



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

**ÚSTAV MECHANIKY TĚLES, MECHATRONIKY A
BIOMECHANIKY**

INSTITUTE OF SOLID MECHANICS, MECHATRONICS AND BIOMECHANICS

**ANALÝZA ODEZVY LABORATORNÍHO MODELU
KOLEJIŠTĚ**

RESPONSE ANALYSIS OF TRAIN TRACK LABORATORY MODEL

DIPLOMOVÁ PRÁCE

DIPLOMA THESIS

AUTOR PRÁCE

AUTHOR

MAREK HETEŠ

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. FILIP KŠICA

BRNO 2022



Zadání diplomové práce

Ústav: Ústav mechaniky těles, mechatroniky a biomechaniky
Student: **Bc. Marek Heteš**
Studijní program: Mechatronika
Studijní obor: bez specializace
Vedoucí práce: **Ing. Filip Kšica**
Akademický rok: 2021/22

Ředitel ústavu Vám v souladu se zákonem č. 111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma diplomové práce:

Analýza odezvy laboratorního modelu kolejiště

Stručná charakteristika problematiky úkolu:

Moderní železniční trať je charakteristická množstvím senzorů zajišťujících bezpečnost provozu a dlouhodobé monitorování vlastností kolejiště a vlaků. Měření slouží nejen ke sběru informací pro detekci defektů či jiných problémů, vyhodnocení rychlosti a hmotnosti projíždějících vlaků, stavu povrchů kol, ale i pro energy harvesting technologie, které mohou sloužit k napájení těchto senzorických uzlů. I po osazení trati moderními senzory je však velmi obtížné odhalit existenci vad a problémů v kolejišti a analyzovat jejich projevy v měřeném signálu. Z tohoto důvodu byl v rámci probíhajících projektů na pracovišti sestaven laboratorní model kolejiště, který umožňuje tyto vlivy analyzovat bez nutnosti měření na reálné železniční trati. Cílem této práce bude tento laboratorní přípravek využít k vyhodnocení vlivu jednotlivých parametrů kolejiště na měřenou odezvu.

Cíle diplomové práce:

1. Rešerše dostupných metod měření a vyhodnocení signálů na moderní železniční trati s ohledem na detekci možných poruch v kolejišti.
2. Využití laboratorního přípravku k realizaci experimentu představujícího přejezd vlaku, záznam a zpracování měřených signálů a porovnání se signály získanými na reálné trati.
3. Analýza vlivu parametrů kolejiště na měřenou odezvu trati a zhodnocení přístupů pro detekci možných vad v kolejišti.

Seznam doporučené literatury:

JU, Shen Haw, Hung Ta LIN a Jeng Yuan HUANG. Dominant frequencies of train-induced vibrations. Journal of Sound and Vibration. 2009, 319(1–2), 247–259. ISSN 10958568. Dostupné z:
doi:10.1016/j.jsv.2008.05.029


SHENG, X., C. J.C. JONES a D. J. THOMPSON. A theoretical study on the influence of the track on train-induced ground vibration. Journal of Sound and Vibration. 2004, 272(3–5), 909–936. ISSN 0022460X. Dostupné z: doi:10.1016/S0022-460X(03)00781-8

FITZGERALD, Paul C., Abdollah MALEKJAFARIAN, Daniel CANTERO, Eugene J. OBRIEN a Luke J. PRENDERGAST. Drive-by scour monitoring of railway bridges using a wavelet-based approach. Engineering Structures. 2019, 191(April), 1–11. ISSN 18737323. Dostupné z: doi:10.1016/j.engstruct.2019.04.046


Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku.

V Brně, dne 19. 10. 2021

L. S.



prof. Ing. Jindřich Petruška, CSc.
ředitel ústavu

v z. 

doc. Ing. Jaroslav Katoický, Ph.D.
děkan fakulty



Abstrakt

Z hľadiska bezpečnosti je potrebné udržiavať železničné dráhy v dobrej kondícii. Včasná a presná detekcia porúch dokáže pri údržbe ušetriť čas aj peniaze. Táto práca sa zaoberá simuláciou prejazdu vlaku na laboratórnom prípravku a meraním vzniknutej odozvy. Prípravok reprezentuje zmenšenú časť železničnej dráhy, a umožňuje simulovať vznik rôznych porúch. Na základe získaných dát bol hľadaný vhodný spôsob, ktorý umožní vznik porúch detekovať.

Summary

In terms of safety, railway tracks have to be kept in good condition. Early and accurate detection of track defects can save both time and money. This thesis deals with simulation of a passing train on laboratory apparatus, and the measurement of the generated response. Apparatus represents scaled down section of a railway track, and allows the simulation of defect formation. With the help of the obtained data, a suitable method for defect detection was created.

Klíčová slova

Železničné dráhy, Detekcia porúch, Laboratórne merania, Spracovanie signálov, Klasifikácia dát

Keywords

Railway tracks, Defect detection, Laboratory measurements, Signal processing, Data classification

HETEŠ, M. *Analýza odezvy laboratorního modelu kolejíště*. Brno: Vysoké učení technické v Brně, Fakulta strojního inženýrství, 2022. 60 s. Vedoucí Ing. Filip Kšica.

Prehlasujem, že som diplomovú prácu na tému „Analýza odezvy laboratorního modelu kolejiště“ vypracoval samostatne s použitím odbornej literatury a zdrojov uvedených v zozname, ktorý tvorí prílohu tejto práce.

Marek Heteš

Ďakujem týmto Ing. Filipovi Kšicovi za cenné pripomienky a rady pri vypracovaní diplomovej práce.

Marek Heteš

Obsah

1	Úvod	3
2	Rešeršná časť	4
2.1	Železničné dráhy	4
2.1.1	Štruktúra železničných dráh	4
2.1.2	Dynamické modely vlakov a dráh	5
2.1.3	Používané parametre v dynamických modeloch	5
2.1.4	Laboratórne modely dráh	6
2.2	Poruchy železničných dráh	7
2.2.1	Spôsoby merania	7
2.2.2	Analýza meraní a detekcia porúch	8
2.3	Analýza signálov	9
2.3.1	Záznam signálov	9
2.3.2	Predbežné spracovanie signálov	9
2.3.3	Analýza signálu v časovej doméne	10
2.3.4	Analýza signálu vo frekvenčnej doméne	11
2.3.5	Analýza signálu v časovo-frekvenčnej doméne	12
2.4	Strojové učenie	15
2.4.1	Algoritmy určené na klasifikáciu dát	15
2.4.2	Výber vhodných črt	17
3	Ciele práce	18
4	Laboratórny prípravok	19
4.1	Konštrukcia	19
4.2	Popis meracieho reťazca	21
4.3	Nastaviteľné parametre	22
5	Meranie ma laboratórnom prípravku	24
5.1	Nastavenie vhodných parametrov	24
5.2	Meranie na reálnych železničiach	24
5.3	Simulácia odozvy koľajníc	26
5.4	Porovnanie simulovaných a reálnych dát	28
5.5	Meranie odozvy pri zmene parametrov	29
6	Spracovanie meraní	31
6.1	Vytvorenie a popis datasetu	31
6.2	Dataset s odozvou "jedného kolesa"	31
6.2.1	Črty signálov v časovej doméne	31
6.2.2	Bezrozmerné črty signálov v časovej doméne	35
6.2.3	Črty signálov v časovo-frekvenčnej doméne	37
6.3	Dataset s odozvou "4 vagónov"	44
6.4	Zhodnotenie prístupu na reálnych dátach	48
7	Záver	51

OBSAH

Literatúra	52
Zoznam obrázkov	57
Zoznam použitých skratiek a symbolov	59

1. Úvod

Železničná doprava je veľmi využívanou formou transportu. Oproti cestnej doprave má vyššiu energetickú účinnosť, no jej prevádzkovanie býva často finančne náročné. Železničné dráhy je z dôvodu bezpečnosti potrebné udržiavať vo výbornej kondícii. Údržba dráh je však veľmi nákladná. Aby sa ušetrili čas aj peniaze, vznikajú rôzne metódy na presnú lokalizáciu a včasnú detekciu začínajúcich porúch.

Poruchy môžu vzniknúť v rôznych častiach dráhy, napríklad praskliny v koľajnici, uvoľnený podval alebo opotrebovanie štrkového lôžka. Poruchy rôznych častí majú odlišný vplyv na celkové správanie dráhy. Preto je, za účelom detekcie porúch, potrebné skúmať tieto jednotlivé vplyvy. Ich skúmanie je možné buď priamo na železničných dráhach v prevádzke, pomocou matematických simulačných modelov, alebo využitím laboratórnych modelov. Každá metóda výskumu má svoje výhody aj nevýhody. Meraním na reálnych dráhach získame najrealistickejšie dáta, no táto metóda môže byť nebezpečná, časovo náročná a môže ovplyvniť prevádzku železníc. Matematickými modelmi vieme vytvoriť veľa simulácií, a jednoduchšie dokážeme meniť parametre dráhy oproti meraniu na reálnych dráhach (napr. vytvorenie poruchy, zmena tuhosti niektorej časti a pod.). Problémom však je správne nastavenie simulácií, aby sa dáta čo najviac podobali realite. Poslednou metódou je tvorba laboratórnych modelov, ktorá kombinuje výhody predchádzajúcich dvoch. Laboratórne modely sú väčšinou zmenšené časti železničných dráh, takže realistickejšie simulujú deje ktoré v dráhach vznikajú, a dokážeme relatívne jednoducho nastavovať ich parametre.

V nasledujúcich kapitolách budeme simulovať odozvu lab. modelu, ktorý reprezentuje zmenšenú časť železničnej dráhy. Pomocou neho dokážeme simulovať prejazd vlaku po koľajnici. Zároveň môžeme meniť niektoré parametre modelu, čo nám umožní skúmať ich vplyv na odozvu železničnej dráhy. Zmenou týchto parametrov vieme simulovať vznik porúch v dráhe (napr. opotrebovanie lôžka). Pri simuláciách budeme merať deformáciu koľajnice s využitím piezo-elektrického senzoru. Získané dáta následne spracujeme, analyzujeme a budeme sa snažiť identifikovať vhodné črty signálov, na základe ktorých dokážeme detekovať zmenu parametrov lab. modelu.


2. Rešeršná časť

2.1. Železničné dráhy

Existujú dva najčastejšie typy železničných dráh, štandardná konštrukcia so štrkovým lôžkom a konštrukcia s betónovým lôžkom, taktiež nazývaná pevná jazdná dráha. Pevná jazdná dráha má oproti štandardnej lepšie jazdné vlastnosti, preto jej využívanie, kvôli vysokým rýchlostiam vlakov, narastá. Je stabilnejšia, má vyššiu životnosť a nižšie náklady na údržbu, ale jej obstarávacía cena je omnoho vyššia a zároveň má vyššie nároky na kvalitu železničného podkladu. Aj preto má väčšina železničných dráh štandardnú konštrukciu so štrkovým lôžkom. Tieto typy dráh sú síce lacnejšie, ale za to vyžadujú častejšiu údržbu. [1, 2]

2.1.1. Štruktúra železničných dráh

Železničná dráha sa skladá z viacerých častí: koľajnice, uchytenie koľajníc, koľajnicové podložky, podvaly a lôžko ktoré môže byť zložené z viacerých vrstiev s rôznymi vlastnosťami. (obr. 2.1).




Obr. 2.1: Železničná dráha so štrkovým lôžkom [1]

Koľajnice musia mať konštantnú rozteč počas celej dĺžky dráhy, a taktiež musí byť zamedzené ich rotácii a pozdĺžnemu posuvu. Preto sú prichytené k priečnym podvalom ktoré tradične bývali z dreva, no dnes sú najčastejšie zo železobetónu. Podvaly majú za úlohu zamedziť spomínaným posuvom a rovnomerne rozložiť pôsobiacu silu do štrkového lôžka. Medzi koľajnicami a podvalom sa nachádza gumená podložka, ktorá chráni podvaly pred veľkými nárazmi a tlmí veľkú časť vibrácií. Koľajnice s podvalmi sú vložené do štrkového lôžka, ktoré tvorí elastický podklad. Lôžko zamedzuje podvalom v pohybe a zároveň má za úlohu ďalej rozložiť pôsobiace sily do železničného podkladu. Vďaka jeho zrnitej štruktúre dokáže veľmi dobre tlmieť vibrácie. [3]

Parametre všetkých častí tohto komplexného systému vplývajú na celkové správanie dráhy. Z dôvodu zvyšovania bezpečnosti a kvality železničných dráh je potrebné skúmať, ako tieto časti vplývajú na celkové správanie dráhy, a ako sa menia ich vlastnosti postupom času (opotrebovaním). Väčšina výskumov mechanického správania tratí sa dá rozdeliť do 3 kategórií: výskum na reálnych železničiach, softvérové simulácie na matematických modeloch a simulácie na laboratórnych prípravkoch.

2.1.2. Dynamické modely vlakov a dráh

Počítačové simulácie železničných dráh môžu oproti meraniam na reálnych dráhach urýchliť výskum. No modelovanie interakcie vlaku a železničnej dráhy je veľmi komplexný problém a overenie modelu môže byť náročné. Autori článku [4] navrhli dynamický model vlaku a koľajnice, pomocou ktorého dokážu analyzovať dynamické správanie vlaku pri vysokých rýchlostiach a nerovnom povrchu koľajnice. Týmto modelom je možné napríklad testovať rôzne odpruženia vlaku a sledovať vplyv na komfort pasažierov. Model ale nezahŕňa správanie ostatných častí dráhy. Komplexnejšie modely železničných dráh môžu obsahovať viac vrstiev (podložky, podvaly, lôžko), s nastaviteľnými parametrami.



