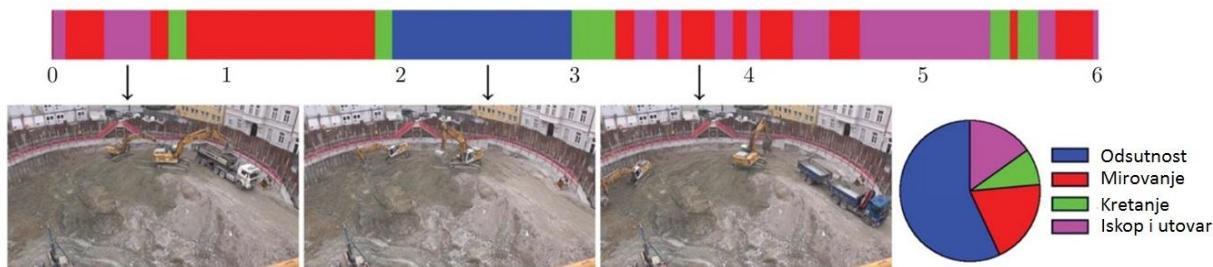
Slika 1. Pregled primjene fotogrametrije (preuzeto, uređeno i prevedeno: Bügler i dr., 2017)

Primjena video analize, u radu autora Bügler i dr. (2017), uključuje postavljanje video kamere na potrebnoj visini motrišta, kako bi postavljena video kamera mogla obuhvatiti rad bagera i kamiona kipera na gradilištu te obradu odsječaka videa. Autori Bügler i dr. (2017) su za obradu odsječaka video snimaka primijenili i poboljšali model autora Ogunmakin i dr. (2013). Obrada odsječaka video snimaka (Slika 2.) uključuje modeliranje gradilišta, detekciju strojeva koji se pojavljuju u analiziranom odsječku, praćenje rada detektiranih strojeva te definiranje svih aktivnosti koje se odvijaju unutar snimljenog odsječka. Tako dobivenim podacima i unosom istih u algoritam za detekciju aktivnosti, algoritam može generirati podatke poput prosječnih vremena trajanja zabilježenih aktivnosti, standardne devijacije prosječnih vremena trajanja zabilježenih aktivnosti, informacije broja strojeva koji se pojavljuju u snimanom odsječku, informacije broja utovarenih lopati bagera za punjenje sanduka kamiona kipera i sl. Obrada video analize može pokazati odstupanje od uobičajenih ili očekivanih vrijednosti izvedbe te je u tim slučajevima potrebno utvrditi razloge loše izvedbe.

Izlazni podaci algoritma za detekciju aktivnosti, koje su autori Bügler i dr. (2017) prikupljali za svoje istraživanje, bili su, broj kamiona kipera koji su pristupili na gradilište, trajanje zadržavanja kamiona kipera na gradilištu, trajanje punjenja sanduka kamiona kipera, broj utovarenih lopati bagera u svaki od sanduka kamiona kipera te trajanje mirovanja stroja na gradilištu bez ikakvih aktivnosti. Aktivnosti strojeva na gradilištu su bile grupirane pod faze odsutnosti stroja s gradilišta, mirovanja stroja na gradilištu, kretanja stroja te faze iskopa i utovara (Slika 3.).



Slika 2. Pregled primjene video analize (preuzeto, uređeno i prevedeno: Bügler i dr., 2017)



Slika 3. Primjer aktivnosti kamiona kipera u odsječku video snimke trajanja 6 minuta (preuzeto, uređeno i prevedeno: Bügler i dr., 2017)

2.1.1 Praćenje progrusa i procjena produktivnosti

Produktivnost zemljanih radova može se iskazati na različite načine omjerom izvršene količine iskopa, odvoza, nasipavanja, planiranja, zbijanja i sl., u nekom vremenskom periodu, poput mjerjenja volumena iskopanog materijala u nekom vremenskom periodu, brojem napunjenih sanduka kamiona kipera u nekom vremenskom periodu, mjerjenjem vremenskog ciklusa stroja određene zapremnine lopate ili sanduka i sl.

Autori Bügler i dr. (2017), su progres izvedbe i produktivnost zemljanih radova željeli pratiti kroz volumen iskopanog i uklonjenog materijala s gradilišta, za vrijeme trajanja jednog sata, ali i za kraće vremenske periode. U njihovom primjeru, mjera produktivnosti zemljanih radova je razmjerno rasla sa većom količinom kvalitetno izvršenog iskopa i utovara, kao i odvoza iskopanog materijala na deponiju, u što kraćem vremenu, s minimalnim fazama mirovanja strojeva na gradilištu.

