

Primljen / Received: 17.6.2025.

Ispravljen / Corrected: 11.9.2025.

Prihvaćen / Accepted: 29.9.2025.

Dostupno online / Available online: 10.4.2026.

Preliminarno istraživanje procjene mase vozila na temelju zvučnih signala s prijelazne naprave mosta

Autori:



Mr.sc. **Shichao Qian**, dipl.ing.grad.
18155545324@163.com



Prof.dr.sc. **Xiaojuan Shu**, dipl.ing.grad.
254528003@qq.com
Autor za korespondenciju



Izv.prof.dr.sc. **Mingyan Shen**, dipl.ing.grad.
511272252@qq.com



Mr.sc. **Yili Luo**, dipl.ing.grad.
154674841@qq.com



Mr.sc. **Haopeng Dang**, dipl.ing.grad.
3026529583@qq.com

Znanstveno i tehnološko sveučilište u Hunanu, Kina
Građevinski fakultet

Prethodno priopćenje

Shichao Qian, Xiaojuan Shu, Mingyan Shen, Yili Luo, Haopeng Dang

Preliminarno istraživanje procjene mase vozila na temelju zvučnih signala s prijelazne naprave mosta

Ovo istraživanje predstavlja metodu za određivanje razine opterećenja vozila analizom karakteristika zvučnih signala proizvedenih tijekom prelaska vozila preko prijelazne naprave mosta. Predloženi je pristup neinvazivan i neovisan o uvjetima osvjetljenja, zahvaljujući čemu ima znatne prednosti u primjeni. Na početku provedena su eksperimentalna ispitivanja, a potom su analizom linije trenda amplitude zvučnog tlaka izdvojeni relevantni udarni zvučni signali, pri čemu su prethodno primijenjeni procesi filtriranja, prednaglašavanja signala te detekcije signala. Iz zvučnih su zapisa izdvojene karakteristične značajke signala u frekvencijskoj, vremenskoj i vremensko-frekvencijskoj domeni. Utvrđeno je da odnosi između kratkotrajne energije, entropije energije dobivene metodom empirijskog razlaganja (EMD) te spektralnog centroida pokazuju znatnu povezanost s masom vozila, što omogućuje njihovu primjenu u identifikaciji mase vozila. Konačno, za klasifikaciju mase vozila primijenjen je klasifikator temeljen na algoritmu k-najbližih susjeda (KNN), pri čemu su analizirani rezultati identifikacije pri različitim brzinama vozila i parametrima značajki. Rezultati su pokazali da je KNN klasifikator, postigao visoku razinu točnosti u utvrđivanju mase vozila: 90,8 % pri malim brzinama i 83,1 % pri velikim brzinama. Matrica zabune pokazala je da su pogreške u razvrstavanju najčešće nastajale između susjednih kategorija masa vozila.

Ključne riječi:

prepoznavanje mase vozila, prijelazna naprava, zvučni signal, izdvajanje značajki, metoda empirijskog razlaganja (EMD)

Research Paper

Shichao Qian, Xiaojuan Shu, Mingyan Shen, Yili Luo, Haopeng Dang

Preliminary investigation of vehicle weight estimation employing acoustic signals from bridge expansion joints

This study introduces a method for identifying vehicle load levels by analysing the characteristics of sound signals generated when vehicles pass over bridge expansion joints. The proposed approach is non-invasive and independent of lighting conditions, offering significant advantages. Experimental tests were initially conducted and effective impact sound signals were extracted by analysing the trend of the sound pressure amplitude following filtering, pre-emphasis, and signal detection processes. Typical characteristics of sound signals in the frequency, time, and time-frequency domains were extracted. The relationships between short-term energy, empirical mode decomposition (EMD) energy entropy, spectral centroid features, and vehicle weight were found to be significant for vehicle weight identification. Finally, a classifier based on the k-nearest neighbour (KNN) algorithm was employed for vehicle weight classification by analysing the identification results under varying vehicle speeds and feature parameters. The results indicated that the KNN classifier achieved high accuracy in vehicle weight identification: 90.8% at low speeds and 83.1% at high speeds. The confusion matrix revealed that misclassifications tended to predict vehicle weights in adjacent categories.

Key words:

vehicle weight recognition, expansion joint, acoustic signal, feature extraction, empirical mode decomposition (EMD)

1. Uvod

Procjena sigurnosti i trajnosti cestovne i mostovne infrastrukture zahtijeva provedbu sveobuhvatnih ispitivanja i analiza opterećenja vozila, koji su ključni za očuvanje cjelovitosti i dugovječnosti konstrukcije [1, 2]. Za potrebe prikupljanja relevantnih podataka o vozilima u sklopu takvih ispitivanja primjenjuje se niz različitih metodologija. One uključuju:

- konvencionalne statičke vage
- dinamičke sustave vaganja
- tehnike prepoznavanja na temelju vizualnih slika
- metode prepoznavanja na temelju akustičnih i vibracijskih signala.

Svaka od navedenih metoda ima svoje prednosti i ograničenja, osobito u pogledu utjecaja na protočnost prometa i točnosti dobivenih podataka.

Iako se konvencionalna metoda statičkog vaganja odlikuje jednostavnom primjenom, njezin je nedostatak to što ne omogućuje prikupljanje podataka u stvarnome vremenu, jer je za vaganje potrebno zaustaviti vozilo. Takav je postupak nepogodan u uvjetima gustog prometa jer dovodi do zastoja [1]. S druge strane, dinamički sustavi vaganja predstavljaju učinkovitije rješenje jer omogućuju vaganje bez prekidanja prometnog toka. Ti se sustavi mogu svrstati u dvije podskupine: sustave za mjerenje prometa u pokretu ugrađene u kolničku konstrukciju (eng. *pavement based weigh in motion* - PWIM) i mostne sustave za mjerenje prometa u pokretu (eng. *bridge based weigh in motion* - BWIM). PWIM sustav primjenjuje senzore ugrađene u kolničku konstrukciju, pri čemu je njegova trajnost ograničena zbog stalnog djelovanja opterećenja uzrokovanih prometom vozila. Nasuprot, BWIM sustav primjenjuje senzore integrirane u konstrukciju mosta, pri čemu se iskorištavaju dinamički odzivi konstrukcije izazvani prolaskom vozila [3, 4]. Primjenom specifičnih algoritama za određivanje raspodjele krutosti mosta BWIM sustav može precizno odrediti osovinska opterećenja, brzinu i masu vozila, predstavljajući pritom diskretnu i neinvazivnu metodu prikupljanja podataka.

Brojna su istraživanja razvila metode za identifikaciju osovinskih opterećenja vozila primjenom BWIM sustava. Naprimjer, Zhang i suradnici [5] primijenili su iterativni algoritam temeljen na Mosesovu algoritmu, u kombinaciji s algoritmom izmjerenog utjecaja, radi identifikacije osovinskih opterećenja vozila u sklopu BWIM sustava. Chen [6] je razvio BWIM sustav namijenjen istodobnome praćenju više vozila, u kojemu su primijenjeni Braggovi optički senzori s dugim vlaknima za određivanje brzine vozila, razmaka među osovinama i mase vozila. Kawakatsu i sur. [7] predložili su BWIM sustav s jednim senzorom, koji primjenom dubokih neuronskih mreža omogućuje izdvajanje značajki poput podataka o prometnome traku, brzini vozila, putanji kretanja i osovinskim opterećenjima, primjenjujući konvolucijske neuronske mreže (CNN). Deng i sur. [8] predložili su metodu dinamičkog vaganja temeljenu na više mostova, pri čemu su za obradu podataka primijenjene konvolucijske neuronske mreže (eng. *Convolutional Neural Networks* - CNN).