Obr. 2.2: Vertikálny model vlaku a železničnej dráhy [5]

Autor práce [5] vytvoril vertikálny model vlaku a železničnej dráhy (obr. 2.2), kde vlak mal 10 stupňov voľnosti a dráha sa skladala zo spojitého nosníku ktorý bol diskretné podporený na miestach spojenia koľajnice s podvalom a dvoch ďalších vrstiev ktoré reprezentovali tuhosť 2-vrstvového lôžka. Autor zároveň odvodil spôsob ako estimovať veľkosti tuhostí a hmôt na základe parametrov lôžka (rozmery, hustota, modulus). Pomocou tohto komplexného modelu dokážeme analyzovať odozvu celého koľajiska pri rôznych nastaveniach parametrov, a ohodnotiť ich z hľadiska bezpečnosti a komfortu.

Na simulácie železničných dráh sa využívajú aj modely vytvorené metódou konečných prvkov (MKP). Tieto modely sú výpočetne veľmi náročné, no sú vhodné napríklad na analýzu pozemných vibrácií, alebo celkové správanie železničnej dráhy. [3, 6]

2.1.3. Používané parametre v dynamických modeloch

Pri simulácii pomocou matematických modelov je potrebné zvoliť vhodné parametre, aby sa správanie modelu čo najviac približovalo realite. Zistiť parametre niektorých niektorých častí je celkom jednoduché, napr. ohybovú tuhosť koľajnice vieme ľahko stanoviť na základe jej prierezu a použitého materiálu. No stanoviť napríklad tuhosť lôžka je už kom-

2.1. ŽELEZNIČNÉ DRÁHY

plikovanejšie a je potrebné využiť metódy na estimáciu parametrov na základe meraní. Jeho tuhosť sa však dá aproximovať aj analyticky, ako ukázal autor práce [5].

V práci [7] simulovali pomocou matematického modelu, ako sa bude meniť odozva železničnej dráhy pri zmene parametrov rôznych častí. Parametre nastavovali na základe rozsahu v tabuľke 2.1, čo predstavuje reprezentatívny rozsah tuhostí koľajnicovej podložky, vrchnej a spodnej vrstvy lôžka na európskych železničných dráhach.

	Spodná hranica	Vrchná hranica
Tuhosť koľajnicovej podložky [kN/mm]	60	500
Tuhosť vrchnej vrstvy lôžka [kN/mm]	100	200
Tuhosť spodnej vrstvy lôžka [kN/mm]	40	120


Tabuľka 2.1: Reprezentatívne hodnoty parametrov železničných dráh

2.1.4. Laboratórne modely dráh

Výskumy na laboratórnych prípravkoch sú rýchlejšie a bezpečnejšie v porovnaní s výskumom na reálnych železniciach. Ďalej je jednoduchšie meniť rôzne parametre a sledovať správanie koľajníc. Na základe meraní na lab. modeloch je možné overovať matematické modely. Laboratórne prípravky môžu byť zmenšené časti dráh (závisí na tom čo chceme pomocou prípravku skúmať), čo šetrí priestor a peniaze.

Laboratórne prípravky vieme rozdeliť do 3 hlavných kategórií. Prvou kategóriou sú prípravky na skúmanie železničného lôžka. Pomocou týchto prípravkov vieme skúmať vplyv rôznych materiálov a počtu vrstiev, deformácie a opotrebovanie lôžka pri cyklickom zaťažení, aký má vplyv znečistenie lôžka a podobne. Nedokážeme však pomocou nich simulovať ako vplývajú interakcie medzi kolesom, koľajnicou a podvalom na lôžko.

Druhá kategória prípravkov zahŕňa testovanie celej štruktúry železničnej dráhy. Tieto prípravky bývajú často v reálnej veľkosti, ale s kratšou dĺžkou, no môžu byť aj v pomere menšom ako 1:1 (obr. 2.3). Pomocou nich je možné testovať posuv koľajnice vo vertikálnom, priečnom a pozdĺžnom smere, životnosť rôznych častí, zmeny parametrov pri simulovaných prejazdoch alebo vznik permanentných deformácií.



Obr. 2.3: Zmenšený model železničnej dráhy s 3 podvalmi [8]

Predošlé laboratórne prípravky neboli vhodné na simuláciu interakcie medzi kolesom a koľajnicou pretože boli zatažované diskkrétne. Poslednou kategóriou sú prípravky ktoré riešia práve tento problém. Skladajú sa zo zataženého kolesa alebo celej nápravy ktorá sa odvaluje po koľajnici. Sú vhodné na testovanie odpruženia nápravy a pretože sa najviac približujú realite, sú vhodné aj na analýzu interakcie všetkých častí železničnej dráhy. [8]

2.2. Poruchy železničných dráh

Poruchy na železničných dráhach sa dajú rozdeliť na základe ich vlnovej dĺžky. Poruchy s krátkou vlnovou dĺžkou súvisia hlavne s poškodením povrchu koľajnice. Sú to napríklad praskliny, nekvalitné zvary alebo vlnkovitosť. Spôsobujú nadmerné vibrácie ktoré môžu urýchliť degradáciu ďalších častí dráhy alebo znížiť komfort pasažierov a pri vysoko-rýchlostných vlakoch dokážu znížiť bezpečnosť.

Poruchy so strednou až dlhou vlnovou dĺžkou súvisia s podvalmi a lôžkom. Ide hlavne o zmeny v globálnej vertikálnej tuhosti dráhy. Globálna vertikálna tuhosť je vzťah medzi aplikovanou silou a vertikálnym posunom koľajnice.[9] Cyklickým namáhaním sa môže na niektorých miestach štrkové lôžko opotrebovať až do takej miery, že nebude v kontakte s podvalom (visiace podvaly). V týchto miestach môže vznikať vyššie dynamické namáhanie ktoré urýchli degradáciu lôžka čo ďalej spôsobí veľké deformácie koľajníc a zníženie stability. [10]. Ďalej sa opotrebovaním môže meniť tuhosť koľajnicových podloží, čo zmení celkovú odozvu dráhy a zvýši namáhanie podvalov. [3]

Často problémové miesta bývajú priechody koľajníc cez cesty alebo prechody na most. Na prechodoch je prudká zmena vertikálnej tuhosti čo spôsobí vznik veľkých síl a urýchli degradáciu komponentov a ničenie lôžka. Tomuto je možné zabrániť vytvorením tzv. prechodových zón, kde sa vertikálna tuhosť dráhy mení kontinuálne. Tieto zóny sú označované ako kritické a je potrebné udržiavať ich vo veľmi dobrej kondícii. [11]. Železničné výhybky môžu byť taktiež označené za kritické miesta. Výhybky obsahujú mechanické diskontinuity, ktoré pri prejazde vlaku spôsobujú veľké nárazy, čo môže urýchliť opotrebovanie ďalších komponentov dráhy. [12] Z dôvodu bezpečnosti je potrebné vykonávať častú údržbu. Údržba železničných dráh je ale veľmi nákladná a preto vznikajú rôzne metódy na monitorovanie, predikciu a detekciu porúch na dráhach.

2.2.1. Spôsoby merania

Na základe toho, ktorú časť dráhy chceme kontrolovať, existujú rôzne metódy merania. Dajú sa rozdeliť do dvoch hlavných skupín: valivé merania a statické merania. Valivé merania sú vykonávané pomocou špeciálnych vozidiel alebo pomocou vlakov v prevádzke na ktorých sú pripevnené meracie zariadenia. Výhodou týchto meraní je, že pomocou nich dokážeme kontrolovať dlhé úseky koľajníc, relatívne vysokou rýchlosťou. Pri statických sú meracie zariadenia pripevnené priamo na častiach železničnej dráhy, čo umožňuje monitorovanie ich kondície v reálnom čase (napr. v kritických zónach).

Na monitorovanie železničnej dráhy sa využíva široká škála senzorov. Najvyužívanejšie sú senzory zrýchlenia, ktoré bývajú pripevnené na rôznych častiach dráhy, alebo na vlakových nápravách (pri valivých meraniach). Analýzou signálov z týchto senzorov je možné detekovať rôzne poruchy (povrchové vady, visiace podvaly, náhle zmeny tuhosti dráhy a pod.). Ďalšie často využívané senzory sú geofóny, ultra-zvukové snímče, optické

2.2. PORUCHY ŽELEZNIČNÝCH DRÁH

zariadenia na meranie vychýlenia koľajnice, tenzometre, piezo-elektrické senzory na meranie deformácie koľajnice, snímače vírivých prúdov atď. S pokrokmí v počítačovom videní sú častejšie využívané aj kamerové záznamy, ktorých analýza umožňuje detekciu povrchových väd alebo kontrolu geometrie. [9, 10, 11, 12, 13]

Všetky senzory generujú signály z ktorých nie vždy dokážeme detekovať poruchu na prvý pohľad. Preto je potrebné tieto signály vhodným spôsobom spracovať a ďalej analyzovať.

2.2.2. Analýza meraní a detekcia porúch

Pri detekcii povrchových väd je často využívaná časovo-frekvenčná analýza signálov z tzv. ABA meraní (*axle box acceleration*, meranie zrýchlenia nápravy). Použitie časovo-frekvenčnej analýzy umožní nahliadnuť na rôzne črty signálov, ktoré by boli v časovej doméne ťažko rozpoznateľné a pomocou ktorých dokážeme závady detekovať. V práci [14] autori predstavili prístup na detekciu ľahkých, stredných a ťažkých šikmých trhlin na jazdnej ploche koľajnice (ang. *squats*). ABA signály transformovali pomocou wavelet transformácie do časovo-frekvenčnej domény (vytvorili spektrogram), kde zistili, že pri prejazde vlaku cez trhlínu vzniknú vysoké vibrácie. Tieto miesta sa v spektrograme prejavili ako vysoké hodnoty koeficientov v určitých frekvenčných pásmach. Zároveň zistili, že ľahké a ťažké trhliny spôsobia vibrácie v rôznych frekvenciách. Povrchové vady je možné detekovať aj pomocou snímačov vírivých prúdov. Autori práce [15] využívali snímače vírivých prúdov na detekciu povrchových väd. Rôzne povrchové vady mali odlišné charakteristické črty v signáloch. Tieto signály spracovali pomocou wavelet transformácie a následne trénovali konvolučnú neurónovú sieť, pomocou ktorej tieto charakteristické črty v signáloch detekovali.

Častým problémom na železničných dráhach sú miesta kde vznikla dutina medzi podvalom a štrkovým lôžkom a podvaly tým pádom nemajú dobrý kontakt s lôžkom. Ich skorou detekciou dokážeme predísť opotrebovaniu ďalších komponentov dráhy. V práci [16] bola autormi navrhnutá metóda na detekciu takýchto miest s využitím ABA meraní. Zrýchlenia nápravy boli simulované pomocou dynamického modelu, čo im umožnilo ľahko meniť veľkosť dutiny pod podvalom. Simulované dáta spracovali pomocou wavelet scattering transformácie čím získali veľké množstvo črt. Z týchto črt následne vybrali tie, ktoré niesli najviac informácií o stave dráhy, a následne natrénovali model ktorý dokázal automaticky určiť či sa na dráhe nachádza vada a aká je jej závažnosť.


Opotrebovaním lôžka, alebo podložiek pod koľajnicami sa môže meniť ich tuhosť. Zmena tuhosti rôznych komponentov dráhy zmení aj jej dynamickú odozvu pri prejazde vlaku. Analýza tejto odozvy by nám preto mohla umožniť kontrolu zdravia jednotlivých komponentov. Autori práce [17] monitorovali zdravie železničných mostov na podobnom princípe. Matematicky simulovali zrýchlenie vlakovej nápravy pri prejazde po moste. Na moste menili veľkosť diery v okolí pilierov, ktorá môže vzniknúť prúdením vody, čo vplývalo na tuhosť celej štruktúry. Následne spracovali simulované zrýchlenia pomocou wavelet transformácie, kde hľadali rozdiely medzi poškodeným a nepoškodeným mostom.

2.3. Analýza signálov

Väčšina senzorov generuje napäťový signál, ktorý nesie informáciu o meranej veličine. Existujú rôzne metódy na spracovanie a analýzu signálov. Výber vhodného spôsobu závisí na tom, z akých meraní signály pochádzajú a čo v nich chceme hľadať.

2.3.1. Záznam signálov

Výpočtová technika nedokáže pracovať so spojitými signálmi s nekonečným rozlíšením. Aby sme tieto signály dokázali analyzovať s využitím počítačov, je potrebné ich najprv digitalizovať s využitím AD prevodníka.



