

Primljen / Received: 22.1.2024.
 Ispravljen / Corrected: 24.7.2024.
 Prihvaćen / Accepted: 2.9.2024.
 Dostupno online / Available online: 10.12.2024.

Utvrđivanje stanja kolnika pomoću podataka o ubrzaju prikupljenih pametnim telefonima na temelju 1D konvolucijske neuronske mreže

Autori:



Mr.sc. **Yudong Han**, dipl.ing.građ.
 Sveučilište za znanost i tehnologiju Liaoning, Kina
 Građevinski fakultet
hanyudong@ustl.edu.cn



Zhaobo Li, dipl.ing.građ.
 Centar za inovativne usluge u znanosti i
 tehnologiji Hohhot, Kina
 Kinesko sveučilište za ruderstvo i tehnologiju
 Fakultet strojarstva i građevinarstva
lb23030001@cumt.edu.cn



Dr.sc. **Jiaqi Li**, dipl.ing.grad.
 Sveučilište za znanost i tehnologiju Liaoning, Kina
 Građevinski fakultet
ljiaqi@ustl.edu.cn
 Autor za korespondenciju

Yudong Han, Zhaobo Li, Jiaqi Li

Prethodno priopćenje

Utvrđivanje stanja kolnika pomoću podataka o ubrzaju prikupljenih pametnim telefonima na temelju 1D konvolucijske neuronske mreže

Posljednjih je godina postignut napredak metoda utvrđivanja stanja kolnika na temelju vibracija i dokazano je da je moguće utvrditi stanje kolnika analizom podataka o ubrzaju. U ovom se radu predlaže sudjelovanje javnosti u prikupljanju podataka i uvedena je jednodimenzionska konvolucijska neuronska mreža (1D-CNN) za izravnu obradu signala ubrzanja kako bi se otklonila ograničenja tradicionalnih metoda kategoriziranja strojnim učenjem. U ovom istraživanju kao alati za ispitivanje upotrijebljeni su pametni telefon i bicikl, a prikupljena su 422 uzorka podataka o ubrzaju duž X, Y i Z osi, uključujući četiri tipa stanja kolnika: neravan kolnik, kolnik s uspornicima (tzv. ležećim policijcima), ravni kolnik i kolnik s udarnim rupama. Projektirano je pet tipova mreže 1D-CNN-a s različitim funkcijama za aktivaciju i mrežnim strukturama za klasifikaciju podataka i uspoređeno je s algoritmima za strojno učenje, uključujući neuronske mreže stroja potpornih vektora (SVM) i radialne bazne funkcije (RBF). Rezultati pokazuju da je jednodimenzionska konvolucijska neuronska mreža, uz tri konvolucijska sloja i tri sloja udruživanja primjenom rektificirane linearne aktivacije najučinkovitija u pogledu klasifikacije, s klasifikacijskom točnošću od 0,9976. U usporedbi s neuronskim mrežama stroja potpornih vektora (SVM) i radialne bazne funkcije (RBF), konvolucijska neuronska mreža ne samo da štedi mnogo vremena jer ne zahtijeva ručno izdvajanje značajki, već pruža i veću klasifikacijsku točnost.

Ključne riječi:

utvrđivanje stanja kolnika, konvolucijska neuronska mreža, duboko učenje, kolnik, pametni telefon

Yudong Han, Zhaobo Li, Jiaqi Li

Research Paper

Pavement condition detection using acceleration data collected by smartphones based on 1D convolutional neural network

Vibration-based pavement condition detection methods have advanced in recent years, and it has been proven to be feasible to identify pavement conditions by analysing acceleration data. In this study, a public participation solution is proposed, and a one-dimensional convolutional neural network (1D-CNN) is introduced to directly process acceleration signals, addressing the limitations of traditional machine-learning classification methods. In this study, a smartphone and bicycle were used as the experimental tools, and 422 samples of acceleration data across the X-, Y-, and Z-axes were collected, including four types of pavement conditions: bumpy pavement, speed bumps, smooth pavement, and potholes. Five types of 1D-CNN with different activation functions and network structures were designed to classify the data and were compared with machine learning algorithms, including support vector machine (SVM) and radial basis function (RBF) neural networks. The results show that a 1D-CNN, with three convolution layers and three pooling layers using the ReLU activation function, achieved the best classification performance, with a classification accuracy of 0.9976. Compared with SVM and RBF neural networks, CNN not only saves considerable time by eliminating manual feature extraction operations but also provides higher classification accuracy.

Key words:

pavement detection, convolutional neural network, deep learning, pavement, smartphone

1. Uvod

Utvrđivanje stanja kolnika ključno je za održavanje i upravljanje cestovnom infrastrukturom. Preciznom i pravovremenom procjenom stanja kolnika mogu se utvrditi područja koja zahtijevaju održavanje, čime se sprječava da manji problemi prerastu u značajne strukturne probleme. Ovaj proaktivni pristup produljuje vijek prometnica i omogućuje sigurnost i udobnost korisnika smanjujući rizik od nesreća prouzročenih lošim uvjetima na cesti. Nadalje, učinkovitom procjenom stanja kolnika tijela lokalnih uprava i prijevozne agencije mogu značajno uštedjeti na troškovima optimiziranjem rasporeda održavanja i raspodjele resursa. Povećanjem urbanizacije i obujma prometa potražnja za velikim i prilagodljivim rješenjima za nadzor kolnika postaje još važnija u potpori održivog razvoja infrastrukture [1-4]. Uz sve veću pozornost posvećenu upravljanju i održavanju cestovne infrastrukture i sve većom raznolikošću uređaja za prikupljanje podataka, praćenje stanja kolnika postaje sve uobičajenije. Zasad se učestalo rabe tri metode: 3D rekonstrukcija, vizualno otkrivanje i otkrivanje na temelju vibracija.

Metode trodimenzijske (3D) rekonstrukcije mogu se dalje klasificirati u metode 3D laserskog skeniranja, stereometode i vizualizaciju upotrebom dubinske kamere. Chang i sur. [5] i Li i sur [6] upotrijebili su tehnologiju 3D laserskog skeniranja za otkrivanje udarnih rupa u kolniku u stvarnom vremenu. Wang [7] i Hou i sur. [8] upotrijebili su stereovid za otkrivanje udarnih rupa na cesti i ostvarili dobre rezultate. Joubert i sur. [9] i Mozzami sur. [10] upotrijebili su Microsoftovu kameru Kinect za dobivanje trodimenzijskih informacija o udarnim rupama. Međutim, tehnologija 3D laserskog skeniranja i metode stereovida ne primjenjuju se često zbog relativno skupe opreme i složenosti izračuna i obrade u kasnjim fazama. Metode vizualnog otkrivanja intuitivne su i posljednjih se godina često upotrebljavaju u građevinskim inspekcijama. Koch i Brilakis [11] predstavili su metodu za automatsko otkrivanje udarnih rupa na snimkama asfaltnog kolnika na temelju histogramskog praga i uspješno su primjenjeni upotrebom računalnog programa MATLAB. Hoang [12] je upotrijebio stroj potpornih vektora (engl. *support vector machine* - SVM) i umjetne neuronske mreže (engl. *Artificial Neural Network* - ANN) za izradu modela za otkrivanje udarnih rupa. Primjenom SVM-a postignuta je klasifikacijska točnost od 89 %. Eisenbach i sur. [13] upotrijebili su mobilni sustav mapiranja, S.T.I.E.R., za otkrivanje oštećenja na cesti, poput pukotina, udarnih rupa i zakrpa, s točnošću većom od 90 %. Li i sur. [14] razvrstali su pukotine na kolniku u četiri kategorije (uzdužne, poprečne, blokovske i mrežaste pukotine). Primjenjena su četiri konvolucijske neuronske mreže različitih struktura, s preciznošću klasifikacije preko 0,9. Posljednjih godina, s razvojem tehnologije za otkrivanje objekata, predloženo je nekoliko pristupa za praćenje stanja kolnika i otkrivanje oštećenja, koji postižu zadovoljavajući stupanj točnosti [15, 18]. Prednost vizualnih metoda su

brzo otkrivanje i lokalizacija oštećenja. One, međutim, nisu dobro integrirane s mehaničkim odzivom kolnika kako bi dale informacije o početnim pokazateljima stanja određene dionice kolnika.