U novije vrijeme postignut je znatan napredak, osobito u postizanju visoke razine točnosti pri očitavanju registarskih oznaka, identifikaciji tipova vozila te određivanju njihovih brzina i dimenzija. Međutim, iako su te tehnologije dosegnule visok stupanj zrelosti, njihova su ograničenja sve uočljivija, osobito kada je riječ o prepoznavanju mase vozila. Primarni izazov leži u tome što se razlike u masi vozila ne mogu pouzdano prepoznati na temelju vizualnih značajki, čak ni kod istih vozila ili vozila iste kategorije. Posljedično, istraživanja usmjerena na prepoznavanje mase vozila primjenom vizualnih metoda još su uvijek ograničena. Nekoliko je radova istraživalo mogućnost procjene mase vozila na temelju deformacije guma u prepoznavanju slike za procjenu težine vozila, no takav pristup zahtijeva vrlo visoku razlučivost snimaka. Međutim, snimanje slika visoke rezolucije deformacije guma tijekom kretanja vozila pri većim brzinama znatan je izazov. Huan i sur. [9] te Feng i sur. [10] primijenili su takav pristup, pri čemu su istaknuli nužnost vrlo jasnog snimanja deformacije gume. McKay i sur. [11] predložili su metodu u kojoj se kamerom visoke razlučivosti bilježi torzija šasije uzrokovana zakretnim momentom motora, a tako dobiveni podaci upotrebljavaju se za procjenu mase vozila. Međutim, slično kao i druge metode koje se oslanjaju na slike strukturnih deformacija, i taj se pristup suočava sa znatnim izazovima. Glavni nedostaci vizualnog prepoznavanja za određivanje mase vozila odnose se na stroge zahtjeve za snimanje mikroskopskih strukturnih detalja te na smetnje uzrokovane čimbenicima poput osvjetljenja, brzine vozila i vibracija mosta [12].

Zvučni signali, iako manje intuitivni od vizualnih prikaza, imaju veliku prednost u tome što nisu podložni promjenama osvjetljenja, zbog čega predstavljaju pouzdanu opciju za prepoznavanje parametara vozila [13-19]. U literaturi postoji velik broj radova koji se bave prepoznavanjem tipova vozila na temelju zvučnih signala, pri čemu su rana istraživanja uglavnom bila usredotočena na prikupljanje zvučnih zapisa vožnje te primjenu pojedinačnih značajki zvuka za klasifikaciju tipova vozila primjenom plitkih neuronskih modela poput strojeva potpornih vektora (eng. *Support Vector Machines* - SVM). Naprimjer, Frederick i sur. [16] primijenili su brzu Fourierovu transformaciju (FFT) za izdvajanje značajki vršnih frekvencija iz zvučnih signala dizelskih i benzinskih motora te su primjenom SVM-a postigli visoku razinu točnosti binarne klasifikacije. Razvojem metoda obrade signala i algoritama umjetne inteligencije preciznost i primjenjivost prepoznavanja zvučnih signala znatno su povećane. Zhao Hongxu i sur. [17] integrirali su kratkotrajnu Fourierovu transformaciju (eng. *Short-Time Fourier Transform* - STFT), Mel-kepstralne koeficijente (eng. *Mel-Frequency Cepstral Coefficients* - MFCC) te fuziju značajki STFT-a i MFCC-a u kombinaciji sa SVM klasifikatorom za određivanje tipa vozila, pri čemu je pokazano da kombinacija značajki postiže višu razinu točnosti prepoznavanja od pojedinačnih značajki. Zhao i sur. [19] primijenili su analizu glavnih komponenti (PCA) u kombinaciji s neuronskom mrežom s povratnim širenjem (eng. *Back Propagation* - BP) (PCA-BP) za klasifikaciju prvih dviju dominantnih MFCC značajki zvučnih signala vozila, čime su uspješno klasificirani brzina i tip vozila. Chen [20] uveo je inovativan pristup spajanjem triju značajki zvučnih

signala vozila, i to MFCC koeficijenta, značajki kratkotrajne energije te značajki oblika razine zvuka, pri čemu je za klasifikaciju tipa vozila primijenjena hibridna neuronska mreža koja integrira konvolucijske neuronske mreže (CNN) i LSTM (*Long Short Term Memory*) jedinice. LSTM je vrsta napredne povratne neuronske mreže koja se koristi u dubokom učenju za obradu i predviđanje sekvencijalnih podataka.

Unatoč sve većem broju istraživanja koja se bave primjenom zvučnih signala za prepoznavanje karakteristika vozila te postignutim visokim stopama točnosti u klasifikaciji tipova vozila i prepoznavanju brzine, u literaturi i dalje nedostaje znatniji broj radova koji se bave prepoznavanjem mase vozila na temelju zvučnih signala [21]. Kada se vozilo kreće, zvučni signali prikupljeni iznad kolnika vrlo su složeni te obuhvaćaju:

- mehaničke zvukove vozila poput rada motora, mjenjača i zvukova komponenti vozila
- zvukove trenja, uključujući zvukove trenja između kotača i podloge te između karoserije vozila i zraka
- bijeli šum iz okoliša [22–24].

Zvukovi trenja posebno su osjetljivi na brzinu vozila te čine osnovu za prepoznavanje brzine kretanja vozila [22, 23]. Različiti modeli vozila imaju karakteristične akustične potpise koji proizlaze iz rada njihovih motora i prijenosnih sustava, što je ključno za identifikaciju tipa vozila [14]. U teoriji, pri promjeni mase vozila pod jednakim uvjetima, promjene u mehaničkim zvukovima i zvukovima trenja između kotača i kolnika trebale bi biti izraženije od promjena u obliku karoserije, koje se uobičajeno detektiraju vizualnim metodama. Zato je prepoznavanje mase vozila na temelju zvučnih signala izvedivo. Tijekom vožnje preko čvrste "neravnine", naprimjer, u obliku uspornika brzine ili prijelaznih naprava, promjene u zvuku uzrokovane promjenom mase vozila postaju izraženije [25–26]. Ravšanović i sur. [25] proveli su ispitivanja buke vozila pri prelasku preko modularnih prijelaznih naprava te su uočili dominantnu frekvenciju u rasponu od 500 do 800 Hz u zvuku generiranome na gornjoj površini prijelazne naprave. Dominantna frekvencija uočena u tome području pripisuje se rezonantnoj buci uzrokovanoj promjenama tlaka zraka u šupljini gumenoga brtvenog profila među modularnim elementima pod utjecajem prolaska vozila. Primarna frekvencija buke koja nastaje na donjoj strani prijelazne naprave iznosi manje od 200 Hz, a proizlazi iz vibracija čeličnih nosača modularne prijelazne naprave. Ghimire i sur. [26] ispitivali su mehanizam nastanka buke modularnih prijelaznih naprava primjenom metode konačnih elemenata za vibracije te metode akustičnih rubnih elemenata, pri čemu su u analizi buke šupljine prijelazne naprave uočili dominantnu frekvencijsku komponentu vibracija konstrukcije. Autori su upozorili na moguću interakciju između strukturnih modalnih oblika prijelazne naprave i akustičnih modova šupljine, što implicira da se vibracijski signali uzrokovani strukturnim naprezanjem mogu odražavati u akustičnome signalu. Jednostruke prijelazne naprave u obliku slova "U", koje se općenito primjenjuju na prilaznim konstrukcijama velikih mostova te na mostovima srednjih i manjih raspona, pogodan su izvor udarnog

zvuka tijekom prolaska vozila [27]. Polazeći od te pretpostavke, u ovome se radu istražuje mogućnost prepoznavanja različitih razina mase vozila na temelju karakteristika akustičnog signala pri prelasku vozila preko prijelazne naprave.