Obr. 2.4: Vzorkovanie spojitého signálu

Proces digitalizácie sa skladá z 2 hlavných krokov: vzorkovanie a quantizácia. Pri vzorkovaní sa získava amplitúda signálu v diskrétnych časových intervaloch (obr. 2.4). Veľkosť tohto intervalu je určená vzorkovacou frekvenciou f_s . Výber vhodnej f_s je veľmi dôležitý a závisí na maximálnej frekvencii signálu ktorú chceme analyzovať. Nyquistov-Shannonov vzorkovací teorém nám hovorí, že na rekonštrukciu spojitého signálu je potrebná vzorkovacia frekvencia f_s ktorá je väčšia ako dvojnásobok maximálnej frekvencie signálu f_{max} : [18]

$$f_s > 2f_{max} \quad (2.1)$$

Pomocou tejto frekvencie bude zachovaná iba informácia o frekvencii signálu. Pre zachovanie amplitúdy signálu by mala byť f_s aspoň 10 násobne vyššia ako f_{max} . [19]

Quantizácia je prevod meraného napätia s nekonečným rozlíšením na binárne číslo s ktorým dokáže výpočtová technika pracovať. Jeho rozlíšenie závisí na počte bitov AD prevodníku. Rozlíšenie AD prevodníku je ďalší dôležitý parameter a závisí na tom aké veľké zmeny v signáli chceme sledovať. [20]

2.3.2. Predbežné spracovanie signálov

Signál môže obsahovať šum alebo deje na rôznych frekvenciách ktoré nám neprinášajú žiadne relevantné informácie a môžu ovplyvniť ďalšiu analýzu. Preto je vhodné signály predbežne spracovať. [21, 22]


Predbežné spracovanie môže zahŕňať odstránenie vadných signálov alebo prevzorkovanie signálu z dôvodu šetrenia pamäte, ale najhlavnejším nástrojom predbežného spracovania sú digitálne filtre. Ak vieme, že sa v signáli nachádza vysoko-frekvenčné rušenie,

2.3. ANALÝZA SIGNÁLOV

môžeme ho odstrániť pomocou dolno-priepustného filtra. Horno-priepustným filtrom je zas možné zo signálov odstrániť jedno-smernú zložku alebo nízkofrekvenčné trendy. Ak chceme analyzovať iba určité frekvenčné pásmo môžeme využiť pásmový filter.

Digitálne filtre

Digitálna filtrácia je proces ktorý umožňuje upraviť digitálne signály, zoslabiť alebo zosilniť jeho určité časti. Rozdeľujú sa na filtre s konečnou impulznou odozvou (FIR, *finite impulse response*) a s nekonečnou impulznou odozvou (IIR, *infinite impulse response*). Podľa frekvenčnej odozvy sa delia na: dolná prepust', horná prepust', pásmová prepust' a pásmová zádrž (obr. 2.5). Hlavnými parametrami filtrov sú hraničná frekvencia v priepustnej a zádržnej oblasti a zosilnenie v zádržnej oblasti.



Obr. 2.5: Frekvenčná odozva rôznych typov filtrov

FIR filtre fungujú na základe konvolúcie jadra filtra so vstupným signálom. Vlastnosťami týchto filtrov sú, že môžu mať lineárnu fázovú odozvu (čiže zachovávajú tvar originálneho signálu), sú stabilné, no majú vyššie nároky na výpočtovú silu a potrebujú väčší počet koeficientov na vytvorenie ostrej hrany vo frekvenčnej odozve obr. 2.5. IIR filtre sú systémy so spätnou väzbou, takže okrem vstupného signálu využívajú aj predchádzajúce výstupy systému. Ich výhodou je, že sú rýchlejšie na výpočet, no majú nelineárnu fázovú odozvu a môžu byť za určitých podmienok nestabilné.

Po predbežnom spracovaní môžeme prejsť k ďalšiemu spracovaniu a analýze signálov. V tejto práci sa budeme ďalej zaoberať hľadaním reprezentatívnych črt ktoré najlepšie popisujú merané signály a na základe ktorých ich dokážeme rozdeliť do určitých tried. Tieto črty môžeme získať analýzou signálu v časovej, frekvenčnej alebo časovo-frekvenčnej doméne. [23, 24]

2.3.3. Analýza signálu v časovej doméne

Črty popisujúce signál v časovej doméne sú získavané priamo z priebehu amplitúdy signálu na čase. Existuje obrovské množstvo týchto črt a výber súvisí s riešeným problémom. Napríklad, pri detekcii porúch ložísiak autori prác [25, 26] zistili, že je vhodné využiť črty ako: priemer, efektívna hodnota, smerodajná odchýlka, skewness, kurtosis. Alebo bezrozmerné črty: shape faktor, crest faktor, impulzný faktor, clearance faktor, skewness faktor a kurtosis faktor. Ich výpočet je tabulke 2.2.

Črty	Vzťah	Bezrozmerné črty	Vzťah
Priemer	$T_m = \frac{1}{n} \sum_{i=1}^n x_i$	Shape factor	$T_{sf} = \frac{T_{rms}}{\bar{x}}$
Efektívna hodnota	$T_{rms} = \left[\frac{1}{n} \sum_{i=1}^n x_i^2 \right]^{1/2}$	Crest factor	$T_{cf} = \frac{x_{\max}}{x_{rms}}$
Root	$T_r = \left[\frac{1}{n} \sum_{i=1}^n x_i ^{1/2} \right]^2$	Impulse factor	$T_{if} = \frac{x_{\max}}{\bar{x}}$
Smerodajná odchýlka	$T_{sd} = \left[\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{1/2}$	Clearance factor	$T_{clf} = \frac{x_{\max}}{x_r}$
Skewness	$T_{sk} = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)T_{sd}^3}$	Skewness factor	$T_{skf} = \frac{T_{sk}}{T_{rms}^3}$
Kurtosis	$T_{ku} = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)T_{sd}^4}$	Kurtosis factor	$T_{kuf} = \frac{T_{ku}}{T_{rms}^4}$

Tabuľka 2.2: Črty signálov v časovej doméne a ich výpočet


Existujú však aj komplexnejšie črty signálov v časovej doméne ako Wilsonova amplitúda, autoregresné koeficienty, cepstrum koeficienty, v-Order a pod. Ktoré je vhodné využívať napríklad pri klasifikácii elektromiografických signálov. [27, 28]

2.3.4. Analýza signálu vo frekvenčnej doméne

Transformovať signál z časovej domény do frekvenčnej dokážeme pomocou Fourierovej transformácie (3.2).

$$X(\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (2.2)$$

Táto transformácia funguje iba ak dokážeme popísať meraný signál spojitou matematickou funkciou. Pri meraných signáloch máme k dispozícii iba diskkrétne body (vzorky), preto je potrebné využiť diskrétnu Fourierovu transformáciu (DFT). Využitím DFT dostaneme hodnoty amplitúdy v diskkrétnych frekvenčných intervaloch, kdežto pri spojitý Fourierovej transformácii dostaneme spojitú amplitúdovo-frekvenčnú závislosť. Veľkosť frekvenčného intervalu je závislá na použitej vzorkovacej frekvencii a dĺžke signálu. FFT (fast Fourier transform) je efektívnejšou verziou DFT.



Obr. 2.6: FFT transformácia signálu zloženého z 3 sinusoid o 3 frekvenciách

2.3. ANALÝZA SIGNÁLOV

Pomocou tejto transformácie dokážeme zistiť z akých frekvenčných komponentov sa signál skladá (obr. 2.6). Niektoré črty z frekvenčnej domény, ktoré môžu byť použité na klasifikáciu signálov sú priemer alebo medián frekvencie, amplitúdy a pozície najväčších vrcholov, energia v rôznych frekvenčných pásmach a podobne. [27, 29]


Fourierova transformácia ale predpokladá, že transformovaný signál je stacionárny a opakuje sa do nekonečna. Na analýzu nestacionárnych signálov je Fourierova transformácia nevhodná. Pre takéto signály je vhodné využiť časovo-frekvenčnú analýzu. [30]

2.3.5. Analýza signálu v časovo-frekvenčnej doméne

Časovo-frekvenčnou analýzou dokážeme sledovať ako sa rôzne frekvenčné komponenty signálu vyvíjali v závislosti na čase. Preto je táto metóda vhodnejšia na skúmanie nestacionárnych signálov.

Krátkodobá Fourierova transformácia - STFT

STFT funguje tak, že signál rozdelí na menšie okná na ktorých následne použije Fourierovu transformáciu. Výsledkom STFT transformácie 1D reálneho signálu je 2D matica komplexných čísiel. Magnitúda tejto komplexnej 2D matice je často vyobrazená ako spektrogram (obr. 2.7) kde osa y je čas, osa x je frekvencia a osa z nesie informáciu o amplitúde (farebne kódovaná). Nastaviteľné parametre STFT sú veľkosť a funkcia okna alebo dĺžka prekrytia okien. [31]



Obr. 2.7: STFT chirp signálu [32]


Veľkosť okna vplýva na časové a frekvenčné rozlíšenie transformácie. Použitím veľkého okna dostaneme lepšie frekvenčné rozlíšenie, čo znamená, že dokážeme dobre separovať blízke frekvenčné komponenty, ale bude ich ťažšie lokalizovať v čase. Použitím krátkeho okna získame lepšie časové rozlíšenie (zmeny v signáli dokážeme lepšie lokalizovať), ale frekvenčné rozlíšenie sa zhorší. Tento kompromis medzi časovým a frekvenčným rozlíšením je hlavnou nevýhodou STFT, pretože toto okno je fixné a rozlíšenie nemusí byť dostatočné pre všetky frekvencie. Túto nevýhodu dokáže čiastočne vyriešiť napríklad wavelet transformácia. [33]

Ak by sme nepoužili žiadnu funkciu okna (alebo použili obdĺžnikové okno), môže vzniknúť tzv. "spectral leakage". Vzniká z toho dôvodu, že Fourierova transformácia predpokladá periodický signál, a použitím okna môže na krajoch vzniknúť diskontinuita, ktorá

sa v spektrograme prejaví ako vertikálne artefakty cez celé frekvenčné spektrum. Preto sa často využívajú špeciálne funkcie, ktoré sa na krajoch blížia k nule, aby bol problém s diskontinuitami eliminovaný. [34]

Wavelet transformácia

Wavelety patria do skupiny funkcií, ktoré sú lokalizované v čase a majú nulovú priemernú hodnotu (obr. 2.8).



Obr. 2.8: Rôzne wavelet funkcie [35]

Existuje veľké množstvo takýchto funkcií, Morlet, mexican hat, Haar, atď. Výber závisí na konkrétnom probléme. Wavelety vieme "natahovať" (dilatácia) a posúvať v čase (translácia), čo nám umožní lokalizovať rôzne frekvenčné komponenty v signáli.


Spojitú wavelet transformáciu (vzťah 3.3) môžeme chápať ako vzájomnú koreláciu rôzne dilatovaných wavelet funkcií so signálom. [36]

$$T(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (2.3)$$

Vo vzťahu 3.3, $x(t)$ je signál závislý na čase, ψ je wavelet funkcia, ktorá má parameter dilatácie a , a parameter translácie b . Funkcia pred integrálom $\frac{1}{\sqrt{a}}$ je váhová funkcia, ktorá zaistí aby wavelet funkcie, pri rôznych hodnotách dilatácie, mali rovnakú energiu.

Hlavnou výhodou oproti STFT je, že zlepšuje kompromis medzi frekvenčným a časovým rozlíšením. STFT má zafixovanú veľkosť okna, ale pri wavelet transformácii môžeme, pre nižšie frekvencie, použiť širšie okno (čo zlepší frekvenčné rozlíšenie) a pre vyššie frekvencie môžeme použiť kratšie okno (zlepšenie časového rozlíšenia). Táto vlastnosť nám v analyzovanom signáli umožní dobre separovať nízko-frekvenčné deje a zároveň dobre lokalizovať vysoko-frekvenčné deje. Na obrázku 2.9 je časovo-frekvenčná analýza signálu, ktorý sa skladá z 2 hyperbolických-chirp signálov (ľavý graf). Frekvencia týchto signálov sa rapídne zvyšuje v závislosti na čase. V strednom grafe je signál transformovaný pomocou STFT s 50 ms oknom. Z neho ale nedokážeme ľahko separovať obe komponenty signálu. Na pravom grafe je použitá wavelet transformácia a pomocou nej je možné tieto dve komponenty separovať. [37, 38]


2.3. ANALÝZA SIGNÁLOV



Obr. 2.9: Porovnanie STFT a wavelet transformácie hyperbolického chirp signálu [39]

Wavelet scattering transformácia

Je často využívaná pri klasifikácii 1D alebo 2D signálov. Pomocou tejto transformácie dokážeme zo signálov extrahovať spoľahlivé črty potrebné na ich klasifikáciu. Tieto črty sú invariantné na transláciu a a stabilné pri časovej deformácii. Má podobnú štruktúru ako konvolučné neurónové siete.[40, 41]



Obr. 2.10: Strom wavelet scattering transformácie [42]

Transformácia sa skladá z vrstiev ako je vidieť na obrázku 2.10. Vrstvy sa skladajú z uzlov a výstupy uzlov sú vstupmi pre uzly v nasledujúcej vrstve. Scattering koeficienty nulte vrstvy získame konvolúciou škálovacej funkcie ϕ so signálom f . V každom uzli ďalších vrstiev sa vykonávajú 3 operácie: konvolúcia wavelet funkcie ψ so signálom f , výpočet absolútnej hodnoty koeficientov a následne konvolúcia so škálovacou funkciou ϕ (vzťah 2.4).

$$S_1(t, \lambda_1) = |f * \psi_{1,1}| * \phi \quad (2.4)$$

S_1 vo vzťahu 2.4 sú scattering koeficienty prvej vrstvy, závislé na čase t a centrálnej frekvencii λ_1 použitej wavelet funkcie ψ . Koeficienty ďalších vrstiev získame rovnakým spôsobom ale do vzťahu namiesto f dosadíme absolútnu hodnotu konvolúcie f a ψ z predchádzajúcej vrstvy (vzťah 2.5).

$$S_2(t, \lambda_2) = ||f * \psi_{1,1}| * \psi_{2,1}| * \phi \quad (2.5)$$

2.4. Strojové učenie


Strojové učenie je oblasťou umelej inteligencie. Algoritmy strojového učenia si vytvoria model na základe tréovacích dát a pomocou tohto modelu dokážu robiť predikcie, alebo rozhodnutia. Pomocou týchto algoritmov dokážeme zautomatizovať širokú škálu úloh. Využíva sa napríklad, pri detekcii a identifikácii predmetov v obraze, v medicíne, alebo pri rozpoznávaní reči.