Fotogrametrija se, zbog kompleksnosti u izvođenju zemljanih radova, kao i za uočavanje i mjerjenje znatnijeg pomaka u napredovanju iskopa i odvoza materijala, može koristiti, najkraće, ugrubo, za iskaz dnevnog volumena ukupno iskopanog i uklonjenog materijala s gradilišta. Dnevnim iskazima u napredovanju iskopa i odvoza, ne može se dobiti detaljan, dublji uvid u tijek izvedbe, a eventualno loša izvedba se registrira zakašnjelo. Upravo iz tog razloga, prednost primjene video analize, uz fotogrametriju, posebno dolazi do izražaja. Video analizom se nasuprot, može izračunati produktivnost u jednom satu, kao i kraćem vremenskom razdoblju, primjerice na način da se mjeri ukupan broj utovarenih lopati bagera, unutar mјerenog vremena, tvornički iskazane zapremnine lopate.

Radi jednostavnosti, i za usklađivanje dviju individualnih vizualnih tehnologija, u radu Bügler-a i dr. (2017), uzeta je pretpostavka da bi se, zasebnom primjenom fotogrametrije i video analizom, dobila ista mjera produktivnosti. Također, volumen obuhvata materijala s lopatom bagera, ovisno o kategorijama tla, može se razlikovati od tvornički iskazane zapremnine lopate bagera. Za premašivanje ograničenja zapremnine lopate, kao i radi praktičnosti, usklađenosti i jednostavnosti primjene, u kombinaciji dviju individualnih vizualnih tehnologija, zapremnina lopate bagera procijenjena je dijeljenjem ukupnog volumena dnevno iskopanog i uklonjenog materijala s gradilišta, primjenom fotogrametrije, s ukupnim brojem dnevno utovarenih lopati bagera u sanduke kamiona kipera, zabilježenih primjenom video analize. Tako je dobivena procijenjena vrijednost zapremnine lopate bagera. Brojem utovarenih lopati, dobivene zapremnine lopate, za neki vremenski period, može se iskazivati produktivnost izvođenja u tom vremenskom periodu. Vrijednostima produktivnosti u kratkim vremenskim intervalima, poput jednog sata, ali i kraće, može se detektirati slaba produktivnost, kao i izvrsna produktivnost, a obradom video snimke i analizom iste, imati uvid u razloge i uzroke određene produktivnosti. Uvidom u progres i produktivnost, može se pratiti napredak i dinamika izvođenja, preciznije proračunati potrebno vrijeme i trošak aktivnosti, ali i na vrijeme uočiti neprihvatljive, rizične i nepovoljne radnje, što je od posebne važnosti za pravodobno poduzimanje odgovarajućih korektivnih mјera.



2.1.2 Prednosti i nedostaci

Autori Bügler i dr. (2017) su svoju metodologiju za praćenje progresa i procjenu produktivnosti primijenili na dva velika građevinska projekta. Jedan je predstavljao izvedbu garaže za parkiranje automobila, dok je drugi predstavljao dogradnju bolnice. U oba građevinska projekta bile su prisutne masivne količine iskopa materijala s odvozom.

Primjena fotogrametrije i video analize na građevinskim projektima istaknula je nedostatke metodologije. Loši vremenski uvjeti poput kiše, snijega, jakog vjetra, ili uvjeti slabe prirodne ili umjetne rasvjete, mogu oslabiti kvalitetu fotografskih snimaka te smanjiti točnost u kreiranju 3D prikaza prostora gradilišta. Investiranjem u opremu boljih performansi, donekle se može ublažiti utjecaj loših vremenskih uvjeta na kvalitetu fotografskih snimaka. Osim toga, ako je video kamera loše postavljena, može se dogoditi preklapanje resursa u video prikazu, što također može uzrokovati netočnu generaciju podataka.