Značajna količina informacija može se dobiti na temelju signala ubrzanja, kao što su prepoznavanje ljudskog kretanja [19, 22], praćenje stanja konstrukcije [23, 25] i seizmička analiza [26, 28]. Yu i Yu [29] predložili su procjenu stanja kolnika pomoću signala ubrzanja tijekom vožnje. Erikson i sur. [30] opisali su sustav detekcije udarnih rupa na kolniku koji primjenjuje algoritam strojnog učenja za otkrivanje udarnih rupa na kolniku. Mednis i sur. [31] razvili su metodu za nadzor udarnih rupa u kolniku pomoću senzora ubrzanja u pametnim telefonima, sa stvarnom pozitivnom stopom od 90 %. Fox i sur. [32] prikupili su podatke o ubrzanju tijekom vožnje i predložili metodu otkrivanja udarnih rupa na temelju strojnog učenja, pomoću koje je postignuta eksperimentalna točnost od 0,889. Bhatt i sur. [33] usporedili su učinak klasifikacije povećanja gradijenta i SVM-a za signale ubrzanja, a rezultati su pokazali da je točnost tih dvaju klasifikatora za prepoznavanje udarnih rupa na kolniku iznosila 92,02 % odnosno 92,9 %. Du i sur. [34] istaknuli su nepravilnosti kolnika koristeći se podacima o ubrzanju putem algoritma k-najbližeg susjeda (KNN), pri čemu je točnost premašila 0,9. Yang i Zhou [35] analizirali su podatke o ubrzanju u vremenskoj i frekvencijskoj domeni i otkrili poprečne pukotine. Egaji i sur. [36] predložili su model strojnog učenja za otkrivanje udarnih rupa pomoću podataka o ubrzanju, pri čemu su metoda "slučajnih šuma" i KNN pokazali najbolji učinak. Zhang i sur. [37] naveli su da se hrapavost površine kolnika može procijeniti pomoću senzora ubrzanja ugrađenog u pametni telefon, a eksperimentalni rezultati pokazali su da je stopa pogreške manja od 10 %. Među gore spomenutim istraživanjima, većina su bili pristupi temeljeni na graničnim vrijednostima ili strojnom učenju. U prvom se utvrđuje vrijednost praga za ubrzanje. Čim vrijednost ubrzanja prieđe taj prag, smatra se da postoji udarna rupa u kolniku. Ne može se jamčiti točnost ove metode te ona ne može razlikovati druge situacije koje dovode do naglih promjena ubrzanja (npr. vožnja preko uspornika tzv. ležećih policajaca). Metode obrade podataka temeljene na strojnom učenju općenito obuhvaćaju dva koraka: izvlačenje obilježja i klasifikaciju. Iako postoji veća brzina i veća točnost u drugoj fazi, izvlačenje obilježja povećava složenost i smanjuje učinkovitost cijelog procesa. Što se tiče opreme za otkrivanje, razvijaju se inteligentne, ekonomične i prijenosne tehnologije. Trenutačno pametni telefoni mogu biti konkurentni u određenim aspektima praćenja stanja kolnika i mogu omogućiti sudjelovanje javnosti [38, 39]. Ukratko, signali ubrzanja bolje reagiraju na mehanička svojstva kolnika. Pametni telefoni široko su dostupni prijenosni uređaji koji omogućuju sudjelovanje javnosti i prikupljanje i analizu podataka velikih razmjera. Ovaj rad stoga predlaže sudjelovanje javnosti kao metodu za klasifikaciju podataka o ubrzanju za otkrivanje stanja kolnika kako bi se poboljšalo upravljanje i održavanje prometne infrastrukture.

Široka dostupnost bicikala i pametnih telefona pruža povoljne uvjete za sudjelovanje javnosti. Za otkrivanje podataka predlažemo upotrebu konvolucijskih neuronskih mreža (CNN) za automatsko izvlačenje i klasifikaciju obilježja, bez potrebe za ručnim oblikovanjem i izvlačenjem obilježja u skladu s tradicionalnim metodama strojnog učenja. Ovaj pristup nije prije bio predložen i detaljnije je ispitana u ovom radu.

2. Metodologija

Kako b se provele ovo istraživanje, korišteni su bicikli, koji se još uvijek često upotrebljavaju, a koji su služili kao nosači i pametne telefone učvršćene sprijeda kao uređaje za prikupljanje podataka o ubrzanju. Nakon toga uslijedila je vožnja biciklom ravnim i neravnim kolnikom, kolnikom s udarnim rupama i kolnikom s uspornicima ravnomjernom brzinom i snimanje podataka o ubrzanju po X-, Y- i Z-osi u tri smjera pomoću aplikacije Orion CC. Na kraju smo upotrijebili konvolucijsku neuronsku mrežu te neuronske mreže stroja potpornih vektora (SVM) i radikalne bazne funkcije (RBF) za klasifikaciju četiri različita signala ubrzanja i usporedili klasifikacije triju algoritama.

2.1. Skup podataka

Kao što je prikazano na slici 1., u ovom ispitivanju korišten je mobilni uređaj iPhone 8 Plus, koji je bio pričvršćen na prednji dio bicikla za prikupljanje podataka o ubrzanju. Kako bismo smanjili radno opterećenje uslijed treniranja konvolucijske neuronske mreže, analizirali smo samo ubrzanje po Z-osi tako da je Z-os bila okomita na smjer tla nakon što je mobilni telefon pričvršćen. Međutim, zbog utjecaja okretanja, naginjanja i vibracija, Z-os nije uvijek bila okomita na tlo tijekom prikupljanja stvarnih podataka. Stoga su podaci o ubrzanju po X-, Y- i Z-osi i dalje bili uključeni u skup podataka. Svrha ovog istraživanja jest utvrditi stanje kolnika. Ne samo da će udarne rupe uzrokovati promjene ubrzanja, već će uspornici i neravan kolnik uzrokovati značajne promjene u ubrzanju. Stoga je konačni skup podataka o ubrzanju obuhvaćao ravni kolnik,

kolnik s udarnim rupama, neravan kolnik i uspornike (slika 2.). Prilikom prikupljanja podataka o ubrzanju, brzina je postavljena na 10 - 15 m/s, frekvencija uzorkovanja bila je 100 Hz, a vrijeme uzorkovanja 5 s. Svaki signal vremenske serije sadržavao je 500 elemenata. Svaki je obuhvaćao tri smjera: X, Y i Z. Prikupljene su 422 skupine podataka: 108 skupina za neravne kolnike, 99 skupina za kolnik s uspomicima, 113 skupina za ravne kolnike i 102 skupine za kolnike s udarnim rupama. Na slici 3. prikazani su izvorni podaci o ubrzanju u vremenskoj domeni prikupljeni pametnim telefonom i podaci o ubrzanju u frekvencijskoj domeni, dobiveni brzom Fourierovom transformacijom.



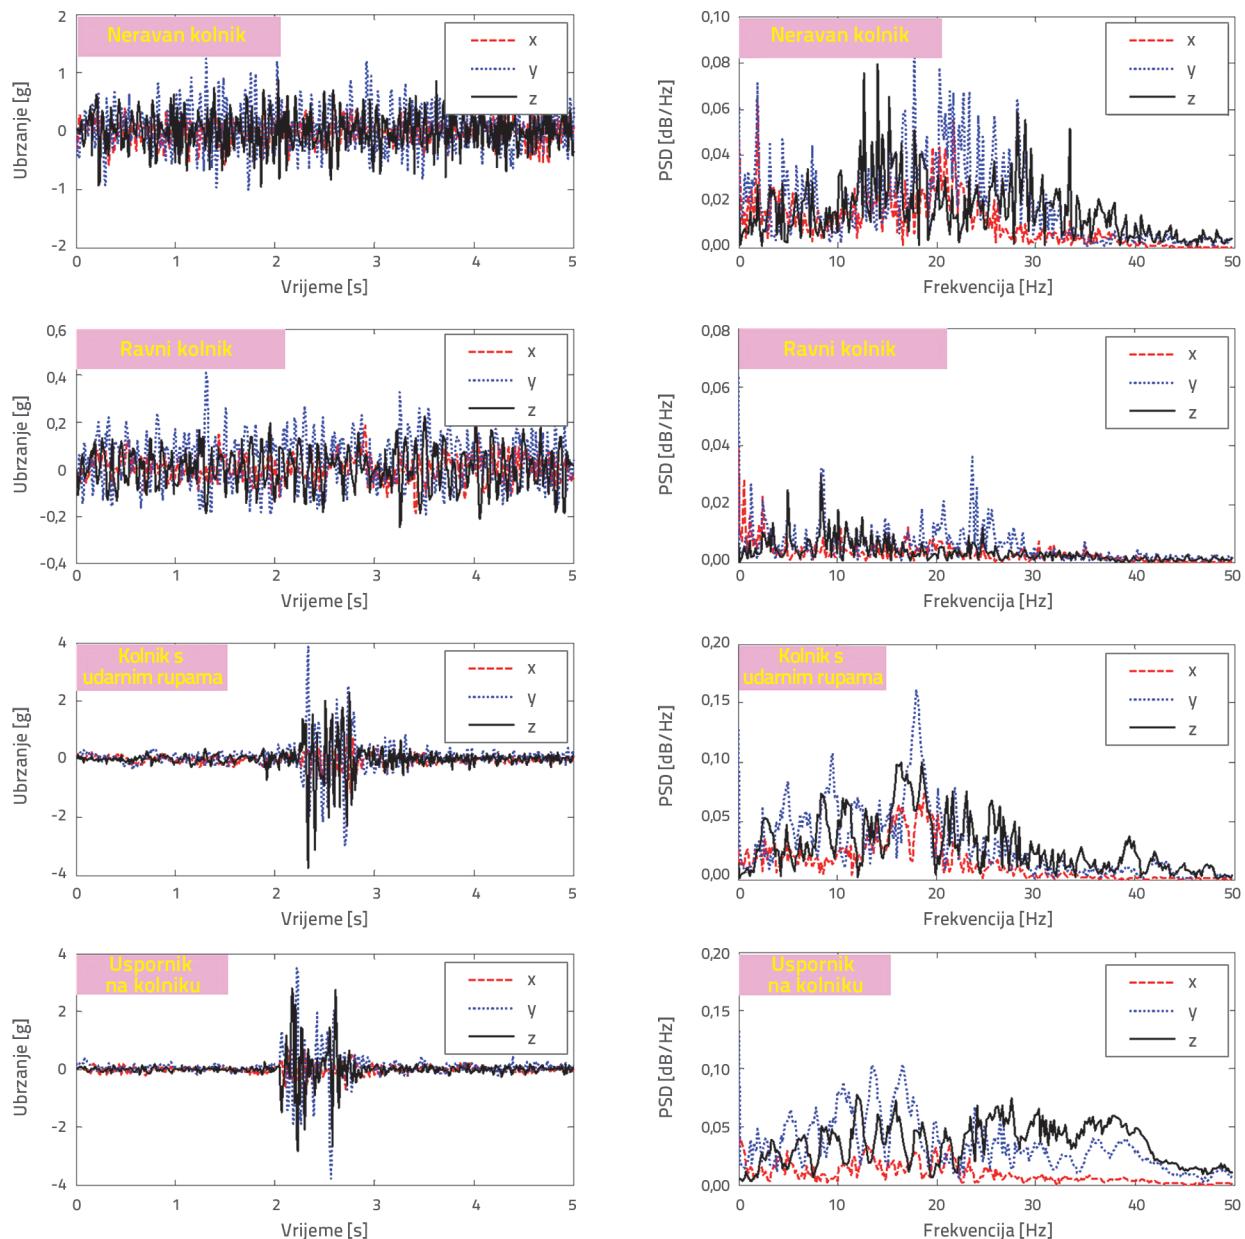
Slika 1. Alati za ispitivanje i Orion CC