2.4.1. Algoritmy určené na klasifikáciu dát

Klasifikačné algoritmy dokážu určiť čo sa nachádza vo vstupných dátach. Tieto dáta môžu byť napr. hodnoty pixelov z obrázku, rôzne črty napätových signálov a podobne. Algoritmy sa delia na učenie s učiteľom a učenie bez učiteľa (ang. *supervised/unsupervised learning*). Pri učení s učiteľom je model trévaný na **označených dátach**, čiže model pri tréovaní vie, aký výstup od neho očakávame. Dáta musia byť označené človekom, preto je pri učení s učiteľom veľmi dôležité vytvoriť kvalitný dataset. Pre učenie s učiteľom existuje mnoho algoritmov: neurálne siete, naive Bayes, K-nearest neighbor, decision trees alebo **support vector machines**. Algoritmy na učenie bez učiteľa využívajú neoznačené dáta. Dáta dokážu rozdeliť do skupín na základe ich podobnosti. K tomu sa využívajú rôzne neurónové siete alebo zhuková analýza (ang. *cluster analysis*). [43]

Support vector machine klasifikátor


Úlohou SVM klasifikátoru je nájsť hyperplane v N-rozmernom priestore (N je počet vstupov), ktorý najlepšie oddeľuje dáta v závislosti na ich označení (triedach). Algoritmus učenia si ukážeme na zjednodušenom príklade. Ak budeme mať 2 vstupy (x_1 a x_2 na obr. 2.11), tak algoritmus bude v tomto 2D priestore hľadať optimálnu priamku ktorej vzdialenosť (ang. *margin*) od dát rozdielnych tried bude čo najväčšia. Nové dáta potom dokáže klasifikovať na základe toho, na ktorej strane priamky sa budú nachádzať.



Obr. 2.11: SVM - nájdenie hranice medzi 2 triedami

2.4. STROJOVÉ UČENIE

Výhodou SVM však je, že fungujú aj pri dátach v ktorých triedy nie sú lineárne separovateľné (tak ako na obr. 2.11). Predstavme si 1D vstup kde dátové body majú rozmiestnenie ako na ľavej strane obrázku 2.12. Triedy od seba nedokážeme separovať zvolením jedného bodu. SVM vie tento vstup rozšíriť do ďalšej dimenzie pomocou *kernel funkcie*, a v tomto rozšírenom priestore bude následne hľadať hyperplane, ktorý triedy rozdelí. V prípade na obr. 2.12 bol 1D vstup rozšírený do 2D pomocou kubickej funkcie ($y = x^2$), kde už bolo možné triedy separovať priamkou. [44, 45]



Obr. 2.12: Rozšírenie vstupu do vyššej dimenzie pomocou kernel funkcie

Pred tréňovaním je vhodné celý dataset rozdeliť na tréňovaciu a testovaciu množinu. Na tréňovacej sa model bude učiť, a jeho presnosť sa následne overí na testovacej množine. Výsledky z testovania dokážeme skontrolovať v špeciálnom grafe, tzv. **confusion matrix**, ktorý je na obrázku 2.13.

		Confusion matrix							
Pravdivá trieda	0	95.4%	1.1%		3.6%				
1	0.1%	94.0%	0.1%	5.7%					
2			98.4%	1.6%					
3	3.6%	1.0%		95.4%					
4					93.0%	6.6%	0.3%	0.1%	
5					0.3%	97.0%	0.4%	2.3%	
6							96.1%	3.9%	
7						0.1%	0.8%	99.1%	
		0	1	2	3	4	5	6	7
		Predikovaná trieda							

Obr. 2.13: Confusion matrix pre dáta s 8 triedami

Osa y značí pravdivú triedu dátového bodu a osa x značí predikovanú triedu ktorú predpovedal model. Hodnota na diagonále nám hovorí o tom, že koľko percent dátových bodov jednej triedy označil model správne. Hodnoty mimo diagonály zas hovoria o počte

nesprávnych predikcií. Napríklad, model správne označil triedu 0 pri 95,4% všetkých dátových bodov triedy 0 v datasete, nesprávne ich označil za triedu 1 pri 1,1% a za triedu 3 pri 3,6%. Týmto grafom dokážeme ľahko skontrolovať, či si model nezamieňa dve triedy.

2.4.2. Výber vhodných črt

Pred trénovaním modelov je vhodné vykonať výber črt (ang. *feature selection*), pretože dataset môže obsahovať redundantné a nepotrebné informácie. Výberom tých najlepších črt a odstránením nevhodných znížime počet dimenzií na vstupe, čím znížime komplexnosť modelu, urýchlíme proces trénovania, a v niektorých prípadoch aj presnosť modelov. Existuje veľké množstvo spôsobov na nájdenie najlepších črt. Dajú sa rozdeliť na *filter metódy*, *wrapper metódy* a *embedded metódy*. Filter metódy vyberajú črty na základe rôznych štatistickým ukazovateľoch. Wrapper a embedded metódy pri hľadaní črt zároveň trénujú aj model a na základe jeho presnosti upravujú výber vhodných črt. [46, 47]

Jednou z filter metód, ktorú budeme využívať aj v tejto práci, je **Minimum Redundancy Maximum Relevance** (mRMR) algoritmus. Tento algoritmus bol vyvinutý autormi práce [48], ktorý ho využívali na výber malej podmnožiny z veľkého počtu génov, na presnú klasifikáciu fenotypov. Pomocou tohto algoritmu dokážeme vybrať črty, ktoré majú čo najväčšiu koreláciu s klasifikovanou triedou (s výstupom) a čo najnižšiu koreláciu medzi jednotlivými vybranými črtami.

3. Ciele práce

V rešeršnej časti sme zistili z akých častí sa skladajú železničné dráhy a aké vady sa môžu v nich vyskytovať. Preskúmali sme rôzne spôsoby merania a detekcie porúch, používané v doterajších štúdiách. Zároveň sme vytvorili teoretický základ pre spracovanie signálov a klasifikáciu dát pomocou support vector machines (SVM). Úlohou nasledujúcich kapitol bude využitie laboratórneho modelu na simuláciu prejazdu vlaku, a nájdenie vhodného spôsobu ktorým dokážeme detekovať zmenu parametrov lab. modelu (vznik poruchy)

Cielom kapitoly 4. bude zoznámenie sa s laboratórnym modelom, ktorý reprezentuje zmenšenú časť železničnej dráhy, preskúmanie z akých častí sa model skladá a čo jednotlivé časti reprezentujú. Bližšie si popíšeme akým spôsobom budeme vykonávať merania a ktoré veličiny budú zaznamenávané. Nakoniec sa pozrieme na nastaviteľné parametre modelu a ako dokážeme pomocou nich simulovať vznik porúch.

V kapitole 5. budeme pomocou laboratórneho modelu simulovať prejazd vlaku. Pozrieme sa na merania získané z reálnych železničných dráh a skúsime nájsť najlepší spôsob zaťaženia lab. modelu, aby sa simulované a reálne signály čo najviac podobali. Následne vykonáme simulácie pri rôznych nastaveniach parametrov lab. modelu, čím získame potrebné dáta na analýzu.


Cielom poslednej kapitoly bude spracovanie a analýza získaných dát. Preskúmame aký vplyv mala zmena parametrov na deformáciu koľajnice. Ďalej sa budeme snažiť nájsť vhodné črty signálov, na základe ktorých dokážeme signály klasifikovať (detekovať zmenu nastavenia parametrov lab. modelu). Otestujeme rôzne črty, ktoré popisujú signály v časovej a frekvenčnej doméne. Zistenia sa následne pokúsime aplikovať na reálne dáta a zhodnotíme zvolený prístup.

4. Laboratórny prípravok

V tejto práci sa budeme ďalej zaoberať detekciou zmeny parametrov železničnej dráhy (konkrétne zmeny tuhosti lôžka a podložiek medzi koľajnicou a podvalom). Tieto zmeny budeme detekovať v signáloch, generovaných piezo-elektrickým senzorom, ktoré nesú informáciu o deformácii koľajnice. K tomu budeme potrebovať dostatočné množstvo dát. Experimentovanie na reálnych železničiach by bolo však príliš náročné, preto budeme dáta generovať s využitím laboratórneho prípravku.


4.1. Konštrukcia

Laboratórny prípravok je zmenšeným modelom železničnej dráhy, ktorý nám umožňuje simulovať prejazd vlaku, nastavovať parametre dráhy a skúmať odozvu koľajnice. Skladá sa z dvoch koľajníc, pružne spojených s podvalmi, ktoré sú následne pružne spojené s rámom prípravku. 3D model lab. prípravku je na obrázku 4.1 Simulácia zataženia spôsobeného vlakom je vykonaná pneumatickými piestami.



Obr. 4.1: CAD model laboratórneho prípravku


Koľajnica je v lab. modeli reprezentovaná ako hliníkový T profil o dĺžke 1,2 m, s hrúbkou 3 mm, výškou 50 mm a šírkou 20 mm (obr. 4.2).



Obr. 4.2: Rozmery prierezu koľajnice

4.1. KONŠTRUKCIA


Prichytenie koľajnice je reprezentované 2 párami tlačných pružín. Prichytenie sa skladá zo skrutky, ktorá je prevedená dierou v koľajnici a napevno pripevnená k podvalu. Na skrutke sú nasadené dve pružiny, jedna medzi spodkom koľajnice a podvalom, druhá medzi vrchom koľajnice a hlavou skrutky. Týmto je vytvorené pružné spojenie koľajnica-podval v kladnom aj zápornom vertikálnom smere. Ukážka tohto spojenia je na obrázku 4.3, kde podval je označený zelenou farbou, pružiny modrou a koľajnica šedou.



Obr. 4.3: Detail pružného spojenia koľajníc a podvalu

Koľajnice sú pripevnené k podvalu na 3 miestach, ktoré sú od seba vzdialené približne 60 cm. Podval je ocelový kváder, z vrchnej strany pružne spojený s koľajnicou a zo spodnej strany pružne spojený s rámom lab. prípravku.

Pružné spojenie podval-rám simuluje lôžko železničnej dráhy. Toto spojenie je vykonané pomocou dvoch hliníkových nosníkov namáhaných na ohyb so šírkou prierezu 15 mm a výškou 2 mm. Nosníky sú na obrázku 4.4 zobrazené oranžovou farbou. Ku stredu nosníkov je napevno pripevnený podval a kraje nosníkov sú pevne spojené s rámom.




Obr. 4.4: Detail pružného spojenia podvalu a rámu

Prejazd vlaku po koľajniciach simulujeme pomocou 9 pneumatických piestov, ktoré tlačia z vrchu na koľajnice. Na koncoch výsuvných častí piestov je plastový nástavec, ktorým docielime symetrické zaťaženie oboch koľajníc. Každý piest má vlastný, elektronicky ovládaný, 3 polohový ventil (ovláda zasunutie/vysunutie piestu, vyrovnanie tlaku v pieste). Vstupy ventilov sú cez redukčný ventil pripojené ku kompresoru s tlakovou nádobou. Redukčný ventil zaistí, že do piestov vždy pustíme rovnaký tlak 5 bar. Polohu ventilov meníme pomocou mikrokontroléru Arduino Leonardo a relé poľa.

Laboratórny prípravok vieme zjednodušiť do modelu ktorý je na obrázku 4.5, kde koľajnica je spojený nosník o ohybovej tuhosti EI, ktorá je na 3 miestach spojená s podvalom


o hmotnosti m_P pomocou pružiny s tuhosťou k_P a tlmiča s tlmením b_P . Podvaly sú následne spojené so základným telesom (rám) pomocou kombinácie pružiny a tlmiča, k_L a b_L . Zmenou parametrov k_P a b_P meníme vlastnosti simulovanej koľajnicovej podložky a zmenou k_L a b_L meníme vlastnosti železničného lôžka.



Obr. 4.5: Zjednodušený model popisujúci laboratórny prípravok

4.2. Popis meracieho reťazca

Pri simulácii prejazdu vlaku meriame deformáciu koľajnice pomocou piezo-elektrických senzorov. Tento senzor je tenká pizo-elektrická vrstva, ktorá pri jej deformácii generuje elektrický potenciál. Sú prilepené na spodnej a bočnej strane koľajnice (obr. 4.6), buď v strede medzi podvalmi, alebo na mieste podvalu. Meraním priebehu napätia na senzore a následným prepočtom dokážeme získať priebeh deformácie koľajnice.



Obr. 4.6: Pozície piezo-elektrických senzorov na koľajnici

Na záznam napätia bol využívaný AD prevodník od spoločnosti National Instruments. Vzorkovacia frekvencia záznamu bola nastavená na 10 kHz, čo by mala byť dostatočná hodnota pre naše potreby.

Pri meraní napätia piezo-elektrického senzoru, nieje vhodné senzor priamo pripojiť na meracie zariadenie, z dôvodu, že piezo-elektrické senzory majú veľmi vysokú výstupnú impedanciu a väčšina meracích zariadení má omnoho nižšiu vstupnú impedanciu, rádovo v $M\Omega$. Preto je potrebné použiť medzi senzorom a meracím zariadením obvod ktorý tento problém vyrieši. [49] V tejto práci bol použitý spôsob, kde výstupy senzoru boli pripojené na 15 k Ω rezistor, na ktorom sa meralo napätie spôsobené prúdom piezo-senzoru.