Proces prelaska vozila preko prijelazne naprave može se analogno usporediti s relativnim klizanjem koje se pojavljuje u mehaničkim prijenosnim sustavima, naprimjer, u zupčanicima, kotrljajućim elementima ležajeva te njihovim unutarnjim i vanjskim prstenovima. Kada na zupčanicima ili prstenovima ležaja postoje kvarovi poput pukotina, emitirani zvuk klizanja na mjestu kvara znatno odstupa od zvuka u normalnim radnim uvjetima. Na tom se načelu temelji dijagnostika mehaničkih oštećenja analizom akustičnih signala [28–31]. Izazov u dijagnostici leži u preciznome razlikovanju vrsta kvarova i njihove ozbiljnosti (npr. širine pukotine) u prisutnosti složene pozadinske buke. Pritom je poboljšanje omjera signala i šuma ključan zahtjev u postupku detekcije signala. Lu i sur. [32] primijenili su metodu dvostrukog praga za detekciju impulsnih zvučnih signala uzrokovanih udarnim defektima, čime je poboljšana točnost određivanja krajnjih točaka signala. Hou i sur. [33] predstavili su metodu MOMEDA, temeljenu na načelu rijetkosti signala, koja je primijenjena za pojačavanje i dijagnosticiranje značajki kvarova ležajeva na temelju zvučnih signala. Tehnike fuzije i vrednovanja signala mogu dodatno pojačati udio zvučnih komponenti povezanih s kvarovima. Naprimjer, Li i sur. [34] predložili su novu metodu koja integrira višemodalne signale zvučnih i vibracijskih senzora radi izdvajanja karakterističnih značajki kvarova, čime se ublažava problem prikrivanja ranih indikacija kvarova snažnom pozadinskom bukom. Di Pei i sur. [35] primijenili su autokorelacijsku analizu i metodu empirijskog razlaganja (eng. *empirical mode decomposition* – EMD) za potiskivanje buke. Osim toga informacije o kvarovima rekonstruirane su i dodatno istaknute primjenom indeksa za procjenu zaobljenosti distribucije temeljenog na unakrsnoj korelaciji, nakon čega su frekvencijske značajke kvarova izdvojene Teagerovim energetske operatorom, što je omogućilo praćenje ranih i slabih simptoma kvarova ležajeva. Shi i sur. [36] predložili su dvostupanjski algoritam fuzije zvučnih i vibracijskih signala koji primjenjuje vrednovanje sivom B-korelacijom, metodu empirijskog razlaganja (eng. *empirical mode decomposition* – EMD) te superpoziciju indeksa za procjenu zaobljenosti distribucije radi poboljšanja omjera signala i šuma karakterističnih značajki kvarova. Pritom različite značajke zvučnog signala imaju različitu dijagnostičku važnost pri prepoznavanju kvara. Yang i sur. [37] predložili su metodu fuzije značajki koja primjenjuje projekciju atributa interferencije s vrednovanjem entropijom (eng. *entropy-weighted interference attribute projection* – EWNAP) te ortogonalnu projekciju s očuvanjem lokalnosti (eng. *orthogonal locality preserving projection* – OLPP) radi izdvajanja značajki osjetljivih na kvarove pri identifikaciji kvarova kotrljajućih ležajeva primjenom povratnopropagacijske (BP) neuronske mreže. Mian i sur. [38] primijenili su sustav HATS za prikupljanje zvučnih signala radi imitiranja ljudske percepcije zvuka te su na temelju značajki kvalitete zvuka proveli dijagnostiku kvarova ležajeva, pri čemu su opisali različite značajke kvalitete zvuka u različitim stanjima oštećenja. U području inteligentnih klasifikacijskih algoritama, u

dijagnostici kvarova i identifikaciji vozila primjenjuju se algoritmi umjetne inteligencije kao što su KNN, CNN, RNN i LSTM [39-46]. Disperzijska *fuzzy* entropija (eng. *Fuzzy dispersion entropy* – FuzzDE) predstavlja nedavno predložen nelinearni dinamički pokazatelj koji kombinira prednosti disperzijske entropije (DE) i *fuzzy* entropije (eng. *fuzzy entropy* – FuzzEn) radi detekcije dinamičkih promjena u vremenskoj nizu. Li i sur. [47] uveli su računanje frakcijskog reda na temelju FuzzDE pokazatelja, predložili FuzzDE α te ga primijenili kao značajku u analizi signala i dijagnostici kvarova ležajeva. Kodirana permutacijska entropija predložena je kao metoda za poboljšanje otpornosti na buku primjenom kvadratne particije na temelju permutacijske entropije. Li i sur. [48] primijenili su koncept kvadratne particije na disperzijsku entropiju (DE), upotrebom njezine sposobnosti da učinkovito mjeri informacije o amplitudi, te predložili kodiranu disperzijsku entropiju (CDE), koja povećava broj obrazaca i poboljšava razlučivost dodatnim kodiranjem disperzijskih obrazaca u sklopu DE-a.

U dijagnostici mehaničkih oštećenja prijelazne naprave mogu se promatrati kao defekti unaprijed određenog intenziteta. Međutim, za razliku od uobičajenih dijagnostičkih pristupa u kojima se analiza temelji na rotacijskim opterećenjima, u ovom se slučaju promjene zvučnih signala koriste za raspoznavanje varijacija primijenjene sile. U ovom su radu akustični odzivi teških teretnih vozila pri prelasku preko prijelazne naprave u obliku slova "U" na mostu, pri različitim brzinama i masama vozila, iskorišteni za bilježenje "udarnih" zvučnih signala. Nakon toga ispitana je osjetljivost više značajki zvučnog signala na masu vozila. Na temelju provedene analize osjetljivosti predloženi su korisni parametri značajki zvučnog signala za identifikaciju mase vozila. Primjenom algoritma k-najbližih susjeda (KNN) provedena je preliminarna klasifikacija i identifikacija razine mase određenog tipa teškoga teretnog vozila.

U 2. poglavlju opisan je postupak ispitivanja i prikupljanja podataka, u 3. poglavlju prikazana je predobrada akustičnih signala, u 4. poglavlju opisani su izdvajanje značajki signala i njihova statistička obilježja, u 5. poglavlju dani su rezultati analize klasifikacije mase primjenom KNN algoritma, dok su u 6. poglavlju izneseni zaključci rada.


2. Prikupljanje udarnih zvučnih signala teškoga teretnog vozila pri prelasku preko prijelazne naprave

2.1. Ispitni poligon i sustav prikupljanja zvučnih signala


Ispitivanja su provedena na središnjemu dijelu ravnog, ortogonalnog mosta duljine veće od 200 m, na lokaciji s ograničenim prometnim opterećenjem. Taj dio mosta obuhvaća prijelaznu napravu postavljenu okomito na uzdužnu os mosta, odnosno jednostruku čeličnu prijelaznu napravu u obliku slova "U", širine 60 mm. Okolni prostor u radijusu od približno 500 m otvoren je, bez viših građevina ili guste vegetacije, što osigurava vrlo nisku razinu buke iz okoliša i odsutnost jeke. Tijekom ispitivanja prikupljani su akustični signali koje su proizvela

teška teretna vozila različitih masa i brzina pri prelasku preko promatrane dionice kolnika, uključujući prijelaznu napravu. Mikrofon za potrebe ispitivanja bio je postavljen uz nogostup, na udaljenosti od 8,8 m od osi prometnog traka. Ispitni poligon prikazan je na slici 1. Prikupljanje zvučnih signala započelo je kada je vozilo stiglo na točku A, a završilo pri dolasku na točku B. Udaljenost između točaka A i B, u smjeru kretanja vozila, iznosila je 20 m, dok je mikrofon bio postavljen približno na sredinu odgovarajućeg nogostupa. U ispitivanju je kao mikrofon primijenjen senzor zvučnog tlaka tipa INV9206, povezan s uređajem za prikupljanje podataka INV3062T, koji omogućuje inteligentnu obradu podataka u oblaku. Sustav omogućuje mjerenje razina zvučnog tlaka do 146 dB te podržava maksimalnu frekvenciju uzorkovanja od 51,2 kHz.

Na slici 1. prikazan je ispitni poligon s pripadajućom opremom, dok je na slici 2. prikazan shematski prikaz postupka ispitivanja.



Slika 1. Ispitni poligon i primijenjeni instrumenti



Slika 2. Raspored sheme ispitivanja

2.2. Parametri teretnoga ispitnog vozila

U ovom je istraživanju upotrijebljeno terensko vozilo marke *Dongfeng Huashen*, četveroosovinska teška dizalica, neto mase 18,4 tona. Betonski blokovi slagani su na vozilo radi promjene njegove ukupne mase. Svaki je betonski blok imao masu od 3,19 tona, a maksimalna konfiguracija mase iznosila je 34,4 tona, što je postignuto dodavanjem pet betonskih blokova, čime je postignuto šest razina mase. Vozilo je zatim prelazilo preko prijelazne naprave dvjema različitim brzinama: 30 km/h i 50 km/h. Akustični podaci udarnih zvučnih signala prikupljeni su dok je vozilo prelazilo od točke A do točke B preko prijelazne naprave. Pregled parametara teretnoga ispitnog vozila prikazan je u tablici 1.