2.2. Konvolucijska neuronska mreža

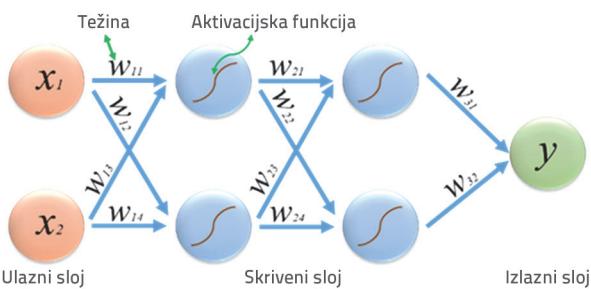
Najznačajnija razlika između konvolucijske neuronske mreže (engl. *convolutional neural network* - CNN) i tradicionalne umjetne neuronske mreže (engl. *Artificial Neural Network* - ANN) je dodatna upotreba konvolucijskih slojeva i slojeva udruživanja. Kao što je prikazano na slici 4., ANN uključuje ulazni sloj, skriveni sloj i izlazni sloj. Neuroni su najosnovnija struktura ANN-a. Svaki neuron smatra se čvorom. Susjedni slojevi neurona se povezuju, dok između neurona unutar istog sloja nema poveznice.



Slika 2. Primjeri neravnog kolnika, ravnog kolnika, kolnika s udarnom rupom i uspornika



Slika 3. Primjeri podataka o ubrzanju u vremenskoj i frekvencijskoj domeni za x, y i z osi



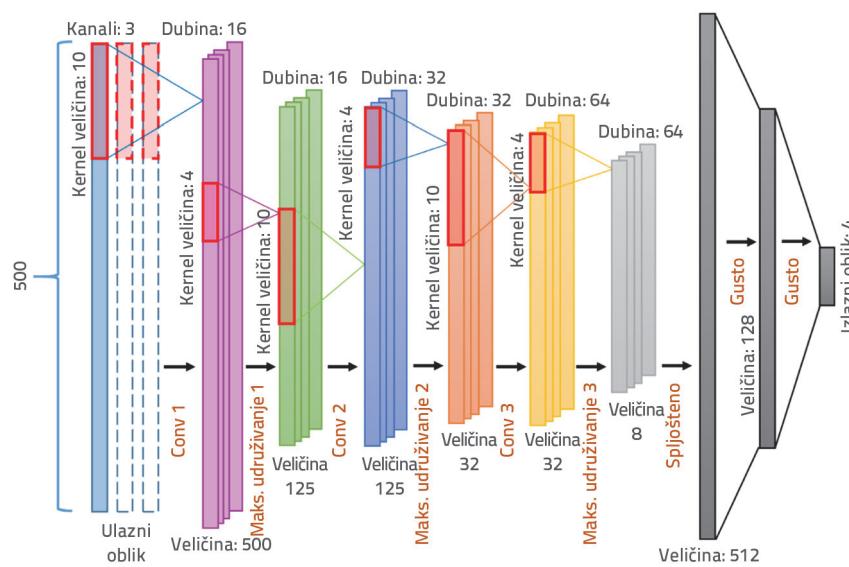
Slika 4. Primjeri podataka o ubrzanju u vremenskoj i frekvencijskoj domeni

ANN-ovi sporo obrađuju složene probleme. Na primjer, pri obradi crno-bijele slike dimenzije 28×28 u skupu podataka MNIST, ako je broj čvorova u prvom skrivenom sloju 500, potrebno je 392 500 parametara u cijelom konečničkom sloju. Crno-bijela slika može se promatrati kao dvodimenzionska matrica sastavljena od podataka. Kada je broj čvorova pretjerano velik, brzina treniranja ANN-a se smanjuje. Ako dođe do pretreniranja, to će također utjecati na točnost.

Primjenu konvolucijske neuronske mreže prvi su predložili LeCun i sur. [40] i postigli su točnost od 99,7 % za skup podataka MNIST. Konvolucijska neuronska mreža povećava

Tablica 1. Pojedinosti o konvolucijskoj neuronskoj mreži (CNN-u)

	Slojevi	Ulagani oblik	Veličina jezgre	Broj jezgre	Stope	Razmak	Aktivacija	Izlazni oblik
CNN0 / CNN1 / CNN2	Conv1	(500,3)	10	16	1	Jednako	ReLU/tanh/Sigm	(500,16)
	Pooling1	(500,16)	4	Nema	4	Valjano	Nema	(125,16)
	Conv2	(125,16)	10	32	1	Jednako	ReLU/tanh/Sigm	(125,32)
	Pooling2	(125,32)	4	Nema	4	Jednako	Nema	(32,32)
	Conv3	(32,32)	10	64	1	Jednako	ReLU/tanh/Sigm	(32,64)
	Pooling3	(32,64)	4	Nema	4	Valjano	Nema	(8,64)
	Izravnajajući	(8,64)	Nema	Nema	Nema	Nema	Nema	(512)
	Dense1	(512)	Nema	Nema	Nema	Nema	ReLU/tanh/Sigm	(128)
	Dense2	(128)	Nema	Nema	Nema	Nema	Softmax	(4)
CNN3	Conv1	(500,3)	10	16	1	Jednako	ReLU	(500,16)
	Pooling1	(500,16)	4	Nema	4	Valjano	Nema	(125,16)
	Conv2	(125,16)	10	32	1	Jednako	ReLU	(125,32)
	Pooling2	(125,32)	4	Nema	4	Jednako	Nema	(32,32)
	Izravnajajući	(32,32)	Nema	Nema	Nema	Nema	Nema	(1024)
	Dense1	(1024)	Nema	Nema	Nema	Nema	ReLU	(128)
	Dense2	(128)	Nema	Nema	Nema	Nema	Softmax	(4)
CNN4	Conv1	(500,3)	10	16	1	Jednako	ReLU	(500,16)
	Pooling1	(500,16)	4	Nema	4	Valjano	Nema	(125,16)
	Conv2	(125,16)	10	32	1	Jednako	ReLU	(125,32)
	Pooling2	(125,32)	4	Nema	4	Jednako	Nema	(32,32)
	Conv3	(32,32)	10	64	1	Jednako	ReLU	(32,64)
	Pooling3	(32,64)	4	Nema	4	Valjano	Nema	(8,64)
	Conv4	(8,64)	4	128	1	Valjano	ReLU	(5,128)
	Pooling4	(5,128)	2	Nema	2	Valjano	Nema	(2,128)
	Izravnajajući	(2,128)	Nema	Nema	Nema	Nema	Nema	(256)
	Dense1	(256)	Nema	Nema	Nema	Nema	ReLU	(128)
	Dense2	(128)	Nema	Nema	Nema	Nema	Softmax	(4)



Slika 5. Primjeri podataka o ubrzanju u vremenskoj i frekvencijskoj domeni

dubinu matrice kroz konvolucijske slojeve i slojeve udruživanja, smanjuje dimenzijskost i broj parametara koji se upotrebljavaju za rad te je osjetljivija na složene podatke i matrice, čime se može poboljšati preciznost. Podaci o vremenskom ubrzanju korišteni u ovom istraživanju mogu se smatrati jednodimenzionalnim matricom. Kao što je prikazano u tablici 1., razvijeno je pet konvolucijskih neuronskih mreža za rješavanje ovog problema. CNN0, CNN1 i CNN2 imali su istu strukturu mreže, ali različite funkcije za aktivaciju. CNN3 i CNN4 smanjili su, odnosno povećali broj konvolucijskih i slojeva udruživanja. Na slici 5. Prikazan je opći radni postupak koristeći CNN0 kao primjer. Postoje 422

skupine ulaznih podataka, od kojih svaka sadrži 500 elemenata, uključujući tri kanala na vodoravnoj, uspravnoj i aplikatnoj osi. Tri konvolucijska sloja i tri sloja stvaraju matricu veličine $8 \times 1 \times 64$, pri čemu 64 predstavlja dubinu. Zatim se pretvara u vektor od 512 elemenata kroz izravnavački sloj. Klasifikacija se naposljetku odvija kroz posljednja dva gusta sloja.