4.3. NASTAVITEĽNÉ PARAMETRE

Priebeh napätia dokážeme prepočítať na priebeh pomernej deformácie pomocou vzťahu 4.1. Kde e_{31} je piezo-elektrický modulus senzoru, L a B sú jeho rozmery, R_i je veľkosť odporu pripojená k senzoru, C_p je jeho kapacita a U je zmerané napätie. Veľkosti všetkých parametrov sa nachádzajú v tabuľke 4.1.

$$\epsilon_x = \frac{1}{e_{31}LB} \left(\frac{1}{R_i} \int_0^t U dt + C_p U(t) \right) \quad (4.1)$$

e_{31}	-5,1571
L	0,028 m
B	0,007 m
R_i	15 k Ω
C_p	15,11 · 10 ⁻⁹ F


Tabuľka 4.1: Parametre použitého piezo-elektrického senzoru

4.3. Nastaviteľné parametre

Laboratórny model nám umožňuje skúmať, aký vplyv bude mať zmena parametrov určitých častí na odozvu koľajnice pri prejazde vlaku. V modeli dokážeme jednoducho meniť tuhosť lôžka a tuhosť koľajnicovej podložky.

Tuhosť lôžka

Tuhosť lôžka k_L v lab. modeli dokážeme nastavovať zmenou dĺžky nosníkov na obr. 4.4. Ich dĺžku je možné nastavovať pomocou polohovateľného prichytenia k rámu. Aby sme mali predstavu o tom, akú veľkosť k_L sme nastavili, bude potrebné odvodiť závislosť ohybovej tuhosti nosníku na jeho dĺžke.



Obr. 4.7: Schéma nosníku, votknutého na oboch koncoch


Tuhosť k nám hovorí o veľkosti deformácie δ v závislosti na veľkosti aplikovanej sile F : $F = k\delta$. Ohybovú tuhosť nosníku dokážeme odvodiť použitím Bernoulliovej rovnice priehybovej čiary:

$$\frac{d^2 w(x)}{dx^2} = -\frac{M_y(x)}{E \cdot I_y}, \quad (4.2)$$

kde $w(x)$ je vertikálny priehyb nosníku, x udáva polohu na nosníku, $M_y(x)$ je ohybový moment, E je modul pružnosti v ťahu (závislý na použítom materiáli) a I_y je kvadratický moment prierezu (závislý na rozmeroch). Modul pružnosti a kvadratický moment dokážeme určiť jednoducho. Nosník je z hliníku, takže jeho modul pružnosti bude $E = 69$ GPa. Kvadratický moment vypočítame na základe rozmerov prierezu:

$$I_y = \iint_S x^2 dS = \frac{w \cdot t^3}{12} = \frac{0,015 \cdot 0,002^2}{12} = 1 \cdot 10^{-11} \text{ m}^4. \quad (4.3)$$

Priebeh ohybového momentu je na obrázku 4.8 a závislosť jeho veľkosti na polohe x je vo vzťahu 4.4. [50]



Obr. 4.8: Priebeh ohybového momentu M_y v závislosti na polohe x

$$M_y(x) = \frac{F(4x - L)}{8} \quad \text{pre } 0 < x < L/2. \quad (4.4)$$

Dosadením vzťahu 4.4 do 4.2 a dvojitém integrovaním dostaneme rovnicu priehybovej čiary:

$$w(x) = \frac{Fx^3}{12EI_y} - \frac{FLx^2}{16EI_y} \quad \text{pre } 0 < x < L/2. \quad (4.5)$$

Nás zaujíma priehyb v strede nosníku, kde je pripevnený podval, teda $x = L/2$. Po dosadení a upravení dostaneme finálnu závislosť aplikovanej sily na priehybe:

$$w(L/2) = -F \left(\frac{L^3}{192EI_y} \right), \quad (4.6)$$

kde člen v zátvorke je tuhosť nosníku k , resp. jeho prevrátená hodnota $1/k$. Zo vzťahu 4.7 môžeme vidieť, že tuhosť je okrem modulu pružnosti a rozmeroch prierezu závislá aj na dĺžke L na tretiu.

$$k = \frac{192EI_y}{L^3} \quad (4.7)$$

Tuhosť koľajnicovej podložky

Pružné spojenie koľajnice a podvalu reprezentuje koľajnicovú podložku. Podval je s koľajnicou spojený pomocou dvoch pružín. Pretože sú tieto pružiny paralelne, výsledná tuhosť koľajnicovej podložky k_P bude 2-násobok tuhosti pružiny $k_{pružina}$ (4.8).

$$k_P = 2k_{pružina} \quad (4.8)$$

V laboratórnom modeli bola použitá pružina s tuhosťou $k_{pružina} = 31,44 \text{ N/mm}$, a výslednou tuhosťou podložky $\mathbf{k_P = 62,88 \text{ N/mm}}$. Túto tuhosť dokážeme zmeniť výmenou za pružinu o inej tuhosti, alebo môžeme jednu pružinu odstrániť čím znížime tuhosť na polovicu.

Laboratórny prípravok bol navrhnutý tak, aby jeho tuhosti boli približne v **pomere 1/1000** k tuhosti reálnych železničných dráh.

5. Meranie ma laboratórnym prípravku

5.1. Nastavenie vhodných parametrov

Aby boli na lab. modeli nastavené realistické veľkosti tuhostí, budeme sa riadiť podľa tabuľky 2.1. V práci [7] kde tieto hodnoty využívali v matematickom modeli, mali lôžko rozdelené do 2 vrstiev. V našom lab. modeli je však lôžko reprezentované iba jednou tuhosťou k_L , preto tuhosti týchto dvoch vrstiev skombinujeme do jednej hodnoty. V ich modeli bola tuhosť 1. a 2 vrstvy lôžka reprezentovaná ako 2 pružiny v sérii. Výsledná tuhosť bude súčtom ich obrátených hodnôt a výsledný rozsah tuhosti pre jednovrstvové lôžko bude:

	Spodná hranica	Vrchná hranica
Tuhosť koľajnicovej podložky [kN/mm]	60	500
Tuhosť lôžka [kN/mm]	28,5	75

Tabuľka 5.1: Reprezentatívne hodnoty parametrov železničných dráh (1-vrstvové lôžko)

Náš laboratórny model bol navrhnutý tak aby boli tuhosti jednotlivých častí v pomere 1/1000 ku reálnym železničným dráham. Preto budeme na lab. modeli nastavovať 1000 násobne nižšie hodnoty ako sú v tabuľke 5.1.

Na prvé simulácie, kde budeme hľadať najlepší spôsob zataženia koľajnice, nastavíme tuhosť lôžka k_L 28,5 N/mm, aby sme sa nachádzali v rozsahu reprezentatívnych tuhostí. Dĺžka nosníka na základe vzťahu 4.7 bude:

$$L = \sqrt[3]{\frac{192EI_y}{k_L}} = \sqrt[3]{\frac{192 \cdot 69 \cdot 10^9 \cdot 1 \cdot 10^{-11}}{28500}} = 16,69 \text{ cm} \quad (5.1)$$

Na spojení koľajnica-podval ponecháme obi dve pružiny, čo znamená tuhosť koľajnicovej podložky 62,88 N/mm.

5.2. Meranie na reálnych železniciach


Pred začiatkom simulácií sa pozrieme na dáta z reálnych železničných dráh, ktoré boli zaznamenávané pomocou rovnakého meracieho reťazca ako v kapitole 4.2. Na obrázku 5.1 je priebeh napätia piezo-elektrického senzoru prilepeného zospodu koľajnice v strede medzi podvalmi, pri prejazde nákladného vlaku. Vlak mal 23 vagónov a jednu lokomotívu (graf zobrazuje detail prejazdu lokomotívy a prvých 6 vagónov). Každý vagón mal 2 nápravy s 2 kolesami. V tomto grafe môžeme pozorovať napäťové zákmity spôsobené prejazdom jednotlivých kolies po mieste merania.

5. MERANIE MA LABORATÓRNOM PRÍPRAVKU



Obr. 5.1: Získaný signál z reálnej železničnej dráhy (prejazd nákladného vlaku)

Obrázok 5.2 ukazuje detail prejazdu jednej nápravy cez miesto merania. Pribeh obsahuje dva zámky korešpondujúce s dvomi kolesami nápravy. Napätie spočiatku plynule stúpa, po dosiahnutí maximálnej hodnoty prudko klesne na zápornú hodnotu a následne sa plynule vráti do nuly. Znamienko napätia generované piezo-senzorom nám hovorí o smere deformácie koľajnice. Keď sa koleso vlaku približuje k miestu merania, prieťah koľajnice sa zväčšuje, čo znamená kladné znamienko napätia. Ak sa koleso nachádza presne v mieste merania, napätie je nulové (koľajnica dosiahla najväčší prieťah). Následne sa koleso začne z miesta merania oddalovať, prieťah koľajnice sa bude znižovať a napätie bude záporné. Na tomto obrázku je okrem priebehu napätia (vrchný graf) aj priebeh deformácie koľajnice (spodný graf). Priebeh deformácie bol získaný pomocou vzťahu 4.1. Čiernou prerušovanou čiarou sú vyznačené miesta, kedy napätie dosiahne nulu.




Obr. 5.2: Detail nameraného signálu (prejazd 1 nápravy vlaku) a prepočet na deformáciu

Na laboratórnom prípravku sa budeme spočiatku snažiť nájsť najvhodnejší spôsob zaťaženia koľajnice, ktorým získame napätové priebehy čo sa budú najviac podobáť priebehu z obrázku 5.2.

5.3. Simulácia odozvy koľajníc

Prvé sme testovali, ako bude vyzeráť priebeh napätia pri použití iba jedného piestu. Piest sa nachádzal nad stredným podvalom a zaznamenávali sme priebeh napätia senzoru na tom istom mieste, prilepeného zospodu koľajnice. Zátážná sekvencia prebiehala nasledovne: otvoril sa ventil, do piestu sa vpustil stlačený vzduch a zatlačil na koľajnice, v tejto polohe bol ventil ponechaný počas 60 ms, po uplynutí tejto doby sa ventil zatvoril, tlak v pieste sa vyrovnal s okolitým a piest následne prestal tlačiť na koľajnice. Všetky piesty sú v nezataženom stave v kontakte s koľajnicou, takže pri zatažení vykonávajú minimálny pohyb (týmto opatrením boli dosahované lepšie výsledky). Priebeh napätia senzoru pri tejto sekvencii je na ľavom grafe obrázku 5.3. Pravý graf zobrazuje priebeh napätia, keď bol ventil otvorený počas 30 ms.




Obr. 5.3: Simulácia prejazdu jedného kolesa (1 piest)

V dátach z reálnych železníc (obr. 5.2) napätie stúpalo plynule a bez väčších zákmitov. V simulovaných dátach nieje priebeh plynulý a obsahuje veľké množstvo zákmitov o vysokých frekvenciách. Simulovaný prejazd jedného kolesa má oproti reálnemu meraniu aj väčšiu dĺžku. Táto dĺžka je závislá na rýchlosti vlaku. V reálnych dátach trval zákmit spôsobený prejazdom jedného kolesa približne 65 ms, no pri simulovanom prejazde mal dĺžku približne 180 ms. Znížením doby, počas ktorej bol ventil otvorený (z 60 ms na 30 ms) sa táto dĺžka skrátila na približne 150 ms. Ďalším znižovaním doby otvorenia ventilu, aby sa dĺžka zákmitu čo najviac podobala realite, sme však narazili na limit. Pri nižších dobách otvorenia ventilu ako 20 ms sa stávalo, že piest vôbec na koľajnicu nezatlačil. Zároveň sa znižovaním tejto doby, znižovala aj amplitúda meraného priebehu napätia.


Ako ďalšie sme testovali postupnú vlnu, kedy boli zatažené vždy len 2 susedné piesty, ktoré sa postupne presúvali cez koľajnicu. Doba otvorenia ventilu každého piestu bola 60 ms a pri druhom meraní 20 ms. Priebehy napätia z rovnakého senzoru (v strede pod koľajnicou) sú na obrázku 5.4. Priebeh napätia pri 60 ms bol silne nesymetrický. Napätie stúplo do kladných hodnôt a po zmene polaritý veľmi dlhú dobu kmitalo v záporných hodnotách. Znížením doby otvorenia ventilu na 20 ms sa táto asymetria vylepšila, ale signál obsahoval veľké zákmity. Plynulé stúpanie napätia tak ako v reálnych dátach sa nám nepodarilo dosiahnuť. Toto je spôsobené pravdepodobne tým, že koľajnicu v lab.

modeli zafažujeme na diskretných miestach, kdežto na reálnych koľajniciach sa koleso odvaľuje spojitou a postupne sa približuje k miestu merania.



Obr. 5.4: Simulácia prejazdu jedného kolesa (postupná vlna)

Posledné bolo testované zafaženie koľajnice pomocou 3 piestov zároveň. Použité boli 3 stredné piesty a priebeh napätia bol meraný na rovnakom senzore. Priebehy napätia pri dobe otvorenia ventilu 40, 30 a 20 ms sú na obrázku 5.5. Použitím 3 piestov sme dostali priebehy napätia ktoré sa najviac podobajú reálnym meraniam. Obsahujú prudkú zmenu polarita a oproti predchádzajúcim simuláciám sa v nich nachádza menej vysoko-frekvenčných zákmitov.




Obr. 5.5: Simulácia prejazdu jedného kolesa (3 piesty)

V ďalších meraniach budeme používať zafaženie pomocou 3 piestov a s dobou otvorenia ventilu 30 ms, pretože bola veľmi podobná reálnemu meraniu. Pri 20 ms dobe otvorenia ventilu bola dĺžka celkového zákmitu kratšia, čím sa viac podobala realite, ale pri 30 ms dobe sme získavali spoľahlivejšie signály (pri opakovanom meraní sme častejšie získavali rovnaké priebehy napätia). Plynulé stúpanie ako je to v reálnych meraniach sa nám nepodarilo nasimulovať, pretože koľajnicu v lab. modeli zafažujeme diskretné.