Tablica 1. Parametri teretnog ispitnog vozila

Naziv parametara	Vrijednost parametra	Razina opterećenja	Masa vozila [tona]	Brzina
Ukupne dimenzije [cm]	1200 × 255 × 399	1	18,4	
Bočni razmak kotača [cm]	185	2	21,5	
Međuosovinski razmak između prednje i srednje osovine [cm]	215	3	24,8	30 km/h
Međuosovinski razmak između srednje i stražnje osovine [cm]	440	4	28,0	50 km/h
Međuosovinski razmak između stražnjih osovine [cm]	135	5	31,1	
Vrsta gume	Guma ojačana čeličnim pojasom 11.00R20	6	34,4	


3. Predobrada zvučnog signala

Akustični signali prikupljeni tijekom prelaženja vozila preko prijelazne naprave u uvjetima na otvorenom prostoru u prirodi složeni su te se sastoje od više komponenti. Kako bi se poboljšao omjer signala i šuma, smanjilo računalno opterećenje te povećala učinkovitost analize podataka, neophodno je provesti odgovarajuću predobradu akustičnih signala. Postupak predobrade prikazan je na slici 3. Prvo su sirovi signali snimljeni mikrofonom podvrgnuti niskopropusnom filtriranju radi smanjenja utjecaja tlaka vjetra. Nakon toga su na početku i na kraju izvornog signala uklonjeni dijelovi bez udarnog sadržaja, čime je smanjen obujam podataka i poboljšana učinkovitost analize. Treći je korak obuhvatio smanjenje frekvencije uzorkovanja radi uklanjanja šuma ultravisokih frekvencija (eng. *ultra-high frequency* - UHF). U četvrtom je koraku na signal primijenjeno prednaglašavanje. Nakon trećega i četvrtoga koraka omjer signala i šuma dodatno je poboljšao. U završnom je koraku signal podijeljen u okvire i razvrstan u prozore, čime je nestacionarni signal razdijeljen i djelomično stabiliziran. U poglavljima 3.1. do 3.4. detaljno su opisane metodologije primijenjene za svaki korak sekvence predobrade.


3.1. Filtriranje signala i smanjivanje uzorkovanja

Akustični signali zabilježeni iznad kolničke površine tijekom prelaska preko prijelazne naprave obuhvaćaju niz komponenti, uključujući mehaničku buku vozila (pretežito buku motora i prijenosnog sustava), buku vjetra, buku kolnika (nastalu trenjem između podloge i kotača) te kratkotrajnu udarnu buku koja nastaje na prijelaznoj napravi uslijed udara pneumatika. Buka vjetra smatra se ovisnom o brzini te nije znatnije pod utjecajem mase vozila, dok ostale komponente buke mogu pokazivati obilježja ovisna o masi. Na temelju početne analize signala te uvida u literaturu o karakteristikama akustičnih signala tijekom vožnje utvrđeno je da se dominantno frekvencijsko područje zvučnih signala zabilježenih na prijelaznim napravama mostova nalazi u području do

8 kHz [17, 19]. U skladu s Nyquistovim teoremom uzorkovanja, frekvencija sniženog uzorkovanja postavljena je na dvostruku frekvenciju od interesa (16 kHz). Primijenjen je visokopropusni filter s graničnom frekvencijom od 20 Hz kako bi se uklonila niskofrekvencijska buka poput one uzrokovane tlakom vjetra. Na slici 4. prikazani su signali prije filtriranja i nakon njega.



Slika 3. Proces predobrade signala



Slika 4. Filtriranje signala: a) Početni signal; b) Filtrirani signal

3.2. Otkrivanje i hvatanje udarnih signala na temelju linije trenda anvelope amplitude zvučnog tlaka

Svaki je zvučni zapis snimljen tijekom prolaska vozila od točke A do točke B, pri čemu su obuhvaćeni i zvučni signali nastali prelaskom preko prijelazne naprave, kao i zvukovi vožnje po uobičajenoj dionici ceste. Vrijednosti signala koje se odnose na vožnju po uobičajenoj kolničkoj površini bez udarnog djelovanja smatraju se nerelevantnima te su izostavljene kako bi se skratilo trajanje signala. Zbog toga je otkrivanje i segmentacija zvučnih signala ključna za uklanjanje suvišnih podataka i povećanje učinkovitosti analize. U ovom istraživanju primijenjena je metoda temeljena na liniji trenda amplitude zvučnog tlaka za segmentaciju signala udarnog zvuka [42]. Anvelopa zvučnog tlaka izvedena je metodom korijena srednje kvadratne energije (RMS), čime je povećana otpornost anvelope na smetnje. To je postignuto tako da su zbrojeni kvadrati vrijednosti zvučnog tlaka unutar prozora, da je dobiveni zbroj podijeljen duljinom okvira, a zatim je izračunan kvadratni korijen rezultata, čime je dobivena vrijednost anvelope za pojedini okvir. Matematička definicija tog izračuna energije dana je u izrazu (1):


$$RMS_t = \sqrt{\frac{1}{K} \sum_{k=tK}^{(t+1)K-1} x(k)^2} \quad (1)$$

U izrazu (1) t označava broj prozora, K broj uzoraka unutar svakog prozora, a $x(k)$ funkciju uzorka unutar prozora, koja odgovara funkciji amplitude zvučnog tlaka. Za ovo istraživanje KK je postavljen na 50.000. Izračunana anvelopa zvučnog tlaka prikazana je na slici 5.a.

Kao što je to prikazano na slici 5., nakon što se odredi anvelopa amplitude signala, prvo se utvrđuje njezina vršna vrijednost uzduž linije trenda (slika 5.a). Od te se točke provodi pretraživanje u oba smjera. Nakon što se utvrdi određeni prag, uklanjaju se segmenti signala koji prethode i slijede dvije granične linije. Prag pretraživanja utvrđen u ovome članku zadan je izrazom (2),

$$RMS_f = \gamma_{\min} + (\gamma_{\max} - \gamma_{\min})/3 \quad (2)$$

gdje su $\gamma_{\min}$ i $\gamma_{\max}$ najmanje odnosno najveće vrijednosti linije trenda gornje anvelope, kao što je to prikazano na slici 5.b. Na slici 5.b žuta okomita linija označuje položaj vršne vrijednosti linije trenda, dok dvije crvene okomite linije označuju početnu i završnu točku udarnog signala. Duljina signala nakon detekcije i segmentacije prikazana je na slici 5.c.



Slika 5. Predobrada signala: a) Anvelopa amplitude zvučnog tlaka; b) Prag detekcije i izdvajanje; c) Izdvojeni signal; d) Signal nakon prednaglašavanja

3.3. Prednaglašavanje signala

Opaženi segment signala i dalje je sadržavao znatan udio neimpulsnih šumnih signala. Impulsni signali, karakteristični za kratkotrajne događaje, obično se manifestiraju u obliku visokofrekvencijskih komponenti. Prednaglašavanje signala može ublažiti prigušenje tih visokofrekvencijskih komponenti bez znatnijeg utjecaja na šum. Tim je postupkom učinkovitije poboljšan omjer signala i šuma, čime su naglašene značajke akustičnog signala nastale uslijed trenutnog udara vozila pri prelasku preko prijelazne naprave. Tehnika prednaglašavanja provedena je primjenom prijenosne funkcije, prikazane u izrazu (3).

$$H_x = 1 - \alpha x^{-1} \quad (3)$$


gdje x predstavlja amplitudu izvornog signala, a α koeficijent prednaglašavanja, koji je u ovome istraživanju postavljen na 0,97. Usporedba valnih oblika prije primjene prednaglašavanja i nakon njega prikazana je na slikama 5.c i 5.d, pri čemu se uočava pojačanje udarnog signala pri prelasku preko prijelazne naprave. Prikupljeni zvučni signal pripada skupini nestacionarnih signala, zbog čega je potrebno uvesti koncept kratkog vremena kako bi se signal podijelio u više okvira koji se mogu približno odrediti kao stacionarni modeli. U obradi signala uobičajeno se pretpostavlja da signal u vremenskom intervalu od 10 do 30 ms zadržava približno stacionarna svojstva. U ovom je istraživanju duljina okvira postavljena na 30 ms, uz pomak okvira jednak polovini te vrijednosti. Na taj se način omogućuje jednostavnija analiza, pri čemu se svaki okvir može promatrati kao kratki stalni segment signala.