Prednosti fotogrametrije i video analize jesu dobivanje detaljnog uvida u tijek izvedbe, što rezultira boljem donošenju odluka, većoj vjerojatnosti optimalne alokacije strojeva te ostvarenju projektnih ušteda. Također, dugoročna primjena fotogrametrije i video analize omogućila bi stvaranje baze podataka s vrijednim informacijama za buduće, slične projekte. Autori Bügler i dr. (2017) su istaknuli jednostavnost i ekonomičnost primjene fotogrametrije i video analize, kao i njihovu primjenu bez ometanja strojeva u radu. Posebno su istaknuli značajnost primjene u svrhu razvoja dragocjene podrške za upravljanje građevinskim projektima te bolje kontrole i veće učinkovitosti u izvođenju radova. Prema autorima Bügler i dr. (2017), daljnje istraživanje bi uključilo postavljanje većeg broja video kamera i obradu kombinacije odsječaka video snimaka, kako bi se smanjila mogućnost netočnih generacija podataka uzrokovanih preklapanjima resursa u video prikazu.

2.2 Stereo kamera i triangulacija

Autori Yuan i dr. (2016) su predstavili studiju za daljnje istraživanje u svrhu prepoznavanja građevinskog stroja, njegovo lociranje te praćenje njegovog dinamičnog, pokretljivog i brzog rada, prilikom samog izvođenja radova. Svoje istraživanje su primijenili na radu bagera (Slika 4.). Okosnica njihove studije je, primjenom stereo kamera, algoritma za dvodimenzionalno (2D) praćenje te algoritma triangulacije za trodimenzionalno (3D) praćenje, prikaz rada građevinskog stroja, posebno njegovih kinematičkih, zglobno vezanih, alata. Stereo kamera je kamera koja ima dvije, ili više leća sa zasebnim sustavima senzora na svakoj leći, tako ostvarujući mogućnost 3D prikaza. Triangulacija je metoda određivanja položaja nekih glavnih točaka, u ovoj studiji ruke i lopate bagera, pomoću poznatih duljina i mjera svih triju kutova uz nju.

Autori Yuan i dr. (2016) su naglasili da će daljnja istraživanja provesti u svrhu postavljanja većeg broja video kamera, kako bi se smanjila mogućnost netočne detekcije pokreta, uzrokovanih preklapanjima resursa u video prikazu, kao i prema smanjivanju geometrijskih nesigurnosti kod daljinskih prikaza.



Slika 4. Primjer praćenja ruke i lopate bagera (preuzeto i uređeno: Yuan i dr., 2016)

Prema autorima Yuan i dr. (2016), implementacija njihove studije bi doprinijela automatizaciji i razvoju metoda primjenom bežičnih tehnologija, poput metoda za automatizirano upravljanje strojem (eng. *Automated Machine Guidance*, AMG), za automatiziranu kontrolu stroja (eng. *Automated Machine Control*, AMC), za praćenje progresa i procjenu produktivnosti, ali i za povećanje sigurnosti na gradilištu i poboljšanje produktivnosti. AMG i AMC su sustavi koji koriste bežične, osjetne, tehnologije, poput GPS-a, povećane preciznosti (eng. *Real-Time Kinematic*, RTK GPS), raznih senzora, lasera i sl., u svrhu pružanja preciznih informacija o položaju alata stroja, kako bi se brže, kvalitetnije i sigurnije izvodili radni zahvati uz smanjenje mogućnosti pogrešaka.

2.3 Tehnika praćenja česticama

Autori Zhu i dr. (2016) su razvili metodu za vizualno praćenje resursa na gradilištu primjenom tehnike praćenja česticama (eng. *Particle Filtering*). Njihova metoda uključuje postavljanje video kamere visoke rezolucije (eng. *High-Definition*, HD) i snimanje aktivnosti na gradilištu. Primjenom tehnike praćenja česticama, za analizu video snimke, potrebno je ručno, pravokutnikom obuhvatiti resurs koji se želi pratiti, najčešće građevinski stroj ili radnika. U označenom pravokutniku, odnosno na praćenom resursu, generiraju se stotine sitnih čestica. Pravokutnik (ili filter) s česticama slijedi i prati kretanje resursa.

Autori Zhu i dr. (2016) su istaknuli da je praćenje resursa na gradilištu od iznimne važnosti za detaljan uvid u tijek izvedbe, tako omogućujući detekciju nedostataka i opasnosti. Najveću pažnju u svom istraživanju posvetili su rješavanju problematike praćenja, prilikom prolaska resursa iza nekog sadržaja, jer tako dolazi do njihovih preklapanja u video prikazu i moguće netočne generacije podataka (Slika 5.).