5.4. Porovnanie simulovaných a reálnych dát

V tejto kapitole transformujeme signály z lab. modelu a reálnych meraní do časovo-frekvenčnej domény kde ich následne porovnáme. Signály transformujeme pomocou kontinuálnej wavelet transformácie (CWT), k čomu využijeme *Matlab* [51], knižnicu *Wavelet Toolbox* a funkciu `cwt()`. Vstupmi do tejto funkcie je 1D signál a vzorkovacia frekvencia, ktorou bol signál zaznamenaný. Funkcii je možné nastaviť aj ďalšie parametre napríklad, ktorú wavelet funkciu chceme na transformáciu použiť a jej parametre, `VoicesPerOctave` čím dokážeme meniť frekvenčné rozlíšenie transformácie a pod. Týmto parametrom ponecháme prednastavené hodnoty. Je však potrebné dať si pozor na dĺžku signálu ktorý budeme transformovať. Čím bude signál kratší, tým sa bude zvyšovať minimálna frekvencia ktorú dokážeme pomocou transformácie vyšetriť.

Simulovaný signál prejazdu jedného kolesa ktorý sme získali v predchádzajúcej kapitole mal dĺžku 1 s, kde v strede bol napätový zákmit a po krajoch nuly. Ak chceme transformovať zákmit spôsobený jedným kolesom na reálnej železnici (obr. 5.1), musíme ho z celého signálu vystrihnúť. Takýto signál bude ale veľmi krátky, preto použijeme tzv. *zero padding* a signálu na kraje doplníme nuly (rozšírime ho aby mal dĺžku 1 s). Napätový priebeh týchto signálov a ich transformácie do časovo-frekvenčnej domény sú na obrázku 5.6.



Obr. 5.6: Porovnanie simulovaných a reálnych signálov (prejazd 1 kolesa)


Na CWT signálu z lab. modelu si môžeme všimnúť, že veľká časť energie signálu bola koncentrovaná medzi frekvenciami 10 až 20 Hz. Signál obsahoval aj slabšie komponenty vo frekvencii približne 50 a 125 Hz. Signál z reálneho merania mal väčšinu energie koncentrovanú medzi frekvenciami 35 až 80 Hz. Tento rozdiel je spôsobený hlavne celkovou dĺžkou zákmitu (teda rýchlosťou prejazdu). No na lab. modeli sa nám túto dĺžku už ďalej upraviť nepodarilo. Reálny signál neobsahoval slabšie komponenty vo vyšších frekvenciách ako v prípade simulovaného signálu (50 a 125 Hz). Bielou prerušovanou čiarou je vyznačený tzv. *cone of influence*. Pod touto čiarou môžu byť CWT koeficienty nepresné. [52]

V simulovanom a reálnom signáli sú značné rozdiely. Ich vyriešenie by bolo však možné iba upravením laboratórneho modelu, pri ktorom by sme mali viac možností v simulácii prejazdu pri rôznych rýchlostiach.

5.5. Meranie odozvy pri zmene parametrov

Ako prvé budeme simulovať prejazd jedného kolesa po koľajnici, pri rôznych tuhostiach lôžka a koľajnicovej podložky. Pomocou týchto dát budeme v ďalšej kapitole hľadať vhodné črty signálov, na základe ktorých dokážeme detekovať zmenu tuhosti jednotlivých častí. Následne vykonáme merania s realistickejším zaťažením, ktoré bude simulovať prejazd 4 vagónov po koľajnici.

Pred začiatkom simulácií sme zvolili 9 hodnôt tuhosti lôžka a vypočítali k nim príslušné dĺžky nosníkov na základe vzťahu 4.7. 5 hodnôt bolo vybraných z rozsahu v tabuľke 5.1, čo sú hodnoty ktoré sa reálne vyskytujú na železničných dráhach (na grafe hodnoty od 28,5 do 49 N/mm). Potom boli vybrané 4 nižšie hodnoty (24,4 až 12,5 N/mm), ktoré reprezentujú napr. opotrebované lôžko, vysiacy podval a pod.




Obr. 5.7: Závislosť tuhosti nosníka na jeho dĺžke

Graf 5.7 ukazuje závislosť tuhosti lôžka na dĺžke nosníka, kde červenou farbou je vyznačený rozsah nízkych tuhostí a modrou rozsah prijateľných tuhostí. Pri každom nastavení tuhosti lôžka, sme zároveň menili aj tuhosť koľajnicovej podložky. Tu sme mali na výber z dvoch hodnôt tuhostí, 62,88 N/mm ktorá reprezentovala prijateľnú tuhosť podložky, a 31,44 N/mm ktorá reprezentovala nízku tuhosť podložky. Merania sme teda vykonali pri 18 kombináciách tuhostí lôžka a podložky. Meranie prebiehalo nasledovne: nastavila sa kombinácia tuhostí, spustil sa program ktorý kontinuálne zaťažoval koľajnicu pomocou najlepšej záťažnej sekvencie ktorú sme identifikovali v kapitole 5.3, a počas toho sme zaznamenávali priebeh napätia senzoru ktorý bol prilepený v strede pod koľajnicou. Tento postup sme zopakovali pre všetky kombinácie tuhostí. Výsledkom bolo 18 dvojminútových signálov ktoré obsahovali zákmity spôsobené simulovaným prejazdom kolesa. Každý signál obsahoval približne 45 zákmitov vzdialených od seba 2,5 s.

Ďalej sme simulovali prejazd 4 vagónov aby sme vytvorili signál, ktorý sa bude viac podobat signálom z reálnych železníc. Signál 4 vagónov bude obsahovať 16 zákmitov spôsobených prejazdom 16 kolies (8 náprav, každá náprava 2 kolesá), ktoré budú mať od seba rôzne vzdialenosti. Signál nákladného vlaku (obr. 5.1) sa skladal zo zákmitov, ktoré boli, pre jednu nápravu, vzdialené od seba približne 75 ms. Medzi nápravami na jednom vagóne bola doba približne 460 ms a medzi nápravami susedných vagónov 200 ms. Doba medzi jednotlivými kolesami je závislá na rozmeroch a rýchlosti vlaku. Chceme aby sa simulovaný signál čo najviac podobal reálnemu, no simulovaný zákmit spôsobený prejazdom kolesa je

5.5. MERANIE ODOZVY PRI ZMENE PARAMETROV

približne dvojnásobne dlhší ako zákmit pri reálnom nákladnom vlaku. Nedokážeme nasi-
mulovať zákmit tak blízko pri sebe, preto sme pri simulácii použili približne dvojnásobné
doby medzi jednotlivými kolesami a nápravami. Prejazd 4 vagónov sme vytvorili tak, že
sme za sebou spúšťali simuláciu prejazdu kolesa s rôznymi oneskoreniami.



Obr. 5.8: Porovnanie simulovaných a reálnych signálov (prejazd 4 vagónov)

Túto simuláciu sme vykonali 5 krát pre všetky kombinácie tuhostí lôžka a podložky, takže vo výsledku sme mali 90 signálov. Porovnanie reálneho signálu a simulovaného je na obrázku 5.8, kde na vrchnom grafe je signál z reálnej dráhy a na spodnom z laboratórneho modelu.

6. Spracovanie meraní

Zmenou tuhosti lôžka a koľajnicovej podložky by sa mala zmeniť aj odozva dráhy na prejazd kolesa. V tejto kapitole prebehne spracovanie nameraných signálov z lab. modelu a hľadanie vhodných črt pomocou ktorých dokážeme detekovať zmenu tuhosti lôžka a koľajnicovej podložky. K spracovaniu a analýze signálov budeme využívať *Matlab*.

6.1. Vytvorenie a popis datasetu

Pred spracovaním a analýzou nameraných signálov ich bude potrebné upraviť do formy, s ktorou sa bude ľahšie pracovať. Z merania v predošlej kapitole sme získali 18 dlhých signálov v ktorých sa nachádza približne 45 odoziev na prejazd kolesa. Každú odozvu budeme chcieť analyzovať samostatne, preto je potrebné signály narezať. Výsledkom bola matica 792×15000 , kde bolo 792 jednotlivých odoziev pri rôznych kombináciách tuhostí a o dĺžke 1,5 s (pri $f_s = 10 \text{ kHz}$). Ku každej odozve bola pridelená trieda v závislosti na kombinácii nastavených tuhostí lôžka k_L a podložky k_P . Jednotlivé triedy a príslušné tuhosti sa nachádzajú v tabuľke 6.1. Rovnaké triedy boli pridelené aj signálom, ktoré obsahovali odozvu 4 vagónov.

Trieda	0	1	2	3	4	5	6	7
k_L [N/mm]	12, 16	20, 24	29, 34	39, 44, 49	12, 16	20, 24	29, 34	39, 44, 49
k_P [N/mm]	62	62	62	62	31	31	31	31

Tabuľka 6.1: Rozdelenie dát do tried v závislosti na kombinácii parametrov k_L a k_P


6.2. Dataset s odozvou ”jedného kolesa”

V tejto kapitole budeme hľadať spôsob, ktorý nám umožní rozdeliť namerané signály s odozvou jedného kolesa do tried, v závislosti na nastavených tuhostiach laboratórneho modelu. Prvé preskúmame ako sa menila pomerná deformácia koľajnice pri zmene tuhosti. Následne preskúmame rôzne črty ktoré popisujú signály v časovej doméne a nakoniec budeme hľadať črty vo frekvenčnej doméne. Pomocou nájdených črt budeme trénovať support vector machine klasifikátor, ktorý dokáže automaticky rozdeliť signály do jednotlivých tried.

6.2.1. Črty signálov v časovej doméne


Pri zmene tuhosti lôžka by sme mali spozorovať aj zmenu veľkosti pomernej deformácie koľajnice, pretože sila pôsobiaca na koľajnicu je rovnaká. Aby sme sa mohli o tom presvedčiť, prepočítame namerané napäťové signály na pomernú deformáciu pomocou vzťahu 4.1. Na ľavej strane obrázku 6.1 je graf priebehu pomernej deformácie pre všetky merania pri tuhosti lôžka 12,5 N/mm, a napravo pri tuhosti 49 N/mm. Vyššia tuhosť lôžka spôsobila menšiu deformáciu koľajnice. Zároveň tu môžeme pozorovať, že pomerné deformácie pri rovnakých tuhostiach majú podobné priebehy, čo platilo aj pre ostatné merané tuhosti z rozsahu na obr. 5.7.

6.2. DATASET S ODOZVOU "JEDNÉHO KOLESA"



Obr. 6.1: Priebeh pomernej deformácie pri simulácii prejazdu jedného kolesa


Graf 6.2 ukazuje priemer maximálnych amplitúd pomernej deformácie v závislosti na tuhosti lôžka. Maximálna amplitúda klesá so stúpajúcou tuhosťou, ale toto klesanie nieje plynulé. Napríklad pri tuhostiach lôžka 29 a 34 N/mm by sme predpokladali väčší rozdiel v amplitúdach. Rovnako amplitúda pri tuhosti 49 N/mm by mala byť nižšia ako pri 44 N/mm. Tieto nepresnosti boli pravdepodobne spôsobené zlým nastavením dĺžky nosníkov, pretože sme pri zmene tuhosti lôžka uchytenie nosníkov posúvali o veľmi malé vzdialenosti, rádovo milimetre (graf 5.7).



Obr. 6.2: Hodnoty maximálnej deformácie v závislosti na tuhosti lôžka k_L ($k_P = 62$ N/mm)


Zmenu tuhosti lôžka dokážeme relatívne dobre detekovať iba na základe veľkosti deformácie. S použitím tohto prístupu však vzniká viac problémov. Prvým problémom je, že veľkosť sily ktorá pôsobí na koľajnicu nieje vždy konštantná, ako to bolo v prípade nášho laboratórneho modelu. Reálne vlaky môžu mať rôzne hmotnosti, takže budú pôsobiť na koľajnicu rôznymi silami a teda vzniknú aj rôzne veľkosti deformácie. Na identifikáciu tuhosti lôžka by sme preto potrebovali aj informáciu o hmotnosti vlaku. Ďalším problémom je, že iba pomocou hodnoty maximálnej deformácie, by sme nedokázali rozlíšiť medzi zmenou tuhosti lôžka a zmenou tuhosti koľajnicovej podložky. Na grafe 6.3 je rovnaká závislosť ako v predchádzajúcom grafe, ale tuhosť koľajnicovej podložky bola zmenená z 62

N/mm na 31 N/mm. Napríklad pri tuhosti lôžka 44 N/mm a tuhosti podložky 62 N/mm bola nameraná rovnaká pomerná deformácia ako pri tuhosti lôžka 39 N/mm a tuhosti podložky 31 N/mm (približne $3,1 \cdot 10^{-4}$ m/m). Na základe samostatnej hodnoty deformácie nedokážeme rozlíšiť medzi týmito dvoma nastaveniami laboratórneho modelu. K tomu bude potrebné použiť viac rôznych črt signálov.



Obr. 6.3: Hodnoty maximálnej deformácie v závislosti na tuhosti lôžka k_L ($k_P = 31 \text{ N/mm}$)

Ako ďalšie otestujeme klasifikáciu jednotlivých tried (tabuľka 6.1) s použitím efektívnej hodnoty signálov (RMS) a rozdielom medzi maximom a minimom signálu (peak2peak, P2P). Hodnoty týchto črt pre všetky namerané signály sú zobrazené v grafe na obr. 6.4. Os X je hodnota RMS signálu a os y je P2P. Jednotlivé triedy sú odlíšené farebne.