Primjena prozorskih tehnika obrade signala, naprimjer, Hammingova prozora primijenjenog u ovome istraživanju, omogućuje zaglađivanje preklapajućih segmenata susjednih okvira te smanjuje pojavu rasipanja spektra, što je od presudne važnosti za preciznu analizu u frekvencijskoj domeni [22, 43]. Upotreba Hammingova prozora osobito je učinkovita zahvaljujući njegovoj sposobnosti ublažavanja diskontinuiteta na rubnim dijelovima okvira, što rezultira glatkijim prelaskom i pouzdanijom spektralnom procjenom.

3.4. Metoda empirijskog razlaganja (EMD)

EMD jest sastavni dio Hilbert-Huangove transformacije (HHT). Ta metoda razlaganja signala pogodna je za analizu nestacionarnih signala te je prilagodljiva bez potrebe za unosom parametara. EMD može adaptivno rastaviti signal od visokih prema niskim frekvencijama u nekoliko jednostavnih svojstvenih funkcija (eng. *Intrinsic Mode Functions* - IMF) i rezidualni član. IMF-ovi predstavljaju sastavne komponente zvučnog signala raspoređene unutar različitih frekvencijskih pojasa. Postupak izračuna EMD-a prikazan je na slici 6.

Kriteriji za identifikaciju pojedine IMF sastavnice propisuju da aritmetička sredina gornje i donje anvelope u svakoj točki signala mora iznositi nula, dok razlika između broja ekstremnih vrijednosti i broja nultih presjeka ne smije biti veća od jedan. Izdvajanje IMF sastavnice provedeno je u skladu s utvrđenim koracima izračuna EMD-a, pri čemu je završna komponenta signala koja nije ispunila kriterije za IMF definirana kao rezidualni član. U konačnici uspješno je izdvojeno šest IMF-ova.



Slika 6. Koraci za izračun EMD-a

4. Statistička analiza korelacije između karakteristika zvučnog signala i mase vozila

4.1. Izdvajanje značajki

U ovom su istraživanju iz akustičnog signala vozila izdvojene brojne značajke za analizu, uključujući značajke vremenske domene kao što su kratkotrajna brzina prolaska kroz nulu i kratkotrajna energija, te značajke frekvencijske domene kao što su spektralni centroid, spektralno širenje, spektralna entropija, spektralni tok i udio entropije energije EMD-a i energije IMF-a [31]. Nakon sveobuhvatne usporedbe analiza je pokazala da značajke koje iskazuju relativnu osjetljivost na prepoznavanje mase vozila te pritom zadržavaju dosljedne diskriminativne obrasce obuhvaćaju kratkotrajnu energiju, spektralni centroid, spektralnu entropiju i entropiju energije EMD-a.

Kratkoročna energija, E_n , predstavlja količinu energije sadržane u svakome okviru signala. Zato se analiza usredotočila na uokvirene i prozorske signale. Matematički se izražava kao zbroj kvadrata amplituda akustičnog signala unutar svakog okvira, kako je to prikazano izrazom (4).

$$E_n(m) = \sum_{m=0}^{N-1} x_n^2(m) \quad (4)$$

gdje je $x_n(m)$ m -n-ti uzorak signala u n -tom okviru, a N označava duljinu okvira.

Spektralni centroid (S.C.) definiran je kao središnji moment prvog reda spektra te opisuje položaj središta frekvencijskog sadržaja promatranog akustičnog signala. Izračun je sljedeći:

$$SC = \frac{\sum_{n=0}^{N-1} f(n)E(n)}{\sum_{n=0}^{N-1} E(n)} = \sum_{n=0}^{N-1} f(n)P(E(n)) \quad (5)$$

Gdje $E(n)$ predstavlja spektralnu energiju pripadajuće frekvencije nakon primjene STFT-a na diskretni signal u vremenskoj domeni, N duljinu signala, $P(E(n))$ udio energije pojedine točke u ukupnoj energiji signala, a $f(n)$ frekvenciju transformiranog signala u promatranju točki.

Entropija je primijenjena kao mjera stupnja raspršenosti i neodređenosti u sklopu analiziranih signala. Entropija energije EMD-a opisuje stupanj neravnomjerne raspodjele energije po različitim frekvencijskim pojasevima te se uobičajeno primjenjuje u dijagnostici oštećenja i kvarova [42-44]. Njezin je matematički izraz prikazan u izrazu (6).

$$H_E = -\sum_{j=1}^m p_j \log p_j$$

$$p_j = \frac{E_j}{\sum_{j=1}^m E_j} \quad (6)$$

Gdje E predstavlja ukupnu energiju, p_j udio energije j -te IMF sastavnice, a H_E energetska entropija EMD-a. Postupak izdvajanja IMF sastavnica detaljno je prikazan u radu [14].

Matematički izraz za spektralnu entropiju sličan je onome u izrazu (5). Spektralna entropija može se odrediti tako da se izračun p_j zamijeni udjelom spektralne amplitude j -te IMF sastavnice.

Nadalje, iz značajki u vremenskoj i frekvencijskoj domeni izdvojeni su statistički parametri, uključujući pet pokazatelja (aritmetičku sredinu, medijan, najveću vrijednost, standardnu devijaciju i koeficijent spljoštenosti) [29, 30, 44], radi analize i procjene njihove osjetljivosti na masu vozila.

4.2. Statistička obilježja četiriju značajki


Nakon predobrade zvučnih signala vozila pri različitim razinama opterećenja i brzinama izdvojene su značajke parametrizirane kratkotrajnom energijom te su normalizirane kako bi se njihove vrijednosti standardizirale u rasponu od 0 do 1 [45]. Rezultati parametarske statističke analize kratkotrajnih energetske značajki pri voznim brzinama od 30 i 50 km/h prikazani su na slici 7.

Analiza prikazana na slici 7.a pokazuje da karakteristični parametri ne iskazuju jasno uočljiv obrazac s porastom razine opterećenja, no uočen je opći uzlazni trend ukupnih vrijednosti svakog promatranog parametra. Pri voznoj brzini od 50 km/h aritmetička sredina, medijan, najveća vrijednost i standardna devijacija kratkotrajne energije zvučnog signala postupno rastu


od prve do pete razine opterećenja, dok na šestoj razini dolazi do pada vrijednosti tih parametara. Koeficijent spljoštenosti pokazuje znatniji pad isključivo pri prelasku s četvrte na petu razinu opterećenja, dok se u ostalim slučajevima povećava usporedno s porastom opterećenja.

Preliminarna spektralna analiza zvučnog signala skrenula je pozornost na to da udio visokofrekvencijske energije u spektru raste s povećanjem mase vozila, što je prikazano na slici 8. To upućuje na postojanje korelacije između visokofrekvencijskih komponenti udarnoga zvučnog signala i mase vozila. Zato je opravdano nastaviti istraživanja značajki u frekvencijskoj domeni koje bi se mogle primijeniti za određivanje mase vozila. Statistički rezultati značajki spektralnog centroida prikazani su na slici 9. Pri brzini od 30 km/h porast mase vozila uzrokuje tek neznatne promjene vrijednosti spektralnog centroida. Međutim, pri većoj brzini od 50 km/h uočen je izražen uzlazni trend srednjih i medijalnih vrijednosti, dok ostali pokazatelji nisu pokazivali dosljedan obrazac. Korelacija između spektralnog centroida i mase vozila pokazala se relativno slabom pri nižim brzinama, dok je pri višim brzinama postala znatno izraženija. Statistički rezultati izračuna spektralne entropije prikazani su na slici 10. Kao što je vidljivo, odnos spektralne entropije i mase vozila podudara se s onim utvrđenim za spektralni centroid. Uz iznimku vršne i najveće vrijednosti, ostali pokazatelji pri većoj brzini od 50 km/h pokazuju trend porasta u korelaciji s povećanjem mase vozila.


Na slici 11. prikazani su parametri energetske entropije EMD-a, udjeli energije IMF sastavnica te pripadajuće vrijednosti energetske entropije EMD-a, izdvojeni iz prethodno obrađenih udarnih zvučnih signala vozila pri različitim razinama opterećenja i brzinama od 30 i 50 km/h. Također, na slici 11. prikazano je smanjenje udjela energije IMF sastavnica s porastom razine opterećenja pri brzini od 30 km/h za vozila različitih masa. Takav trend upućuje na pomak frekvencijskog sadržaja akustičnog signala prema višim frekvencijama pri navedenoj brzini, uz istodobno smanjenje energije u pojasu niske frekvencije.