2.2.1. Konvolucijski sloj

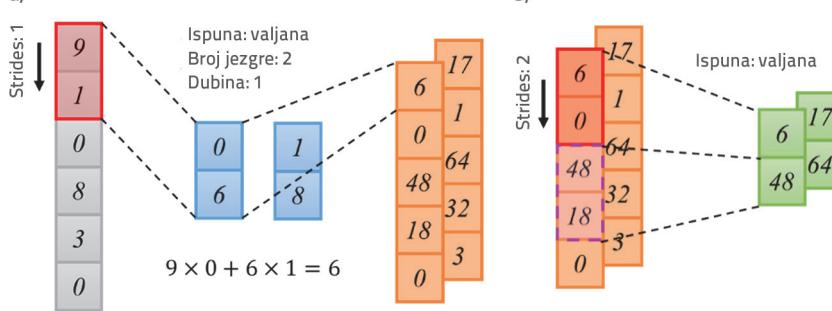
Konvolucijski sloj primijenjen je za proširenje dimenzija matrice. Konvolucijski sloj sastojao se od konvolucijske jezgre. Dubina jezgre mora biti jednaka dubini ulazne matrice. Na primjer, ulazna veličina sloja Conv2 iznosila je 125, dubina 16, veličina i dubina konvolucijske jezgre iznosile su 10 odnosno 16, a broj jezgri bio je 32. Nakon konvolucije, jezgra se pomiče jedan korak odozgo prema dolje i konvoluirala s ulaznom matricom da stvari novu matricu dubine 32. Ako je odmak postavljen na "isto", duljina izlaznog vektora ostaje ista kao i ulaznog vektora. Ako je odmak "važeći", izlazna duljina iznosi $125 - 10 + 1 = 116$. Slika 6(a) oslikava načelo konvolucijskih slojeva pomoću jednostavnog vektora stupca.

2.2.2. Sloj udruživanja

Osnovna funkcija sloja udruživanja jest smanjiti dimenzije ulazne matrice i odrediti značajke. Kao što je ranije spomenuto, nakon završetka operacije Conv2, matrica ulazi u sloj udruživanja. Veličina je 125; veličina jezgre i stope su 4, a od vrha prema dolje odabire se najveća vrijednost za svaka četiri elementa. Ako je odmak "isti", 125 je pomaknuto na 128, što ga čini djeljivim s 4, a izlazna veličina je 32. Ako je odmak "važeći", uzima se cijeli broj nakon dijeljenja, a rezultat je 31. Slika 6.b prikazuje princip sloja udruživanja s izlazom prikazanim na slici 6.a.

2.2.3. Gosti sloj

Gasti sloj funkcioniра kao "klasifikator" u čitavoj konvolucijskoj neuronskoj mreži. Ako operacije konvolucijskog sloja, sloja udruživanja i funkcije preslikaju izvorne podatke u prostor značajki skrivenog sloja, gasti sloj preslikava naučeno "distribuiran prikaz značajki" u prostor oznake uzorka. Nakon slojeva Pooling3 i poravnavajućeg sloja, ulazni podaci se

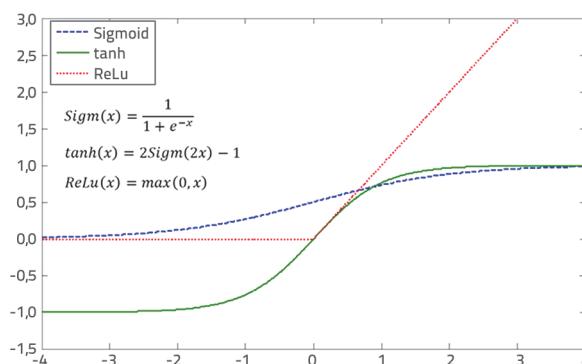


Slika 6. Primjeri konvolucijskog sloja i sloja udruživanja: a) Konvolucijski sloj; b) Sloj udruživanja

proširuju u vektor od 1×512 , 512 čvorova obrađuje sloj Dense1 kako bi stvorili vektor od 1×128 , a konačni vektor od 1×4 dobiva se pomoću funkcije softmax u sloju Dense2, što odgovara četirima kategorijama stanja kolnika.

2.2.4. Funkcije za aktivaciju

U konvolucijskim i gustim slojevima upotrebljava se funkcija za aktivaciju. Za sloj opisan na slici 6, funkcija aktivacije nije predstavljena kada se prednost daje jednostavnosti konvolucije i intuitivnosti. Funkcija aktivacije aktivira dio neurona u mreži i prenosi informacije o aktivaciji na sljedeći sloj neuronske mreže. Uzimajući neuronsku mrežu prikazanu na slici 5. kao primjer, ako funkcija aktivacije nije dodana, izlaz prvog čvora prvog skrivenog sloja bit će $y = x_1 w_{11} + x_2 w_{12}$; međutim, ova metoda klasifikacije ne može riješiti problem linearne neodvojivosti, a funkcija aktivacije uvodi nelinearne čimbenike za rješavanje neadekvatnog izraza linearog modela. Na primjeru slike 5. i pod pretpostavkom da je aktivacijska funkcija $f(x)$, izlaz je $y = f(x_1 w_{11} + x_2 w_{12})$. Kao što je prikazano na slici 7., standardne nelinearne aktivacijske funkcije su sigmoid, tanh i ReLU. ReLU je najčešće korišten.

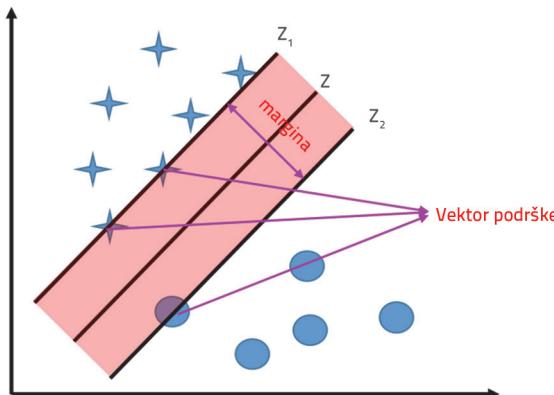


Slika 7. Primjeri podataka o ubrzavanju u vremenskoj i frekvencijskoj domeni

2.3. Stroj potpornih vektora (SVM)

SVM su prvi predložili Cortes i Vapnik [41]. Kada se radi o problemima klasifikacije, glavni cilj je pronaći hiperravninu koja odvaja točke uzorka za treniranje, a istovremeno minimizira pogrešku klasifikacije. U slučajevima linearne separabilnosti, jedna ili više hiperravnina mogu u potpunosti razdvojiti uzorce za treniranje. Cilj SVM-a je pronaći optimalno rješenje.

Slika 8. prikazuje problem klasifikacije za dvodimenzionske podatke u kojima je hiperravnina ravna linija. Kada se radi o trodimenzionskim prostornim podacima, hiperravnina postaje 2D ravnina. Hiperravnina se može opisati pomoću izraza:



Slika 8. Princip stroja potpornih vektora

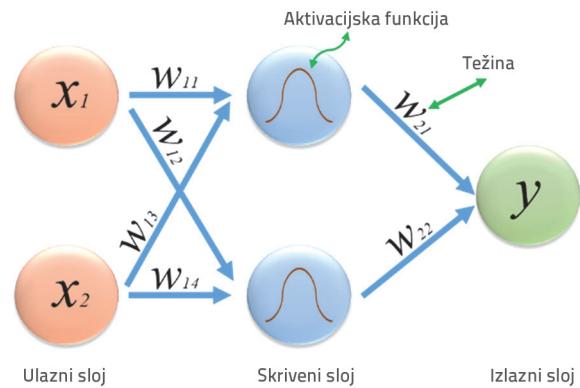
$$\omega^t x + b = 0$$

gdje x predstavlja dvodimenzione koordinate točaka, a Z predstavlja hiperravninu. Z_1 i Z_2 najčešće su paralele linije Z za sve uzorce. Udaljenost između Z_1 i Z_2 je klasifikacijska granica između dva tipa uzorka, a točke uzorka za treniranje na osi Z_1 i Z_2 nazivaju se potporni vektori. Cilj je pronaći vektor ω^t i b putem treniranja kako bi se maksimizirala udaljenost između Z_1 i Z_2 i postigla optimalna klasifikacija.