Slika 5. Primjer praćenja zglobnog dampera (preuzeto i uređeno: Zhu i dr., 2016)

Prednost tehnike praćenja česticama, upravo je u mogućnosti kontinuiranog praćenja resursa, čak i ako se nađe iza nekog sadržaja, ali ga isti ne smije u cijelosti prekriti. Međutim, ako se praćeni resurs nađe iza, ili unutar nekog sadržaja na gradilištu, koji je takve veličine da u cijelosti sakrije praćeni resurs, gubi se povezanost resursa s pravokutnikom s česticama, odnosno praćenje resursa je pauzirano, sve dok resurs ponovno ne bude vidljiv na video zapisu. Najveći nedostatak njihove metode je mogućnost praćenja samo jednog resursa. Stoga su potrebna daljnja istraživanja i modifikacije kako bi se, u isto vrijeme, moglo pratiti više objekata.

3. PRIJEDLOG ISTRAŽIVANJA I ZAKLJUČAK

U radu Šopić i Vukomanović (2017), kao moguće rješenje problematike i kompleksnosti praćenja progresa izvedbe zemljanih radova i točne procjene produktivnosti građevinskih strojeva, predstavila se integracija različitih bežičnih tehnologija. Posebno se razmatralo



rješenje integracije tehnologije RFID s drugim bežičnim tehnologijama, poput tehnologija GPS i GIS, brzorastuće komunikacijske GSM tehnologije, uz analizu naprednih mjernih sustava i softverskih rješenja tvrtki *Caterpillar, Komatsu, Trimble, Leica Geosystems, Topcon* i dr.

Tehnologija RFID se pokazala kao uspješna i jednostavna metoda za mjerjenje stvarne produktivnosti kamiona kipera i skrejpera (Montaser i Moselhi, 2012 i 2013), kao i za praćenje položaja građevinskih strojeva u svrhu sprječavanja sudara, postizanja dobrog rasporeda te radi zaštite života ljudi na gradilištu (Lu i dr., 2011, Teizer i dr., 2010, Karthik i dr., 2014). Kombinacija tehnologija GPS i GIS također se iskazala kao uspješna i jednostavna metoda za procjenu stvarne produktivnosti transportnih sredstava, kao i za predviđanje potrebnog vremena i troška, koji proizlaze djelovanjem transportnih sredstava (Alshibani i Moselhi, 2016).

Vizualne tehnologije imaju mogućnost zabilježbe i vizualne reprodukcije stvarnog, istinskog prikaza na gradilištu, što omogućava lakše praćenje resursa i prikaz njegove interakcije s drugim resursima i sadržajima.

Kombinacija fotogrametrije i video analize pokazala se kao moćan alat za praćenje progresa i procjenu produktivnosti zemljanih radova u kratkim vremenskim intervalima. Vrijednostima produktivnosti u kratkim vremenskim intervalima, može se, pravovremeno, detektirati slaba produktivnost, kao i izvrsna produktivnost, a obradom video snimke i analizom iste, imati uvid u razloge i uzroke istih.

Vizualne tehnologije u svojoj primjeni pružaju vrijedan doprinos jer, u odnosu na ostale bežične tehnologije, jedine mogu prikazati stvarni, istinski prikaz kompleksnog, dinamičnog i jedinstvenog okruženja koje vlada na gradilištu. Također, predstavljaju neizostavan korak prema razvoju odgovarajuće, pouzdane, vjerodostojne, brze, i ekonomične metodologije za praćenje progresa izvedbe zemljanih radova uz točnu procjenu produktivnosti građevinskih strojeva. Pritom, posebno je važna integracija različitih, bežičnih tehnologija, osjetnih, vizualnih i komunikacijskih mogućnosti.

Pri integraciji bežičnih tehnologija, kombinacija fotogrametrije i video analize, dala bi doprinos pri izvedbi zemljanih radova, posebno kod masivnih količina iskopa i odvoza, karakterističnih za radove visokogradnje. Fotogrametrija i video analiza, pri integraciji bežičnih tehnologija, koristile bi se za iskaz progresa i produktivnosti zemljanih radova, posebno prilikom koordinacije između rada bagera i kamiona kipera za vrijeme iskopa i utovara materijala iz iskopa, dok bi se tehnologije RFID i/ili GPS-a i GIS-a, koristile za mjerjenje produktivnosti kamiona kipera.

Uvidom u progres i produktivnost, može se pratiti napredak i dinamika izvođenja, preciznije proračunati potrebno vrijeme i trošak aktivnosti, ali i na vrijeme uočiti neprihvatljive, rizične i nepovoljne radnje, što je od posebne važnosti za pravodobno poduzimanje odgovarajućih korektivnih mjera.