Slika 7. Odnos između mase vozila i parametara kratkotrajne energije: a) 30 km/h; b) 50 km/h




Slika 8. Raspodjela spektra za različite mase vozila: a) razina opterećenja 1.; b) razina opterećenja 3.; c) razina opterećenja 5.



Slika 9. Odnos između mase vozila i parametara spektralnog centroida: a) 30 km/h; b) 50 km/h



Slika 10. Odnos između mase vozila i parametara spektralne entropije: a) 30 km/h; b) 50 km/h



Slika 11. Odnos između mase vozila i parametara energetske entropije EMD-a: a) Udio energije pri 30 km/h; b) Entropija pri 30 km/h; c) Udio energije pri 50 km/h; d) Entropija pri 50 km/h

Također, energetska entropija EMD-a smanjuje se s povećanjem razine opterećenja, pri čemu vrijednosti entropije za prve dvije razine pokazuju znatnije promjene. Pri brzini od 50 km/h nije uočen jasan obrazac u udjelima energije IMF sastavnica za različite mase vozila. Vrijednost energetske entropije porasla

je pri razini opterećenja 4., dok je u ostalim slučajevima opadala s porastom opterećenja. Analizom udarnih zvučnih signala utvrđena je snažna povezanost značajke energetske entropije EMD-a i mase vozila.

5. Usporedba rezultata klasifikacije mase vozila na temelju KNN-a i različitih skupova značajki

5.1. Razvoj skupova značajki zvučnog signala

U 4. poglavlju analiziran je kvalitativni odnos između više značajki u vremenskoj i frekvencijskoj domeni te mase vozila, no ni jednom pojedinačnom značajkom nije moguće uspostaviti jednostavan kvantitativni model za izračun mase vozila. Zato je za dobivanje svojstvenih kvantitativnih odnosa potrebno primijeniti algoritme umjetne inteligencije. Zbog ograničenih sredstava za istraživanje broj uzoraka prikupljenih tijekom stvarnih ispitivanja na mostu bio je relativno malen te su u skladu s time u ovome radu provedeni samo preliminarna kvantitativna analiza i identifikacija razina opterećenja.

Skupovi značajki primijenjeni za prepoznavanje mase vozila na temelju akustičnih signala obuhvaćaju četiri kategorije: kratkotrajnu energiju, spektralni centroid, spektralnu entropiju i energetska entropiju EMD-a. Podaci za značajke kratkotrajne energije, spektralnog centroida i spektralne entropije organizirani su u vektor značajki dimenzija 1×5 , koji obuhvaća aritmetičku sredinu, medijan, najveću vrijednost, standardnu devijaciju i koeficijent spljoštenosti. S druge strane, podaci povezani sa značajkom energetske entropije EMD-a organizirani su u vektor značajki dimenzija 1×7 , koji obuhvaća vrijednost entropije te energetske udjele prvih šest IMF sastavnica.


Nakon obrade podataka baza značajki akustičnog signala sadržavala je 187 uzoraka, pri čemu se 91 uzorak odnosio na udarne zvučne signale pri brzini od 30 km/h, a 96 uzoraka na signale pri 50 km/h. Detaljan sastav uzoraka prikazan je u tablici 2.

Tablica 2. Parametri kretanja pokusnog vozila

Brzina vozila	Ukupan broj uzoraka	Razine opterećenja					
		1	2	3	4	5	6
30 km/h	91	12	18	15	16	15	15
50 km/h	96	15	15	18	15	18	15

5.2. Algoritam K-najbližih susjeda

Veličina uzorka u ovome istraživanju bila je relativno mala. Modeli dubokih neuronskih mreža poput konvolucijskih neuronskih mreža (CNN) u pravilu zahtijevaju velik broj uzoraka za učinkovitu klasifikaciju i prepoznavanje [29, 41]. Zato je u ovome radu primijenjen algoritam K-najbližih susjeda (KNN), tradicionalni plitki algoritam strojnog učenja pogodan za zadatke prepoznavanja s ograničenim brojem uzoraka [40]. Algoritam KNN-a ujedno nudi određene prednosti u odnosu na metode poput SVM-a i linearne regresije. Prednosti tog pristupa uključuju mogućnost jednostavne nadogradnje novim podacima te znatno veću brzinu izračuna. Unutar unaprijed definiranog skupa za učenje algoritam KNN-a identificira k uzoraka koji su najbliži ispitivanome uzorku te na temelju tih najbližih susjeda određuje odgovarajuću klasifikacijsku kategoriju. Postupak



razvrstavanja prikazan je na slici 12.

Slika 12. Princip razvrstavanja KNN-a

Kao što je to prikazano na slici 12., pri vrijednosti $k = 3$ ispitni je uzorak okružen dvama crvenim trokutima i jednim plavim kvadratom, pri čemu su crveni trokuti u većini. Slijedom toga zeleni krug raspoređen je u skupinu crvenih trokuta. Pri vrijednosti $k = 5$ ispitni je uzorak okružen dvama crvenim trokutima i trima plavim kvadratima pa su zbog većine plavih kvadrata zeleni krugovi raspoređeni u tu skupinu. Za određivanje najbližeg uzorka neophodno je izračunati sličnost, ili preciznije, udaljenost između ispitnih i trening točaka. Ukratko, na rad algoritma KNN-a ponajprije utječu tri čimbenika:

- metrika udaljenosti, koja procjenjuje sličnost između ispitnih i trening točaka (u ovom je istraživanju za mjerenje udaljenosti

primijenjena euklidska udaljenost [43])

- pravilo odlučivanja o razvrstavanju, koje se najčešće temelji na većinskome glasovanju, pri čemu se ispitna točka pripisuje kategoriji s najvećim udjelom među njezinim najbližim susjedima
- odabir vrijednosti k , koja određuje broj najbližih točaka obuke uzetih u obzir pri razvrstavanju, ovisno o njihovoj blizini i primijenjenome pravilu o donošenju odluke o razvrstavanju.

Provjerom valjanosti utvrđeno je da je u ovome istraživanju najbolju klasifikacijsku učinkovitost modela KNN-a moguće postići pri vrijednost $k = 3$. Metoda n -strukne ukrštene provjere primijenjena je kako bi se spriječilo pretjerano prilagođavanje modela. Navedena metoda dijeli skup podataka na pet međusobno nepovezanih podskupova, pri čemu se jedan podskup primjenjuje za testiranje, a preostala četiri za učenje modela. Nakon pet ponavljanja postupka učenja i testiranja prosječna vrijednost dobivenih rezultata testa uzeta je kao konačan ishod.

5.3. Analiza rezultata prepoznavanja mase vozila

Algoritam KNN-a primijenjen je za klasifikaciju mase vozila na temelju četiriju vrsta parametara značajki izdvojenih iz zvučnog signala nastalog pri prelasku vozila preko prijelazne naprave. Rezultati razvrstavanja prikazani su u tablici 3.


Kao što je to vidljivo iz tablice 3., udarni zvučni signal pri nižoj brzini od 30 km/h pokazao je bolje performanse klasifikacije mase vozila pri upotrebi značajki kratkotrajne energije i energetske entropije EMD-a. Točnije, klasifikacijska točnost temeljena na energetske entropiji EMD-a iznosila je 90,8 %, dok je točnost utemeljena na kratkotrajnoj energiji dosegla 81,4 %. Za udarni zvučni signal pri većoj brzini od 50 km/h značajke spektralnog centroida, spektralne entropije i energetske entropije EMD-a pokazale su poboljšane performanse u klasifikaciji mase vozila, pri čemu su stope prepoznavanja premašile 70 %.

Prilikom razmatranja isključivo stupnja prepoznavanja točnosti navedene značajke ne pokazuju izražen utjecaj na prepoznavanje razina mase vozila. Međutim, u sklopu provedenoga eksperimentalnog postupka zahtijevala se visoka razina preciznosti pri određivanju mase vozila. Razlika u masi između susjednih razreda iznosila je 3,19 tona, što je samo 0,173 udjela neto mase promatranog vozila. Zato, čak i u slučaju svrstavanja u susjednu kategoriju, takav rezultat i dalje upućuje na određenu razinu točnosti pri procjeni mase vozila [45, 46].