Kernel funkcija se primjenjuje kada je problem linearno neodvojiv [42]. Osnovna ideja za korištenje jezgrene funkcije za rješavanje problema linearne neodvojivosti je mapiranje izvornog uzorka u visokodimenzionalni prostor, što omogućuje linearno odvajanje u visokodimenzionalnom prostoru značajki. Zatim se za klasifikaciju primjenjuje linearni klasifikator SVM. LIBSVM, računalni program za SVM, koji je razvilo Tajvansko sveučilište [43], upotrijebljen je za konstrukciju klasifikacijskog modela.

2.4. Neuronska mreža s radikalno zasnovanom funkcijom (RBF neuronska mreža)

Pojam neuronske mreže s radikalno zasnovanom funkcijom (engl. Radical Basis Function Neural Network) ili RBF neuronske mreže predstavili su Broomhead i Lowe [44]. Kao što je prikazano na slici 9, RBF neuronska mreža je troslojna mreža s jednim skrivenim slojem. Prvi sloj je ulazni sloj, koji se sastoji od čvorova izvora signalata. Drugi sloj je skriveni sloj, a broj čvorova u skrivenom sloju ovisi o specifičnom problemu koji se rješava. Aktivacijska funkcija neurona u skrivenom sloju, tj. funkcija radikalne baze, radikalno je simetrična i oslabljena nelinearna funkcija središnje točke. Često upotrijebljena funkcija aktivacije općenito je Gaussova funkcija. Treći sloj je izlazni sloj, koji odgovara ulazu i primjenjuje strategiju linearne optimizacije. Glavna je ideja primijeniti RBF kao "osnovu" za formiranje prostora skrivenog sloja. Skriveni sloj transformira niskodimenzionske podatke u visokodimenzionalni prostor, čime omogućuje da se linearno neodvojivi problem linearno odvoji u ovom prostoru. Mrežni model RBF-a aktivacijska funkcija mogu se izraziti pomoću izraza (1) i (2):



Slika 9. Princip RBF neuronske mreže

$$y_j = \sum_{i=1}^n w_{ij} \phi\left(\|x - u_i\|^2\right), (j = 1, \dots, p) \quad (1)$$

$$\phi(x - u_i, \|x - u_i\|^2) = e^{-\frac{\|x - u_i\|^2}{\sigma^2}} \quad (2)$$

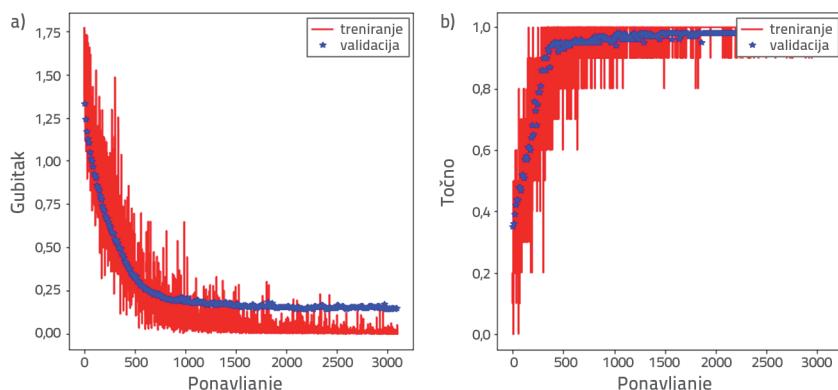
gdje u_{ja} je središnja točka dobivena upotrebom k-means algoritma. ϕ je Gaussova funkcija koja se primjenjuje kao funkcija aktivacije, σ može se izračunati pomoću KNN algoritma, a w_{ij} je težina.

3. Utvrđivanje stanja kolnika

3.1. Rezultati utvrđivanja stanja dobiveni primjenom jednodimenzionske konvolucijske neuronske mreže

U ovom istraživanju treniranje CNN-a izvedeno je pomoću Pythona. Izvorni podaci o ubrzanju u vremenskoj domeni korišteni su izravno tijekom treniranja. Broj kanala postavljen je na tri, što odgovara X-, Y- i Z-osi. Od skupa podataka, 80 % je upotrijebljeno za treniranje, 20 % je upotrijebljeno kao skup za provjeru valjanosti, a 422 skupine izvornih podataka o ubrzanju upotrijebljene su za testiranje učinkovitosti klasifikacije modela. Skup za treniranje upotrijebljen je za prilagodbu i konstrukciju modela, koji je preliminarno ocijenjen pomoću skupa za validaciju.

Veličina serije predstavlja broj uzoraka treniranih u svakom koraku. Brzina učenja određuje brzinu konvergencije modela. U ovom istraživanju veličina serije i stopa učenja postavljeni su na 10 odnosno 0,0001. Epoha je postavljena na 100, a epoha je trenirana jednom sa svih 337 uzoraka u skupu za treniranje; stoga je broj ponavljanja bio 3370. Slike 10.a i 10.b prikazuju krivulje gubitka i točnosti u odnosu na ponavljanja za CNN. Točnost je omjer broja ispravno klasificiranih uzoraka prema ukupnom broju uzoraka. Što je veća točnost, to je bolja klasifikacijska izvedba modela. Gubitak mjeri stupanj nedosljednosti između predviđenih i stvarnih vrijednosti, on je ne-negativna realna funkcija gubitka. Što je manja funkcija gubitka, to



Slika 10. Rezultati treniranja i preciznosti za CNN0: a) Krivulja gubitka i ponavljanja; b) Krivulja preciznosti i ponavljanja

je model robustniji. Povećanjem broja ponavljanja, vrijednost gubitka kontinuirano se smanjivala i napisljeku stabilizirala. To dokazuje da je model konvergirao. Istodobno, točnost se i dalje povećavala. Točnost treniranja i točnost validacije CNN0 dosegle su 1,00 odnosno 0,99, a točnost testa dosegla je 0,9976, s 421 pravilno razvrstanim uzorkom.

Pojedinosti o rezultatima treniranja za CNN0-CNN4 navedene su u tablici 2, uključujući Preciznost, Opoziv i Točnost. Metoda izračuna je kako slijedi.

$$\text{Preciznost} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Opoziv} = \frac{TP}{TP + FN} \quad (4)$$

pri čemu su stvarno pozitivni (TP) i lažno pozitivni (FP) broj uzoraka koji su ispravno i netočno klasificirani kao pozitivni.

Tablica 2. Pojedinosti o rezultatima konvolucijske neuronske mreže (CNN-a)

	CNN0	CNN1	CNN2	CNN3	CNN4
TRA	1,0000	1,0000	0,9100	1,0000	1,0000
VDA	0,9900	0,9700	0,8500	0,9800	0,9900
TEA	0,9976	0,9900	0,8571	0,9952	0,9976
CCI	421	417	361	420	421
BPP	1,0000	0,9727	0,8774	0,9907	1,0000
BPR	1,0000	0,9907	0,8611	0,9907	0,9907
SBP	1,0000	1,0000	0,7578	1,0000	1,0000
SBR	1,0000	0,9898	0,9798	1,0000	1,0000
SPP	0,9900	1,0000	0,9072	1,0000	1,0000
SPR	1,0000	0,9912	0,7788	0,9912	1,0000
PTP	1,0000	0,9804	0,9326	0,9902	0,9902
PTR	0,9902	0,9804	0,8137	1,0000	1,0000

TRA: Točnost treniranja; VDA: točnost valjanosti; TEA: točnost testa; CCI: primjeri ispravne klasifikacije; BPP: preciznost za neravni kolnik; BPR: opoziv za neravni kolnik; SBP: preciznost za uspornik; SBR: opoziv za uspornik; SPP: preciznost za ravn kolnik; SPR: opoziv za ravn kolnik; PTP: polna preciznost; PTR: opoziv za udarne rupe u kolniku

Lažno negativan (FN) je broj netočno klasificiranih negativnih uzoraka. Na primjeru udarnih rupa na kolniku u CNN0, pravilno je utvrđena 101 skupina od 102, pri čemu je jedna pogrešno klasificirana kao uspornik te nije druga vrsta kolnika nije pogrešno klasificirana kao udarna rupa na cesti. Stoga vrijedi:

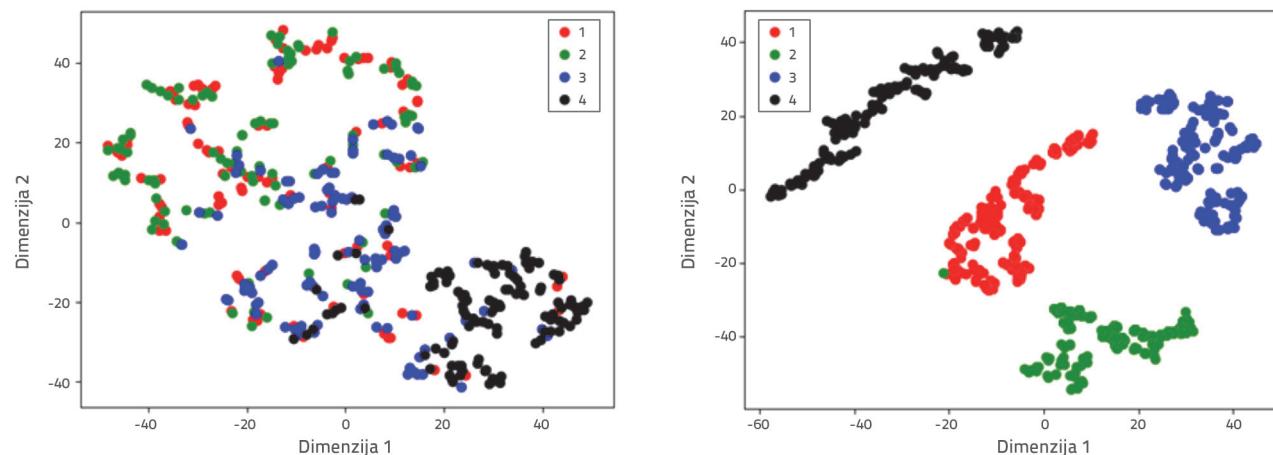
$$TP = 101, FP = 0, FN = 1,$$

$$\text{Preciznost} = 101/101 = 1,0000,$$

$$\text{Opoziv} = 101/102 = 0,9907.$$

Tablica 2. pokazuje da promjena u funkciji aktivacije ima značajan učinak na rad CNN-a. Točnost CNN1 primjenom tanh funkcije i CNN2 primjenom sigmoidne

funkcije bila je 0,9900 odnosno 0,8571. To je zbog činjenice da se u povratnom širenju težina w izračunava pomoću diferencijala. U tanh funkciji i sigmoidu, kada je ulazna vrijednost velika ili mala, izlaz je gotovo ravan, a gradijent je minimalan, što otežava ažuriranje pondera. Ovaj problem je također poznat kao gradijent zasićenja. Izlazni interval za tanh je (-1,1), a cijela je funkcija centrirana na nulu. Zasićenost gradijenta je manje izražena od sigmoidne funkcije; stoga CNN1 ima veću točnost. Za popularnu ReLU funkciju, kada je unos pozitivan, nema problema sa zasićenjem gradijenta, a budući da ReLU ima jednostavan linearan odnos, brzina izračuna je puno brža. Nakon uklanjanja konvolucijskih i slojeva udruživanja, točnost CNN3 smanjena je na 0,9952; međutim, i dalje se pokazao zadovoljavajućim za klasifikaciju. CNN0 i CNN4 imali su najbolji učinak klasifikacije. Svaki od 421 slučaja bili su ispravno klasificirani, a točnost je bila 0,9976. S obzirom na to da je CNN0 imao jednostavniju strukturu mreže, vjerujemo da je CNN0 imao najbolji učinak klasifikacije.



Slika 11. Dvodimenzionalni prikaz neobrađenih podataka i izlaznih podataka (1-uspornik, 2-udarne rupe, 3-neravni kolnik, 4-ravni kolnik)

Konačno, kako bismo intuitivnije prikazali klasifikacijski učinak modela, upotrijebili smo alat za vizualizaciju pod nazivom "t-SNE (t-distribuirano stohastičko umetanje u susjedstvo)", koji može smanjiti dimenziju podataka nelinearno, posebno za vizualizaciju visokodimenzijalnih podataka. Korišten je za vizualizaciju sirovih i izlaznih podataka iz CNN-a. Kao što je prikazano na slici 11., nakon smanjenja dimensijskosti nema očite razlike između različitih klasa na dvodimenzionalnoj ravnini. Međutim, nakon CNN klasifikacije, bilo je primjetnih razlika među ostalim klasama, što dokazuje da je CNN imao izvrsnu klasifikacijsku izvedbu.

3.2. Rezultati otkrivanja pomoću algoritma za strojno učenje

3.2.1. Skup podataka

U ovom istraživanju, dva tradicionalna algoritma strojnog učenja, SVM i neuronska mreža s radikalno zasnovanom

funcijom (RBF), odabrana su za usporedbu s CNN-om. Kao što je prije spomenuto, CNN primjenjuje konvolucijske slojeve i slojeve udruživanja za izdvajanje obilježja, a zatim ih klasificira kroz guste slojeve. Stoga nije bilo potrebno izdvojiti značajke prije unosa podataka. Iako su SVM i RBF mreže klasifikatori, moraju izdvojiti značajke prije unosa podataka o ubrzanju.

Za razliku od CNN-a, skupovi podataka koji se upotrebljavaju u SVM i RBF mrežama sastoje se od vrijednosti značajki. 26 značajki vremenske i frekvencijske domene izračunato je pomoću MATLAB-a, a svaka značajka sadržavala je tri smjera, X, Y i Z; pri čemu je dobiveno ukupno 78 vrijednosti atributa. Zatim je njih 28 odabrano pomoću funkcije "CfsSubsetEval" u alatu WEKA. Vrijednosti atributa navedene u tablici 3. od 1 do 57 su iz vremenske domene (TD), a ostala su iz frekvencijske domene (FD). Naposljetku smo dobili skup podataka koji se sastoji od matrice 422×29 , čiji je posljednji stupac bio označen.

Tablica 3. Vrste atributa

Broj	Atribut	Broj	Atribut
1-3	Srednja vrijednost TD (x/y/z)	40-42	TD faktor impulsa (x/y/z)
4-6	TD varijanca (x/y/z)	43-45	TD margina (x/y/z)
7-9	TD Koeficijent korelacije (xy/xz/yz)	46-48	TD spljoštenost (x/y/z)
10-12	TD Maksimum (x/y/z)	49-51	TD faktor valnog oblika
13-15	TD Minimum (x/y/z)	52-54	TD zakrivljenost (x/y/z)
16-18	TD Standardna devijacija (x/y/z)	55-57	Srednja vrijednost FD (x/y/z)
19-21	TD od vrha do vršne vrijednosti (x/y/z)	58-60	FD standardna devijacija (x/y/z)
22-24	TD medijan (x/y/z)	61-63	FD maksimum (x/y/z)
25-27	TD Apsolutna vršna vrijednost (x/y/z)	64-66	FD vršna frekvencija (x/y/z)
28-30	TD Apsolutna srednja vrijednost (x/y/z)	67-69	FD vršni faktor (x/y/z)
31-33	TD Korijen srednje kvadratne vrijednosti (x/y/z)	70-72	FD spljoštenost (x/y/z)
34-36	TD interkvartilni raspon (x/y/z)	73-75	FD zakrivljenost (x/y/z)
37-39	TD vršni faktor (x/y/z)	76-78	FD entropija (x/y/z)
Odabrani atributi	2, 3, 5, 8, 9, 19, 24, 26, 30, 34, 35, 36, 38, 39, 45, 46, 47, 50, 51, 52, 57, 58, 59, 64, 65, 66, 68, 69		

Tablica 4. Rezultati testiranja pomoću SVM-a (funkcija jezgre: Radijalna bazna funkcija)

Klasifikacija:	Neravan kolnik	Kolnik s uspornicima	Ravan kolnik	Kolnik s udarnim rupama
Neravan kolnik	91	7	8	2
Kolnik s uspornicima	0	98	0	1
Ravan kolnik	6	3	104	0
Kolnik s udarnim rupama	1	7	0	94

Tablica 5. Rezultati testiranja pomoću SVM-a (funkcija jezgre: Polinom)

Klasifikacija:	Neravan kolnik	Kolnik s uspornicima	Ravan kolnik	Kolnik s udarnim rupama
Neravan kolnik	99	0	2	7
Kolnik s uspornicima	0	97	0	2
Ravan kolnik	2	0	110	1
Kolnik s udarnim rupama	2	1	0	99

Tablica 6. Rezultati testiranja korištenjem RBF mreže

Klasifikacija:	Neravan kolnik	Kolnik s uspornicima	Ravan kolnik	Kolnik s udarnim rupama
Neravan kolnik	105	0	0	3
Kolnik s uspornicima	0	98	0	1
Ravan kolnik	1	0	112	0
Kolnik s udarnim rupama	1	0	0	101

3.2.2. Rezultati utvrđivanja stanja

Primjenjene su dvije različite funkcije za aktivaciju neuronske mreže SVM-a (radijalna bazna funkcija i polinom) i RBF-a, a metoda deseterostrukog unakrsne validacije usvojena je za test klasifikacije. Rezultati su sažeti u tablicama 4. do 6. Broj ispravno klasificiranih instanci bio je 387, 405 i 417, a točnosti su iznosile 0,9171, 0,9597, odnosno 0,9858.