Obr. 6.4: RMS a P2P hodnoty nameraných signálov


6.2. DATASET S ODOZVOU "JEDNÉHO KOLESA"

Z grafu je vidieť, že jednotlivé triedy sú od seba dobre separovateľné a klasifikátor by nemal mať problém medzi nimi rozlíšiť. Jediné triedy ktoré by pre klasifikátor mohli byť problémové sú trieda 3 a 7, pretože ich hodnoty RMS a P2P sa prekrývajú.

K trénovaniu Support Vector Machine (SVM) klasifikátoru sme využívali *Matlab* aplikáciu s názvom *Classification Learner app* z knižnice *Statistics and Machine Learning Toolbox*. Vstupom pri trénovaní boli už spomínané hodnoty RMS a P2P všetkých signálov, označené triedami z tabuľky 6.1. Dáta boli rozdelené na trénovacie (70%) a testovacie (30%). Otestované boli 3 rozdielne kernel funkcie, lineárna, kvadratická a kubická. Výsledné presnosti modelov získané na testovacích dátach sa nachádzajú v tabuľke 6.2.

Kernel	lineárny	kvadratický	kubický
Presnosť [%]	73,8	91,1	92,0

Tabuľka 6.2: Presnosť modelov (črty RMS, P2P)




Obr. 6.5: Confusion matrix modelu s kubickým kernelom (črty RMS, P2P)

Najväčšiu presnosť mal SVM s kubickým kernelom, 92%. Confusion matrix (CM) pre tento model a testovacie dáta je na obrázku 6.5. Tu môžeme vidieť že model mal najväčší problém s triedou 3 a 7, ako sme predpokladali. 17,5% dátových bodov z triedy 3 označil nesprávne za triedu 7, a 17,9% dátových bodov triedy 7 označil ako triedu 3.

Pomocou tohto prístupu sa nám podarilo vytvoriť model, ktorý na základe RMS a P2P hodnôt dokáže rozdeliť signály do jednotlivých tried s úspešnosťou 92%. Problém ale nastane ak by sme s týmto prístupom klasifikovali dáta, pri ktorých by bola veľkosť sily aplikovanej na kolajnicu rozdielna. Vyššia sila by spôsobila zvýšenie amplitúdy meraného napätia a tým pádom by sa zvýšilo aj hodnoty RMS a P2P. Rozdielne veľkosti sily dokážeme simulovať vynásobením každého signálu náhodným číslom z intervalu $< 0,5 \quad 2 >$, čím náhodne zväčšíme alebo zmenšíme ich amplitúdy. Toto spôsobí, že dátové body, ako na obr. 6.4, sa budú prekrývať a jednotlivé triedy nebudú tak ľahko separovateľné. Túto zmenu môžeme pozorovať na obr. 6.6. Pre takto upravené dáta sme natrénovali SVM mo-

del, rovnako ako pri predošlých. Kvôli zlej separovateľnosti sa presnosť modelov zhoršila (tabuľka 6.3).



Obr. 6.6: RMS a P2P hodnoty nameraných signálov (náhodná zmena amplitúd)

Kernel	lineárny	kvadratický	kubický
Presnosť [%]	35,0	41,4	17,7

Tabuľka 6.3: Presnosť modelov (črty RMS, P2P a náhodná zmena amplitúd)

V časovej doméne existujú aj tzv. bezrozmerné črty signálov, ktoré otestujeme v nasledujúcej kapitole. Hlavnou výhodou týchto črt je, že ich hodnota nieje závislá na amplitúde, takže by mohli vyriešiť spomínaný problém, ktorý vznikne zmenou amplitúdy signálov.


6.2.2. Bezrozmerné črty signálov v časovej doméne

Pomocou *Matlab* funkcie `signalTimeFeatureExtractor()` sme získali shape factor, clearance factor, crest factor, impulse factor, skewness a kurtosis hodnoty všetkých nameraných signálov, ktoré boli upravené náhodným vynásobením z intervalu $< 0,5 \quad 2 >$. Týmto sme získali 6 čísiel popisujúcich každý zo 792 nameraných signálov. Následne by bolo vhodné z týchto črt vybrať len tie najvhodnejšie, aby vstupné dáta do SVM nemali zbytočne veľké množstvo dimenzií. Pri nízkom počte črt ich dokážeme vybrať aj manuálne, testovaním všetkých kombinácií a výberom tých najlepších. Zvolili sme si, že do SVM budú vstupovať 2 črty, takže budeme mať 15 rôznych kombinácií vstupov. Najväčšiu presnosť SVM model dosahoval pri použití črt **skewness** a **kurtosis**. Presnosti modelov pre rôzne kernely sú v tabuľke 6.4. Confusion matrix modelu s kubickým kernelom je na obrázku 6.7, kde môžeme vidieť, že najväčší problém mal model s triedou 0 a 2, kedy označil 11,5% a 11,1% dátových bodov nesprávne. Ale teraz dokázal správne klasifikovať aj signály, ktorých amplitúdy boli náhodne zmenené.

6.2. DATASET S ODOZVOU "JEDNÉHO KOLESA"


Kernel	lineárny	kvadratický	kubický
Presnosť [%]	72,6	90,7	92,4

Tabuľka 6.4: Presnosť modelov (črty skew, kurt a náhodná zmena amplitúd)



Obr. 6.7: Confusion matrix modelu s kubickým kernelom (črty skew, kurt)

Ak budeme mať väčšie množstvo črt, bude manuálny výber najlepších veľmi náročný. K výberu môžeme využiť napríklad **Minimum redundancy maximum relevance** algoritmus (mRMR), ktorý bol bližšie popísaný v kapitole 3.4.2. V *Matlabe* je tento algoritmus implementovaný vo funkcii `fscmrnr()`. Vstupom funkcie je 2D matica v ktorej riadky označujú jednotlivé merania a stĺpce označujú črty, a druhým vstupom je vektor tried priradených k meraniam. Do funkcie sme vložili hodnoty hore získaných bezrozmerných črt a získali sme ich ohodnotenie, ktoré je na obrázku 6.8. Najlepšie ohodnotené boli **kurtosis** a **skewness**, teda rovnaké črty aké sme vybrali manuálne.




Obr. 6.8: Ohodnotenie bezrozmerných črt pomocou mRMR algoritmu

Náhodnou zmenou amplitúd všetkých signálov, sa hodnoty bezrozmerných črt nemenili, takže klasifikátor dokázal rozdeliť signály s rôznymi amplitúdami. Nevýhodou použitia týchto črt je, že sú veľmi abstraktné a ich veľkosti sa menia s dĺžkou signálu. Klasifikácia reálnych dát by pomocou týchto črt bola náročná, pretože napr. dĺžky signálov sa môžu meniť v závislosti na rýchlosti alebo rozmeroch vlaku.

6.2.3. Črty signálov v časovo-frekvenčnej doméne


Namerané signály sme transformovali pomocou CWT do časovo-frekvenčnej domény. Transformáciou sme dostali 2D maticu CWT koeficientov, kde riadky niesli informáciu o frekvencii a stĺpce informáciu o čase (110 frekvencií x 15000 vzoriek signálu). CWT 3 signálov pri 3 rôznych tuhostiach lôžka (12, 16, 20 N/mm) sú na obrázku 6.9. Tuhosť podložky bola pri všetkých troch 62 N/mm. Pre všetky 3 tuhosti platilo, že najväčšia časť energie signálu bola koncentrovaná v okolí 14 Hz. Rozdiely medzi jednotlivými tuhosťami bolo možné pozorovať medzi frekvenciami približne 30 až 140 Hz. V signáloch sa nachádzali aj komponenty vo vyšších frekvenciách ako 140 Hz, no mali omnoho nižšiu energiu.



Obr. 6.9: Namerané signály pri 3 rôznych tuhostiach k_L a ich CWT

Ako ďalšie sme vypočítali energiu signálu v jednotlivých frekvenciách. Toho sme docielili tak, že sme spočítali kvadráty CWT koeficientov pre každú frekvenciu (každý riadok), čím sme dostali 1D vektor (1x110). Závislosť energie signálu na frekvencii je na obrázku 6.10. Týmto sme stratili informáciu o čase, ale ľahšie dokážeme spozorovať zmeny v signáloch pri zmene tuhosti.


6.2. DATASET S ODOZVOU "JEDNÉHO KOLESA"



Obr. 6.10: Energia signálov v závislosti na frekvencii

Na grafoch je zobrazená energia signálov vo frekvenciách 0 až 300 Hz, pre všetky namerané signály pri tuhostiach 12, 16 a 20 N/mm. V každom grafe je približne 45 kriviek, jedna krivka pre jedno meranie a oddelené sú od seba farebne. Väčšina kriviek sa prekrýva, čo značí o tom, že jednotlivé signály si boli veľmi podobné. Nachádzalo sa tu však pár signálov ktoré boli odlišné a tie bude vhodné pred ďalším spracovaním odstrániť.


Odlahlé signály je možné detekovať a odstrániť viacerými spôsobmi. V tejto práci sme odlahlé signály detekovali na základe vzájomnej korelácie signálov (ang. cross-correlation). Hodnota korelácie nám hovorí, ako sa dva signály na seba podobajú. Vytvorili sme korelačnú maticu pre všetky kombinácie tuhostí pri ktorých sme simulovali. Tieto matice boli diagonálne symetrické a jej rozmery boli závislé na počte meraní pri konkrétnej tuhosti (pre 50 meraní mala matica rozmer 50x50). Každý element matice je hodnota korelácie jedného signálu s iným signálom. Ukážková korelačná matica pre 5 signálov je zobrazená na obr. 6.11.



Obr. 6.11: Korelačná matica pre 5 signálov


Pomocou korelačnej matice sme odstránili tie signály, ktorých hodnota korelácie s ostatnými bola pod zvolenou hranicou (hranica bola 0.99). Grafy s energiou signálu v závislosti na frekvencii, vypočítané z datasetu kde boli odstránené odlahlé signály, sú

zobrazené na obrázku 6.12. Porovnaním obr. 6.10 s obr. 6.12 je vidieť, že odľahlé signály boli úspešne odstránené.



Obr. 6.12: Energia signálov v závislosti na frekvencii (odstránené odľahlé signály)

Z grafov 6.12 je vidieť, že pri zmene tuhosti lôžka sa rozmiestnenie energie signálu najviac mení vo frekvenčnom rozsahu 0 až 150 Hz (menia sa výšky vrcholov). Hodnoty energie by sme preto mohli využiť pri tvorbe črt a klasifikácii dát. Problém s využitím energie signálu však je, že jej hodnota je závislá na amplitúde signálu (takže aj veľkosti sily aplikovanej na koľajnicu) rovnako ako črty v časovej doméne (kapitola 6.2.1). Náhodnou zmenou amplitúd všetkých signálov sa veľkosti energií v jednotlivých frekvenciách zmenia (obr. 6.13) a klasifikátor by mal problém správne určiť triedu.



Obr. 6.13: Energia signálov v závislosti na frekvencii (náhodná zmena amplitúd)

Tento problém môžeme eliminovať napríklad tým, že pri klasifikácii použijeme namiesto energie, hodnoty "relatívnej energie". Relatívnu energiu vypočítame tak, že každú hodnotu energie v jednotlivých frekvenciách podelíme celkovou energiou signálu. Tým energiu normalizujeme (tak že súčet relatívnych energií cez všetky frekvencie bude 1) a zmena amplitúdy signálu nebude mať vplyv na hodnoty relatívnych energií. Problém s týmto prístupom by mohol nastať ak by signál obsahoval silné vysokofrekvenčné rušenie (napríklad silné vibrácie v okolí 300 Hz). Bolo by ho však možné vyriešiť napríklad použitím vhodného filtra. Ďalší spôsob ktorým by sme vedeli eliminovať problém so zmenou ampli-

6.2. DATASET S ODOZVOU "JEDNÉHO KOLESA"


túdy signálu je, že by sme pri klasifikácii využívali pomer energií susedných frekvenčných pásiem.

Spracovaním signálov pomocou CWT a analýzou sme zistili, ako sa mení rozmiestnenie energie signálov v jednotlivých frekvenciách, pri zmene parametrov lab. modelu. Ďalej sme určili, že pri vytváraní črt na tréning klasifikátora, bude pravdepodobne najlepšie, zamerať sa na veľkosti energií signálov vo frekvenciách 0 až 150 Hz.

Predbežné spracovanie

Identifikovali sme frekvenčný rozsah na základe ktorého sa budeme snažiť klasifikovať namerané signály. Preto by bolo vhodné frekvencie vyššie ako tento rozsah odfiltrovať, aby neovplyvňovali klasifikáciu. K vytvoreniu vhodného filtra využijeme *Filter Designer* z knižnice *Signal Processing Toolbox*.

V signáloch potrebujeme ponechať frekvencie z rozsahu 0-150 Hz, preto budeme navrhovať filter typu dolná-prepust, ktorý odfiltruje všetky frekvencie vyššie ako je hraničná frekvencia. Bol vytvorený equiripple¹ FIR filter s hraničnou frekvenciou 200 Hz, zosilnením v nepriepustnom pásme -80 dB a výškou zvlnenia v priepustnom pásme 0,2 dB. Hodnota zvlnenia v priepustnom pásme je čo najnižšia, aby filter neovplyvnil veľkosť energií vo frekvenčnom rozsahu 0-150 Hz.



Obr. 6.14: Frekvenčná odozva použitého filtra

Frekvenčná odozva filtru je na obrázku 6.14. Pri filtrovaní signálov sme využili *Matlab* funkciu `filtfilt()` pomocou ktorej dostaneme po filtrácii signály s nulovým fázovým posunom.