Matrice zabune za klasifikaciju mase vozila temeljenu na značajkama kratkotrajne energije, spektralnog centroida, spektralne entropije i energetske entropije EMD-a prikazane su

Tablica 3. Rezultati klasifikacije mase vozila na temelju zvučnih svojstava

Brzina	Kratkoročna energija	Spektralni centroid	Spektralna entropija	Energetska entropija EMD-a
30 km/h	81,4 %	45,2 %	58,2 %	90,8 %
50 km/h	60,2 %	83,1 %	75,4 %	74,3 %



Slika 13. Matrica zabune za klasifikaciju mase vozila pri 30 km/h: a) kratkotrajna energija; b) spektralni centroid; c) spektralna entropija; d) energetska entropija



Slika 14. Matrica zabune za klasifikaciju mase vozila pri 50 km/h: a) kratkotrajna energija; b) spektralni centroid; c) spektralna entropija; d) energetska entropija

na slikama 13. i 14.

Kao što je to prikazano na slici 13., pri manjoj brzini od 30 km/h primjena značajki kratkotrajne energije i energetske entropije u identifikaciji mase vozila dala je bolje rezultate u odnosu na upotrebu spektralnog centroida i spektralne entropije. Među navedenima, energetska entropija pokazala je najbolju učinkovitost, ostvarivši ukupnu točnost od 90,8 %. Matrica zabune pokazuje da se u slučajevima pogrešne klasifikacije pogreške u pravilu javljaju na susjednoj razini opterećenja, što upućuje na određenu sposobnost razlikovanja. Kratkotrajna energija ostvarila je drugu najbolju učinkovitost, uz približno 10 % vjerojatnosti pogrešne klasifikacije u nesusjedne razine opterećenja. Nasuprot tome, točnost prepoznavanja temeljena na spektralnome centroidu i spektralnoj entropiji bila je znatno niža, a matrica zabune pokazala je slabiju točnost.

Na slici 14. prikazano je da je pri većoj brzini od 50 km/h učinak prepoznavanja temeljen na spektralnome centroidu i spektralnoj entropiji poboljšan u odnosu na rezultate dobivene primjenom kratkotrajne energije i energetske entropije. Među navedenim značajkama spektralni centroid ostvario je najbolju učinkovitost, s ukupnom točnošću od 83,1 %. Matrica zabune upućuje na to da se, čak i u slučajevima pogrešne klasifikacije, podaci pretežito svrstavaju u susjedne razine opterećenja, što upućuje na određenu sposobnost razlikovanja. To je u skladu sa zaključcima analize iz odjeljaka 4.3. i 4.4. Točnost prepoznavanja temeljena na energetska entropiji razmjerno je niska, a matrica zabune pokazuje približno 10 % vjerojatnosti pogrešne identifikacije u nesusjedne razine opterećenja. Ukupna točnost prepoznavanja temeljena na

kratkotrajnoj energiji također je niska, no uzimajući u obzir klasifikaciju susjednih razina, njezina je učinkovitost usporediva s onom koja se temelji na energetske entropiji.

Kao što je to prikazano na slikama 13. i 14., u matrici zabune za klasifikaciju mase vozila na temelju energetske entropije EMD-a većina pogrešnih razvrstavanja nalazi se u neposrednoj blizini ispravnih kategorija. Osim toga pri većim brzinama vozila rezultati prepoznavanja temeljeni na spektralnome centroidu i spektralnoj entropiji pokazali su simetričan raspored duž dijagonale matrice zabune, što upućuje na dobru razinu točnosti prepoznavanja. U budućim istraživanjima bilo bi korisno razmotriti kombiniranje dviju ili više značajki te primjenu naprednijih algoritama prepoznavanja, osobito u uvjetima većeg broja uzoraka, radi dodatnog poboljšanja učinkovitosti razvrstavanja.

6. Zaključak

Komponente akustičnog signala pri prelasku vozila preko prijelazne naprave složene su, a značajke signala povezane s masom vozila nisu unaprijed poznate. Zato je u postupku izdvajanja i predobrade akustičnih signala potrebno uravnoteženo uzeti u obzir suprotstavljene zahtjeve učinkovitosti proračuna i rasipanja spektra. Rezultati provedene analize upućuju na to da frekvencija uzorkovanja ne smije biti preniska te da je za otkrivanje i izdvajanje udarnog akustičnog signala potrebno primijeniti metodu izdvajanja utemeljenu na liniji trenda amplitude zvučnog tlaka, čime se može učinkovito zadržati koristan dio signala povezan s masom vozila.

Rezultati analize korelacije između različitih značajki akustičnog signala i mase vozila upućuju na znatnu povezanost kratkotrajne energije, spektralnog centroida, spektralne entropije i energetske entropije EMD-a s masom vozila.

Zbog ograničenog broja uzoraka, za identifikaciju mase vozila na temelju navedenih četiriju akustičnih značajki primijenjen je klasifikator K-najbližih susjeda (KNN), pri čemu su ostvarene zadovoljavajuće i precizne stope prepoznavanja te konzistentni rezultati matrice zabune.

Rezultati prepoznavanja mase vozila primjenom klasifikatora KNN pokazuju da ukupna učinkovitost slijedi redoslijed: energetska entropija EMD-a > spektralna entropija / spektralni centroid > kratkotrajna energija. Međutim, djelotvornost pojedinih metoda prepoznavanja značajki varira ovisno o brzini vozila, što upućuje na to da je pri određivanju mase vozila neophodno uzeti u obzir utjecaj brzine vozila.

Ovo istraživanje pokazalo je da se metodom prepoznavanja mase vozila temeljenom na akustičnome signalu pri prelasku preko prijelazne naprave može dodatno povećati broj uzoraka te primijeniti fuzija značajki, što potencijalno omogućuje postizanje veće preciznosti prepoznavanja mase vozila.

Zahvala

Istraživanje prikazano u ovom radu financijski su podržali Nacionalna zaklada za prirodoslovna istraživanja Kine (51678253), Zaklada za prirodoslovna istraživanja provincije Hunan (2020JJ5195) te Zaklada za znanstvena istraživanja Odjela za obrazovanje provincije Hunan (CN) (20B218). Autori zahvaljuju na dodijeljenoj potpori.

LITERATURA

- [1] Jacob, B., van Loo, H.: Weigh-in-motion for enforcement in Europe, Proceedings of The International Conference on Heavy Vehicles, HV Paris, 2013., pp. 25-38
- [2] Ministry of Transport of China: 2020 Statistical Bulletin on the Development of the Transportation Industry, China Transport News, 2021.
- [3] Hou, R., Jeong, S., Lynch, J.P., et al.: Law, data-driven analytical load rating method of bridges using integrated bridge structural response and weigh-in-motion truck data, Mech. Syst. Sig. Process., 163 (2022) 4, Paper 108128, <https://doi.org/10.1016/j.ymssp.2021.108128>
- [4] Ren, W.X., Zuo, X.H., Wang, N.B., et al.: Review of non-pavement bridge weigh-in-motion, China J. Highw. Transp., 27 (2014) 7, pp. 45-53
- [5] Longwei, Z., Jianqun, W. et al.: Theoretical and experimental study on a bridge weigh-in-motion iterative algorithm, J. Vib. Shock, 40 (2021) 6, pp. 171-176
- [6] Chen, S.Z., Wu, G., Feng, D.C.: Development of a bridge weigh-in-motion method considering the presence of multiple vehicles, Eng. Struct., 191 (2019), pp. 724-739
- [7] Kawakatsu, T., Aihara, K., Takasu, A., et al.: Deep sensing approach to single-sensor vehicle weighing system on bridges, IEEE Sens. J., 19 (2018) 1, pp. 243-256
- [8] Lu, D., Xin, L., Yang, L.T., et al.: Bridge weigh-in-motion algorithm considering multi-vehicle based on convolutional neural network, J. Hunan Univ. Nat. Sci., 49 (2022) 1, pp. 33-41
- [9] Xuan, K., Jie, Z., Teng-yi, W., et al.: Non-contact vehicle weighing method based on tire deformation using image recognition, China J. Highw. Transp., 35 (2022) 8, pp. 186-193
- [10] Feng, M.Q., Leung, R.Y.: Application of computer vision for estimation of moving vehicle weight, IEEE Sens. J., 21 (2020) 10, pp. 11588-11597
- [11] McKay, T.R., Salvaggio, C., Faulring, J.W., et al.: Remotely detected vehicle mass from engine torque-induced frame twisting, Opt. Eng., 56 (2017) 6, pp. 063101
- [12] Ojio, T., Carey, C., O'Brien, E.J., et al.: Contactless bridge weigh-in-motion, J. Bridge Eng., 21 (2016) 2, pp. 1084-0702
- [13] Xialin, M.A., Ming, M.C., Jianli, D.: Audio identification of vehicle type based on frequency analysis and support vector machine, J. Appl. Acoust., 33 (2014) 4, pp. 371-376