3.3. Usporedba

CNNO, koji je imao najbolje rezultate klasifikacije među CNN-ovima, odabran je za usporedbu sa SVM i RBF neuronskim mrežama. Rezultati su navedeni u tablici 7. Jasno se vidi da CNNO ima najbolji učinak. CNNO je postigao točnost od 0,9976, što je 8,1 %, 3,8 % i 1,2 % više od rezultata ostalih triju algoritama. Ovo dokazuje da CNN ne samo da može klasificirati objekte na

Tablica 7. Pojedinosti rezultata usporedbe

	CNNO	SVMR	SVMP	RBF
TA	0,9976	0,9171	0,9597	0,9858
CCI	421	387	405	416
BPP	1,0000	0,9286	0,9612	0,9813
BPR	1,0000	0,8426	0,9167	0,9722
SBP	1,0000	0,8522	0,9898	1,0000
SBR	1,0000	0,9899	0,9798	0,9899
SPP	1,0000	0,9286	0,9821	1,0000
SPR	0,9907	0,9204	0,9735	0,6612
PTP	0,9902	0,9691	0,9083	0,9619
PTR	1,0000	0,9216	0,9706	0,9902

TA: točnost testa; CCI: primjeri ispravne klasifikacije; BPP: preciznost za neravni kolnik; BPR: opoziv za neravni kolnik; SBP: preciznost za uspornik; SBR: opoziv za uspornik; SPP: preciznost za ravn kolnik; SPR: opoziv za ravn kolnik; PTP: polna preciznost; PTR: opoziv za udarne rupe u kolniku

slikama, već se također može primijeniti za otkrivanje podataka o ubrzaju. U usporedbi s tradicionalnim algoritmima strojnog učenja, CNN ne zahtijeva ručno izdvajanje značajki, što cijeli proces otkrivanja i klasifikacije čini učinkovitijim. CNN je idealan za primjenu na probleme s jednodimenzijskim podacima.

4. Rasprava

Ovaj rad predlaže novu metodu otkrivanja stanja kolnika. Predlaže se metoda otkrivanja stanja kolnika koja se temelji na sudjelovanju javnosti. Primjenom široko dostupnih bicikala i pametnih telefona, šira javnost može sudjelovati u prikupljanju podataka i procjeni stanja kolnika, što omogućuje stručnjacima da naprave daljnje procjene na temelju sažetih podataka bez potrebe za inspekcijsama na licu mjesta, što može značajno poboljšati operativnu učinkovitost.

Što se tiče tehničkih sredstava za otkrivanje, predložili smo primjenu jednodimenzijskog CNN-a. Za razliku od drugih istraživanja, primjena jednodimenzijske konvolucijske neuronske mreže ne zahtijeva postavljanje specifičnih pragova ili ručno dizajniranje i izdvajanje značajki. Ovo istraživanje također ima ograničenja kojima se treba pozabaviti u budućim istraživanjima:

- Generalizacija predložene metode još nije ispitana. Prikupljanje podataka u ovom istraživanju uglavnom je provedeno na sveučilišnom kampusu, a potrebno je više podataka o treniranju, kao i više kategorija cestovnih stanja, kao što su kolotrazi i valovi, kako bi se postigli bolji praktični rezultati.
- podaci o ubrzaju pri više brzina vožnje nisu prikupljeni. U sudjelovanju javnosti u stvarnom svijetu, brzine vožnje različitih pojedinaca mogu se značajno razlikovati, stoga se moraju prikupiti podaci o ubrzaju pri različitim brzinama vožnje. Osim toga, modeli pametnih telefona mogu utjecati na konačne podatke, što zahtijeva analizu podataka prikupljenih s različitih modela telefona.

5. Zaključak

Predložena je metoda otkrivanja stanja kolnika koja primjenjuje klasifikaciju podataka o ubrzaju na temelju CNN-a. U eksperimentu su prikupljene 422 skupine podataka o ubrzaju, uključujući X-, Y- i Z-osi pomoću pametnog

telefona i bicikla, a podaci su se prikupljali za neravan kolnik, kolnik s uspornicima, ravn kolnik i udarne rupe na kolniku. Pet 1D-CNN-ova projektirano je i trenirano kao detektori, što je dovelo do sljedećih zaključaka:

- U klasificiranju i otkrivanju podataka o ubrzaju u ovom istraživanju, aktivacijska funkcija ReLU ima bolji učinak.
- Dodavanje konvolucijskih slojeva i slojeva udruživanja poboljšat će sposobnost izdvajanja značajki i klasifikacije.
- 1D-CNN s dva konvolucijska sloja, dva sloja za udruživanje i aktivacijskom funkcijom ReLU postigao je točnost klasifikacije od 0,9976, što je bila najbolja izvedba među pet CNN-ova.
- Upotreboom CNN-a nema potrebe za projektiranjem i ručnim izvlačenjem vrijednosti značajki, stoga je učinkovitiji od tradicionalnih algoritama strojnog učenja.
- Među algoritmima strojnog učenja primjenjenim u ovoj studiji, RBF neuronske mreže pokazale su veću točnost klasifikacije.

Novost ovog istraživanja je procjena temeljena na sudjelovanju javnosti. Umjesto fokusiranja CNN-a samo na slikovne podatke, upotrijebili smo ga za obradu podataka o ubrzaju vremenskih serija i postigli zadovoljavajuće rezultate prepoznavanja. Ovo je istraživanje imalo neka ograničenja u smislu generalizacije i plana pokusa. U budućim istraživanjima prikupit će se dodatni podaci kako bi se poboljšala sposobnost generalizacije mrežnog modela i proveli eksperimenti prikupljanja podataka s različitim brzinama vožnje i pametnim telefonima. Osim toga, poboljšat ćemo primjenu analize ubrzanja kolnika kako bi se što prije mogla implementirati u malim razmjerima.

Zahvala

Ovaj je rad financiran od strane Programa temeljnih istraživanja za sveučilišta Odjela za obrazovanje provincije Liaoning u okviru bespovratnih sredstava JYTQN2023241, Programa za izvanredne mlade znanstvenike Sveučilišta za znanost i tehnologiju Liaoning u okviru bespovratnih sredstava 2023YQ03 i u okviru bespovratnih sredstava putem projekta za talente Sveučilišta za znanost i tehnologiju Liaoning.

LITERATURA

- [1] Hrapović, K.: Sustainability in road construction – Two case studies, GRAĐEVINAR, 76 (2024) 5, pp. 413-423, <https://doi.org/10.14256/JCE.3979.2024>.
- [2] Zhang, Y., Li, H., Zhang, Y., Zang, W., Yao, K.: Optimal prioritisation of asphalt pavement maintenance using grey relation analysis and cost-benefit analysis, GRAĐEVINAR, 75 (2023) 12, pp. 1155-1164, <https://doi.org/10.14256/JCE.3822.2023>.
- [3] Pradena, M., Houben, L., César, A.: Experimental evaluation of load transfer efficiency of non-dowelled concrete pavements, GRAĐEVINAR, 74 (2022) 3, pp. 179-187, <https://doi.org/10.14256/JCE.2844.2019>.
- [4] Gáspár, L., Bencze, Z.: Increasing the life expectancy of road pavements, GRAĐEVINAR, 72 (2020) 6, pp. 515-522, <https://doi.org/10.14256/JCE.2644.2019>.