Bežične tehnologije pružaju znatan potencijal za primjenu u svrhu praćenja progresa rada i procjene produktivnosti. Međutim, dosadašnja istraživanja ukazuju na nedostatke i ograničenja. Također, literatura ukazuje i na skroman doprinos u istraživanju primjenom integracije bežičnih tehnologija, posebno u svrhu praćenja progresa izvedbe zemljanih radova i procjenu produktivnosti građevinskih strojeva. Potrebna su daljnja istraživanja velikih potencijala bežičnih tehnologija, nadasve prilikom njihove integracije.

LITERATURA

1. Golparvar-Fard M., Heydarian A. and Niebles J.C.: *Vision-based action recognition of earthmoving equipment using spatio-temporal features and support vector machine classifiers*, Advanced Engineering Informatics, 2013, 27(4), 652–663.
2. Tajeen H. and Zhu Z.: *Image dataset development for measuring construction equipment recognition performance*, Automation in Construction, 2014, 48, 1–10.



3. Rezazadeh Azar E., Dickinson S. and McCabe B.: *Server-Customer Interaction Tracker: Computer Vision-Based System to Estimate Dirt-Loading Cycles*, Journal of Construction Engineering and Management, 2013, 139(7), 785–794.
4. Bügler M., Borrmann A., Ogunmakin G., Vela P. A. and Teizer J.: *Fusion of Photogrammetry and Video Analysis for Productivity Assessment of Earthwork Processes*, Computer-Aided Civil and Infrastructure Engineering, 2017, 32(2), 107-123.
5. Teizer J.: *Status quo and open challenges in vision-based sensing and tracking of temporary resources on infrastructure construction sites*, Advanced Engineering Informatics, 2015, 29(2), 225-238.
6. Memarzadeh M., Golparvar-Fard M. and Niebles J. C.: *Automated 2D detection of construction equipment and workers from site video streams using histograms of oriented gradients and colors*. Automation in Construction, 2013, 32, 24–37.
7. Yang J., Park M. W., Vela P. A. and Golparvar-Fard M.: *Construction performance monitoring via still images, time-lapse photos, and video streams: Now, tomorrow, and the future*, Advanced Engineering Informatics, 2015, 29(2), 211-224.
8. Šopić, M., Vukomanović, M.: *Praćenje i kontrola produktivnosti građevinske mehanizacije integracijom bežičnih tehnologija*, 3. Simpozij doktorskog studija građevinarstva, Sveučilište u Zagrebu, Građevinski fakultet, 2017, 95-104.
9. Ogunmakin, G., Teizer, J. & Vela, P.: *Quantifying interactions amongst construction site machines*, in Proceedings of the EG-ICE Workshop on Intelligent Computing in Engineering, Vienna, Austria, 2013.
10. Yuan C., Li S. and Cai H.: *Vision-Based Excavator Detection and Tracking Using Hybrid Kinematic Shapes and Key Nodes*, Journal of Computing in Civil Engineering, 2016, 31(1), 04016038.
11. Zhu Z., Ren X. and Chen Z.: *Visual Tracking of Construction Jobsite Workforce and Equipment with Particle Filtering*, Journal of Computing in Civil Engineering, 2016, 30(6), 04016023.
12. Montaser A., Moselhi O.: *RFID+ for Tracking Earthmoving Operations*, Construction Research Congress 2012: Construction Challenges in a Flat World, West Lafayette, Indiana, pp. 1011-1020, 2012.
13. Montaser A., Moselhi O.: *Tracking Scraper-Pusher Fleet Operations Using Wireless Technologies*, 4th Construction Specialty Conference, Montreal, Quebec, 2013.
14. Lu W., Huang G. Q., Li H.: *Scenarios for applying RFID technology in construction project management*, Automation in Construction, 2011, 20(2), 101-106.
15. Teizer J., Allread B. S., Fullerton C. E., Hinze, J.: *Autonomous pro-active real-time construction worker and equipment operator proximity safety alert system*, Automation in Construction, 2010, 19(5), 630-640.
16. Karthik G., Jayanthu S., Rammohan P., Rahman A.: *Utilisation of mobile communication in opencast mines*, International Journal of Computer Science and Mobile Computing, 2014, 3(7), 373-378.
17. Alshibani A., Moselhi O.: *Productivity based method for forecasting cost & time of earthmoving operations using sampling GPS data*, Journal of Information Technology in Construction (ITcon), 2016, 21(3), 39-56.