- [14] George, J., Mary, L., Riyas, K.S.: Vehicle detection and classification from acoustic signal using ANN and KNN, *Proceedings of The International Conference on Control Communication and Computing (ICCC)*, 2013., pp. 436-439
- [15] Xiaoxuan, Q., Li, D., Guoshan, Z.: Vehicle type recognition by acoustic signal based on wavelet packet decomposition and approximate entropy, *J. Nanjing Univ. Sci. Technol.*, 44 (2020) 1, pp. 67-79
- [16] Frederick, H., Winda, A., Solihin, M.I.: Automatic petrol and diesel engine sound identification based on machine learning approaches, *E3S Web of Conferences*, 130 (2019), pp. 130:01011
- [17] Hongxu, Z., Yiwen, Z., Wenshuai, Y.: Research on model identification of hybrid vehicle audio signal based on support vector machine, *Laser J.*, 39 (2018) 9, pp. 133-137
- [18] Guo, B., Nixon, M.S., Damarla, T.: Improving acoustic vehicle classification by information fusion, *Pattern Anal. Applic.*, 15 (2012) 29, pp. 29-43
- [19] Jiamei, Z., Wencheng, H.U., Congshuang, J, et al.: The vehicle type and speed recognition based on acoustic signal characteristics, *J. Appl. Acoust.*, 40 (2021) 3, pp. 468-473
- [20] Chen, H., Zhang, Z.: Hybrid neural network based on novel audio feature for vehicle type identification, *Sci. Rep.*, 11 (2021) 1, pp. 1-10
- [21] ISO 10844:2014: Specification of test tracks for measuring noise emitted by road vehicles and their tyres, 2014.
- [22] Yong, X.: Characteristics and spectrum evaluation of outside noise on asphalt pavements as vehicle-tire-road coupling, Southeast University, Nanjing, 2017.
- [23] Algohi, B., Mufti, A., Thomson, D.: Detection of speed and axle configuration of moving vehicles using acoustic emission, *J. Civ. Struct. Health Monit.*, 8 (2018) 3, pp. 353-362
- [24] Wieczorkowska, A., Kubera, E., Słowik, T., et al.: Spectral features for audio-based vehicle and engine classification, *J. Intell. Inf. Syst.*, 50 (2018) 2, pp. 265-290
- [25] Ravshanovich, K.A., Yamaguchi, H., Matsumoto, Y., et al.: Mechanism of noise generation from a modular expansion joint under vehicle passage, *Eng. Struct.*, 29 (2007) 9, pp. 2206-2218
- [26] Ghimire, J.P., Matsumoto, Y., Yamaguchi, H.: Numerical investigation of noise generation and radiation from an existing modular expansion joint between prestressed concrete bridges, *J. Sound Vib.*, 328 (2009) 27, pp. 129-147
- [27] Yang, Y., Junping, L., Linze, S., et al.: Field-measurement research on the noise at bridge expansion joints under vehicular load, *Shanghai Environmental Sciences*, 36 (2017) 6, pp. 9-13
- [28] Guo, B., Nixon, M.S., Damarla, T.: Improving acoustic vehicle classification by information fusion, *Pattern Anal. Applic.*, 15 (2012) 29, p. 43
- [29] Yu, Y., Junsheng, C.: A roller bearing fault diagnosis method based on EMD energy entropy and ANN, *J. Sound Vib.*, 294 (2006) 1-2, pp. 269-277
- [30] Fei, S., Chao, C., Jiawen, X., et al.: Application of spectral centroid transfer in bearing fault diagnosis under varying working conditions, *Chinese Journal of Scientific Instrument*, 40 (2019) 5, pp. 99-108
- [31] Sharma, G., Umapathy, K., Krishnan, S.: Trends in audio signal feature extraction methods, *Appl. Acoust.*, 2020.
- [32] Qingqi, L.U., Yanyan, B.: A speech endpoint detection algorithm based on dual-threshold two sentences, *Electron. Sci. Tech.*, 25 (2012) 1, pp.13-19
- [33] Hou, Y., Zhou, C., Changming Tian, et al.: Acoustic feature enhancement in rolling bearing fault diagnosis using sparsity-oriented multipoint optimal minimum entropy deconvolution adjusted method, *Appl. Acoust.*, 2022, pp. 201
- [34] Li, X., Wan, S., Liu, S., Zhang, Y., Hong, J., et al.: Bearing fault diagnosis method based on attention mechanism and multilayer fusion network, *ISA Trans.*, 128 (2022), pp. 550-564
- [35] Di, P., Jianhai, Y., Jing, J.: Weak fault feature extraction of rolling bearing based on autocorrelation and energy operator enhancement, *J. Vib. Shock*, 40 (2021) 11, pp. 101-123
- [36] Shi, H., Li, Y., Bai, X., et al.: A two-stage sound-vibration signal fusion method for weak fault detection in rolling bearing systems, *Mech. Syst. Signal Process.*, 172 (2022), p. 109012
- [37] Yang, D., Lv, Y., Yuan, R., Yang, K., et al.: A novel vibro-acoustic fault diagnosis method of rolling bearings via entropy-weighted nuisance attribute projection and orthogonal locality preserving projections under various operating conditions, *Appl. Acoust.*, 196 (2022), p. 108889
- [38] Mian, T., Choudhary, A., Fatima, S.: An efficient diagnosis approach for bearing faults using sound quality metrics, *Appl. Acoust.*, 195 (2022), p. 108839
- [39] Wang, Y.S., Liu, N.N., Guo, H., et al.: An engine-fault-diagnosis system based on sound intensity analysis and wavelet packet pre-processing neural network, *Eng. Appl. Artif. Intell.*, 194 (2020), p.103765
- [40] Chen, L., Wang, C., Chen, J., et al.: Voice disorder identification by using Hilbert-Huang transform (HHT) and K nearest neighbor (KNN), *J. Voice*, 35 (2021) 6, p. 932.e1-932.e11
- [41] Xiang, L., Yan, W., Baoqing, L.: Acoustic signal classification of field vehicles based on combination of LSTM and CNN, *Piezoelectrics and acoustooptics*, 43 (2021) 3, pp. 379-384
- [42] Khoshouei, M., Bagherpour, R.: Predicting the geomechanical properties of hard rocks using analysis of the Acoustic and vibration signals during the drilling operation, *Geotech. Geol. Eng.*, 39 (2021), pp. 2087-2099
- [43] Hamid, O.K.: Frame blocking and windowing speech signal, *J. Inf. Commun. Intell. Syst.*, 4 (2018), pp. 87-94
- [44] Szwajkowski, A., Pilch, A.: Optimization of piano tuning by means of spectral entropy minimization, *Appl. Acoust.*, 166 (2020), p. 107359
- [45] Pan, C., Huang, Z., You, J., et al.: Moving force identification based on sparse regularization combined with moving average constraint, *J. Sound Vib.*, 515 (2021), p. 116496
- [46] Laxman, K.C., Ross, A., Ai, L., et al.: Determination of vehicle loads on bridges by acoustic emission and an improved ensemble artificial neural network (KNN), *Constr. Build. Mater.*, 364 (2023), p. 129844
- [47] Li, Y., Tang, B., Geng, B., Jiao, S.: Fractional order fuzzy dispersion entropy and its application in bearing fault diagnosis, *Fractal Fract.* 6 (2022), p. 544
- [48] Li, Y., Geng, B., Tang, B.: Simplified coded dispersion entropy: A nonlinear metric for signal analysis, *Nonlinear Dyn.*, 111 (2023), pp. 9327-9344