- [5] Chang, K.T., Chang, J.R., Liu, J.K.: Detection of pavement distresses using 3D laser scanning technology, In Computing in civil engineering (2005), pp. 1-11, [https://doi.org/10.1061/40794\(179\)103](https://doi.org/10.1061/40794(179)103).
- [6] Li, Q., Yao, M., Yao, X., Xu, B.: A real-time 3D scanning system for pavement distortion inspection, Measurement Science and Technology, 21 (2009) 1, 015702, <https://doi.org/10.1088/0957-0233/21/1/015702>.
- [7] Wang, K.C.: Challenges and feasibility for comprehensive automated survey of pavement conditions, In Applications of advanced technologies in transportation engineering (2004), pp. 531-536, [https://doi.org/10.1061/40730\(144\)99](https://doi.org/10.1061/40730(144)99).
- [8] Hou, Z., Wang, K.C., Gong, W.: Experimentation of 3D pavement imaging through stereovision, In International Conference on Transportation Engineering 2007, pp. 376-381, [https://doi.org/10.1061/40932\(246\)62](https://doi.org/10.1061/40932(246)62).
- [9] Joubert, D., Tyatyaantsi, A., Mphahlele, J., Manchidi, V.: Pothole tagging system, In Proceedings of the 4th Robotics and Mechatronics Conference of South Africa, (2011), pp. 1-4.
- [10] Moazzam, I., Kamal, K., Mathavan, S., Usman, S., Rahman, M.: Metrology and visualization of potholes using the microsoft kinect sensor, In 16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013), pp. 1284-1291, <https://doi.org/10.1109/ITSC.2013.6728408>.
- [11] Koch, C., Brilakis, I.: Pothole detection in asphalt pavement images, Advanced Engineering Informatics, 25 (2011) 3, pp. 507-515, <https://doi.org/10.1016/j.aei.2011.01.002>.
- [12] Hoang, N.D.: An artificial intelligence method for asphalt pavement pothole detection using least squares support vector machine and neural network with steerable filter-based feature extraction, Advances in Civil Engineering, 2018, <https://doi.org/10.1155/2018/7419058>.
- [13] Eisenbach, M., Stricker, R., Seichter, D., Amende, K., Debes, K., Sesselmann, M., Gross, H.M.: How to get pavement distress detection ready for deep learning? A systematic approach, In 2017 International Joint Conference on Neural Networks (IJCNN), pp. 2039-2047, <https://doi.org/10.1109/IJCNN.2017.7966101>.
- [14] Li, B., Wang, K.C., Zhang, A., Yang, E., Wang, G.: Automatic classification of pavement crack using deep convolutional neural network, International Journal of Pavement Engineering, 21 (2020) 4, pp. 457-463, <https://doi.org/10.1080/10298436.2018.1485917>.
- [15] Arya, D., Maeda, H., Ghosh, S.K., Toshniwal, D., Mraz, A., Kashiyama, T., Sekimoto, Y.: Deep learning-based road damage detection and classification for multiple countries, Automation in Construction, 132 (2021), 103935, <https://doi.org/10.1016/j.autcon.2021.103935>.
- [16] Du, Y., Pan, N., Xu, Z., Deng, F., Shen, Y., Kang, H.: Pavement distress detection and classification based on YOLO network, International Journal of Pavement Engineering, 22 (2021) 13, pp. 1659-1672, <https://doi.org/10.1080/10298436.2020.17114047>.
- [17] Li, L., Fang, B., Zhu, J.: Performance Analysis of the YOLOv4 Algorithm for Pavement Damage Image Detection with Different Embedding Positions of CBAM Modules, Applied Sciences, 12 (2022) 19, 10180, <https://doi.org/10.3390/app121910180>.
- [18] Guo, G., Zhang, Z.: Road damage detection algorithm for improved YOLOv5, Scientific Reports, 12 (2022) 1, 1-12, <https://doi.org/10.1038/s41598-022-19674-8>.
- [19] Shoaib, M., Bosch, S., Incel, O.D., Scholten, H., Havinga, P.J.: Complex human activity recognition using smartphone and wrist-worn motion sensors, Sensors, 16 (2016) 4, 426, <https://doi.org/10.3390/s16040426>.
- [20] Koskimaki, H., Huikari, V., Siirtola, P., Laurinen, P., Roning, J.: Activity recognition using a wrist-worn inertial measurement unit: A case study for industrial assembly lines, In 2009 17th Mediterranean Conference on Control and Automation, pp. 401-405, <https://doi.org/10.1109/MED.2009.5164574>.
- [21] Ryu, J., Seo, J., Jebelli, H., Lee, S.: Automated action recognition using an accelerometer-embedded wristband-type activity tracker, Journal of Construction Engineering and Management, 145 (2019) 1, 04018114, [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001579](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001579).
- [22] Sanhudo, L., Calvetti, D., Martins, J.P., Ramos, N.M., Mêda, P., Gonçalves, M.C., Sousa, H.: Activity classification using accelerometers and machine learning for complex construction worker activities, Journal of Building Engineering, 35 (2021), 102001, <https://doi.org/10.1016/j.jobe.2020.102001>.
- [23] Zhang, Y., Yuen, K.V.: Review of artificial intelligence-based bridge damage detection, Advances in Mechanical Engineering, 14 (2022) 9, 16878132221122770, <https://doi.org/10.1177/16878132221122770>.
- [24] Bao, Y., Li, H.: Machine learning paradigm for structural health monitoring, Structural Health Monitoring, 20 (2021) 4, pp. 1353-1372, <https://doi.org/10.1177/1475921720972416>.
- [25] Feng, S., Jia, J.: Acceleration sensor placement technique for vibration test in structural health monitoring using microhabitat frog-leaping algorithm, Structural Health Monitoring, 17 (2018) 2, pp. 169-184, <https://doi.org/10.1177/1475921716688372>.
- [26] Pentaris, F.P., Stonham, J., Makris, J.P.: A cost effective wireless structural health monitoring network for buildings in earthquake zones, Smart Materials and Structures, 23 (2014) 10, 105010, <https://doi.org/10.1088/0964-1726/23/10/105010>.
- [27] Fan, G., Li, J., Hao, H.: Dynamic response reconstruction for structural health monitoring using densely connected convolutional networks, Structural Health Monitoring, 20 (2021) 4, pp. 1373-1391, <https://doi.org/10.1177/1475921720916881>.
- [28] Kazantzi, A.K., Vamvatsikos, D., Miranda, E.: Evaluation of seismic acceleration demands on building nonstructural elements, Journal of Structural Engineering, 146 (2020) 7, 04020118, [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0002676](https://doi.org/10.1061/(ASCE)ST.1943-541X.0002676).
- [29] Yu, B.X., Yu, X.: Vibration-based system for pavement condition evaluation, In Applications of advanced technology in transportation, pp. 183-189, [https://doi.org/10.1061/40799\(213\)31](https://doi.org/10.1061/40799(213)31).
- [30] Eriksson, J., Girod, L., Hull, B., Newton, R., Madden, S., Balakrishnan, H.: The pothole patrol: using a mobile sensor network for road surface monitoring, In Proceedings of the 6th International Conference on Mobile Systems, Applications, and Services, pp. 29-39, <https://doi.org/10.1145/1378600.1378605>.
- [31] Mednis, A., Strazdins, G., Zviedris, R., Kanonirs, G., Selavo, L.: Real time pothole detection using android smartphones with accelerometers, In 2011 International Conference on Distributed Computing in Sensor Systems and Workshops (DCOSS), pp. 1-6, <https://doi.org/10.1109/DCOSS.2011.5982206>.
- [32] Fox, A., Kumar, B.V., Chen, J., Bai, F.: Crowdsourcing undersampled vehicular sensor data for pothole detection, In 2015 12th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON), pp. 515-523, <https://doi.org/10.1109/SAHCN.2015.7338353>.
- [33] Bhatt, U., Mani, S., Xi, E., Kolter, J.Z.: Intelligent pothole detection and road condition assessment, arXiv preprint arXiv:1710.02595 (2017).

- [34] Du, R., Qiu, G., Gao, K., Hu, L., Liu, L.: Abnormal road surface recognition based on smartphone acceleration sensor, Sensors, 20 (2020) 2, 451, <https://doi.org/10.3390/s20020451>.
- [35] Yang, Q., Zhou, S.: Identification of asphalt pavement transverse cracking based on vehicle vibration signal analysis, Road Materials and Pavement Design, 22 (2021) 8, pp. 1780–1798, <https://doi.org/10.1080/14680629.2020.1714699>.
- [36] Egaji, O.A., Evans, G., Griffiths, M.G., Islas, G.: Real-time machine learning-based approach for pothole detection, Expert Systems with Applications, 184 (2021), 115562, <https://doi.org/10.1016/j.eswa.2021.115562>.
- [37] Zhang, Z., Zhang, H., Xu, S., Lv, W.: Pavement roughness evaluation method based on the theoretical relationship between acceleration measured by smartphone and IRI, International Journal of Pavement Engineering, (2021), <https://doi.org/10.1080/10298436.2021.1881783>.
- [38] Kong, Q., Allen, R.M., Kohler, M.D., Heaton, T.H., Bunn, J.: Structural health monitoring of buildings using smartphone sensors, Seismological Research Letters, 89 (2018) 2A, pp. 594–602, <https://doi.org/10.1785/0220170111>.
- [39] Figueiredo, E., Moldovan, I., Alves, P., Rebelo, H., Souza, L.: Smartphone Application for Structural Health Monitoring of Bridges, Sensors, 22 (2022) 21, 8483, <https://doi.org/10.3390/s22218483>.
- [40] LeCun, Y., Bottou, L., Bengio, Y., Haffner, P.: Gradient-based learning applied to document recognition, Proceedings of the IEEE, 86 (1998) 11, pp. 2278–2324, <https://doi.org/10.1109/5.726791>.
- [41] Cortes, C., Vapnik, V.: Support-vector networks, Machine Learning, 20 (1995) 3, pp. 273–297, <https://doi.org/10.1007/BF00994018>.
- [42] Amari, S.I., Wu, S.: Improving support vector machine classifiers by modifying kernel functions, Neural Networks, 12 (1999) 6, pp. 783–789, [https://doi.org/10.1016/S0893-6080\(99\)00032-5](https://doi.org/10.1016/S0893-6080(99)00032-5).
- [43] Chang, C.C., Lin, C.J.: LIBSVM: a library for support vector machines, ACM Transactions on Intelligent Systems and Technology (TIST), 2 (2011) 3, pp. 1–27, <https://doi.org/10.1145/1961189.1961199>.
- [44] Broomhead, D.S., Lowe, D.: Radial basis functions, multi-variable functional interpolation and adaptive networks, Royal Signals and Radar Establishment Malvern (United Kingdom), (1988).