Wavelet scattering transformácia

Signály budeme klasifikovať na základe črt, ktoré nesú informáciu o energii signálu v rôznych frekvenciách. Doteraz sme hodnoty energií získavali pomocou CWT. Táto transformácia je však pomalá a dostaneme z nej zbytočne veľa koeficientov (pre 1,5 s signál maticu 110x15000). Preto využijeme wavelet scattering transformáciu (WST). Táto transformácia je rýchlejšia ako CWT a dostaneme z nej menej koeficientov, s ktorými

¹Filter so zvlnením v priepustnom pásme o rovnakej výške

sa následne ľahšie pracuje. Pri nastaveniach jednotlivých transformácií, ktoré sme používali v tejto práci, bola WST približne 10-násobne rýchlejšia ako CWT. Črty, pomocou ktorých budeme jednotlivé signály klasifikovať, budeme preto získavať na základe WST koeficientov.

Na grafe 6.15 sú zobrazené koeficienty 1. vrstvy WST transformácie, pre rovnaký signál ako bol na grafe 6.9 pri tuhosti lôžka 12 N/mm. Pre 1D signál o dĺžke 1,5 s sme získali 118x60 scattering koeficientov (118 frekvenčných pásiem, 60 časových bodov). Priebeh WST koeficientov je podobný ako CWT koeficientov, s rozdielom, že WST má nižšie frekvenčné a časové rozlíšenie. Nižšie rozlíšenie v čase nám nevadí, pretože iba vypočítame energiu koeficientov v jednotlivých frekvenčných pásmach. Potrebujeme však aby transformácia zachovala energiu signálu čo WST dokáže.




Obr. 6.15: WST signálu simulovaného prejazdu jedného kola

Črty ktoré použijeme pri trénovaní klasifikátoru získame tak, že vypočítame energiu scattering koeficientov v prvých 9 frekvenčných pásmach. Rozsahy frekvenčných pásiem sú zobrazené na grafe 6.16 a ich centrálné frekvencie v tabuľke 6.5. Týchto 9 pásiem pokrýva celý frekvenčný interval, v ktorom sme pozorovali najväčšie zmeny pri zmene parametrov lab. modelu. Týmto sme získali, pre každý signál, 9 hodnôt (črt) ktoré nesú informáciu o jeho energii v rôznych frekvenciách. Aby sme zaistili, že tieto hodnoty budú pri zmene amplitúdy signálu konštantné, normalizovali sme ich na základe celkovej energie signálu (transformovali sme ich na hodnoty relatívnych energií). Celkovú energiu sme vypočítali zo všetkých WST koeficientov (118x60).

Číslo črty	1.	2.	3.	4.	5.	6.	7.	8.	9.
Centrálna frekv. [Hz]	14,5	29,9	45,3	60,7	76,1	91,5	106,9	122,3	137,7

Tabuľka 6.5: Označenie WST črt a frekvencie na základe ktorých boli získané

6.2. DATASET S ODOZVOU "JEDNÉHO KOLESA"




Obr. 6.16: Prvých 9 wavelet scattering filtrov

Pomocou týchto 9 črt sme natrénovali SVM klasifikátor. Pri trénovaní sme použili iba 50% zo všetkých nameraných dát a na zvyšku sme model testovali. Týmto zistíme, či sa model nepreučí a či dokáže správne klasifikovať aj dáta ktoré nikdy nevidel. Každý signál bol náhodne vynásobený hodnotou z intervalu 0,5 až 2 aby sme otestovali, či model dokáže klasifikovať aj signály s rôznymi amplitúdami. V SVM modeloch boli použité 3 rôzne kernel funkcie. Ich presnosti na testovacom datasete sú v tabuľke 6.6. Všetky modely dosahovali vysokých presností.

Kernel	lineárny	kvadratický	kubický
Presnosť [%]	99,3	99,7	99,7


Tabuľka 6.6: Presnosť modelov (WST črty 1 až 9)

Na grafe 6.17 je vidieť hodnoty jednotlivých črt. Na ľavej strane sú hodnoty pre rôzne tuhosti lôžka (oddelené farebne) a tuhosť podložky 62 N/mm, na pravej strane pre tuhosť podložky 31 N/mm. Z týchto grafov môžeme pozorovať, že relatívna energia medzi frekvenciami 60,7 až 91,5 Hz (črta 4 až 6) bola celkovo vyššia pri tuhosti podložky 31 N/mm oproti tuhosti 62 N/mm.



Obr. 6.17: Hodnoty WST črt pre rôzne kombinácie k_L a k_P

Najlepšie je však vytvoriť model, ktorý bude mať čo najnižšiu komplexnosť. Preto je vhodné vybrať čo najmenší počet črt, ktoré budú najreprezentatívnejšie a zároveň neznížia presnosť modelu (alebo presnosť znížia iba minimálne). K výberu najlepších črt využijeme mRMR algoritmus. Vstupom do mRMR funkcie je 9 črt z tabuľky 6.5 pre každý signál z datasetu (matica 9x756) a vektor tried (1x756). Ohodnotenie každej črty týmto algoritmom je na grafe 6.18.



Obr. 6.18: Ohodnotenie WST črt pomocou mRMR algoritmu


Štyri najlepšie ohodnotené črty sú hodnoty relatívnej energie vo frekvenciách 14,5; 91,5; 76,1 a 60,7 Hz (1. 6. 5. 4. v tabuľke 6.5). Tieto 4 črty sme použili pri trénovaní ďalších modelov, rovnakým spôsobom ako pri 9 črtách. Ich presnosti sú v tabuľke 6.7. Najlepšie výsledky sme dosahovali použitím kubického kernelu a priemerná presnosť sa oproti modelu s 9 črtami zhoršila iba o 1,5%.

Kernel	lineárny	kvadratický	kubický
Presnosť [%]	94,4	97,5	98,2

Tabuľka 6.7: Presnosť modelov (WST črty 1,4,5,6)

Z confusion matrixu pre model s kubickým kernelom na obr. 6.19 je vidieť, že model mal najväčší problém s triedou 1, ktorú pri 4,3% dát označil nesprávne. Pomocou mRMR sa nám podarilo identifikovať najvodnejšie črty pre klasifikáciu tried, a tým sme úspešne znížili komplexnosť modelu, s minimálnym znížením jeho presnosti.

6.3. DATASET S ODOZVOU "4 VAGÓNOV"



Obr. 6.19: Confusion matrix modelu s kubickým kernelom (WST črty 1,4,5,6)

V tejto kapitole sme zistili, že pri zmene parametrov lab. modelu, sa menili aj merané signály. Wavelet scattering transformáciou, sme zo signálov získali 4 črty, pomocou ktorých dokázal SVM klasifikátor správne určiť nastavené parametre, s presnosťou 98,2%. Tieto 4 črty niesli informáciu o veľkosti relatívnej energie signálu v 4 rôznych frekvenciách (črty 1,4,5,6 z tab. 6.5). Použitie relatívnej energie zaistilo, že hodnoty črt neboli závislé na amplitúde signálu, ale iba na jeho tvare.

6.3. Dataset s odozvou "4 vagónov"

V predchádzajúcej kapitole sme identifikovali vhodné črty pomocou ktorých sme úspešne dokázali klasifikovať namerané dáta. Tieto dáta však obsahovali odozvu na prejazd "jedného kolesa" (samostatný zákmit, obr. 6.9). V reálnych meraniach sa však takýchto zákmitov vyskytuje viac a sú blízko seba (spôsobené kolesami náprav).

Preto sme v kapitole 5.4 vytvorili realistickejšie merania, ktoré reprezentujú prejazd 4 vagónov cez kolajnicu. Rovnako ako pri prejazde jedného kolesa, boli merania vykonané pri všetkých kombináciách tuhosti lôžka a podložky a výsledné signály sme rozdelili do tried podľa tabuľky 6.1. Bol použitý totožný filter s hraničnou frekvenciou 200 Hz, aby boli zo signálov odstránené vysokofrekvenčné vibrácie. Na obrázku 6.20 je jeden z týchto signálov, pri tuhosti lôžka 12 N/mm a tuhosti podložky 62 N/mm.




Obr. 6.20: Nameraný signál pri simulácii prejazdu 4 vagónov

Zákmity spôsobené prejazdom kolies jednej nápravy, sú príliš blízko seba a vyšetřovať ich samostatne bude náročné. Preto budeme črty počítať z dvoch (alebo viac) po sebe idúcich zákmitov. Tieto zákmity by mali mať podobný priebeh, pretože vznikli pri rovnakom zaťažení a rovnakom nastavení lab. modelu.

V predošlej kapitole sme črty počítali pre signály, ktoré obsahovali jeden zákmit. Ak vypočítame rovnaké črty zo signálu ktorý obsahoval dva po sebe nasledujúce zákmity, a zákmity mali rovnaký tvar, hodnoty črt by mali zostať nezmenené. Toto je z dôvodu, že používame hodnoty relatívnej energie signálov. Nezáleží na amplitúde zákmitu, a ani na počte zákmitov v signáli, pokiaľ majú rovnaký tvar.

Aby sme toto tvrdenie overili, spojili sme dva rôzne signály prejazdu jedného kolesa, pri rovnakých tuhostiach (lôžko 12 N/mm, podložka 62 N/mm). Výsledný signál je na obrázku 6.21 (ľavý graf). Obom zákmitom bola náhodne zmenená amplitúda, ale ich tvar je podobný pretože boli získané pri rovnakých nastaveniach lab. modelu.




Obr. 6.21: Umelo vytvorený signál dvoch zákmitov a jeho hodnoty WST črt

Tento signál sme transformovali pomocou wavelet scattering a vypočítali sme črty na základe relatívnej energie. Hodnoty črt by sa mali zhodovať s hodnotami získaných zo signálov so samostatnou odozvou jedného kolesa. Na pravej strane obrázku 6.21 je vidieť, že ich hodnoty sa zhodujú. Červené body zobrazujú hodnoty črt pre signály s odozvou jedného kolesa, červená čiara ich priemernú hodnotu. Modré krížiky a prerušovaná čiara zobrazujú hodnoty črt vypočítaných pre signál s kombináciou dvoch zákmitov. Týmto

6.3. DATASET S ODOZVOU "4 VAGÓNOV"


sme overili, že hodnoty črt sa nezmenia, ani keď signál obsahuje viac po sebe idúcich zákmitov rovnakého tvaru.

Pokiaľ majú zákmity na obrázku 6.20 podobný priebeh ako zákmity analyzované v predchádzajúcej kapitole, mali by sme byť schopný tieto signály klasifikovať s využitím posledného SVM modelu. Signály so simulovaným prejazdom 4 vagónov, pri všetkých kombináciách parametrov lab. modelu, sme transformovali pomocou wavelet scattering. WST koeficienty pre signál na obrázku 6.20 sú zobrazené na obrázku 6.22. Hodnoty črt boli vypočítané zvlášť pre každú nápravu (červené okná v grafe). Týmto sme vytvorili nový dataset ktorý obsahoval črty náprav. Dataset sme následne klasifikovali pomocou posledného SVM modelu, s kubickým kernelom.



Obr. 6.22: WST signálu simulovaného prejazdu 4 vagónov


Presnosť klasifikácie bola iba **34,1%** a výsledný confusion matrix je na obrázku 6.23. Predchádzajúci model nedokázal správne klasifikovať tento nový dataset. So 100% presnosťou trafil iba triedu 1 a 7.



Obr. 6.23: Confusion matrix predchádzajúceho modelu na novom datasete (4 vagónov)

Porovnaním hodnôt črt pre signály s prejazdom jedného kolesa a črt pre jednotlivé nápravy si môžeme všimnúť, že ich hodnoty boli rozdielne, a preto ich model nedokázal správne klasifikovať. Porovnanie týchto hodnôt pri 3 rôznych tuhostiach lôžka je na ob-

rázku 6.24. Červenou farbou sú zobrazené hodnoty črt pre signály s prejazdom jedného kolesa a modrou farbou hodnoty črt pre jednotlivé nápravy. Medzi jednotlivými nápravami simulovaného vlaku však neboli veľké rozdiely, a ich hodnoty črt boli rovnaké.



Obr. 6.24: Porovnanie WST črt signálov zo simulácií prejazdu jedného kolesa a 4 vagónov

Tieto rozdiely mohli byť spôsobené buď tým, že simuláciou prejazdu dvoch kolies blízko seba sa zmenila odozva koľajnice (táto zmena by bola pravdepodobne závislá na rýchlosti prejazdu), alebo problémom v pneumatickej časti lab. modelu.


Bolo by vhodné preveriť, aký vplyv má rýchlosť prejazdu na odozvu koľajnice. No momentálna verzia lab. modelu nám neumožňuje túto rýchlosť meniť. Zvýšením rýchlosti simulovaného prejazdu by sa mala zmenšiť aj dĺžka zákmitu spôsobená jedným kolesom. Tu ale narazíme na limit, kedy doba otvorenia ventilov bude tak malá, že piesty koľajnicu nezatažia (bližšie popísané v kapitole 5.3). Spomalením rýchlosti by sa zas merané signály vôbec nepodobali realite.

Rozdiely však môžu byť spôsobené aj pneumatickou časťou. Piesty, ktoré zatažujú koľajnicu modelu, nemusia mať vždy rovnaký priebeh sily. Na obrázku 6.20 si môžeme všimnúť, že amplitúdy jednotlivých zákmitov sú rozdielne, no na každý zákmit bola použitá rovnaká záťažná sekvencia (rovnaký počet piestov, časy otvorenia ventilov a pod.). Ich amplitúda bola tým nižšia, čím bol zákmit bližšie k predchádzajúcemu. No nepodarilo sa nám identifikovať presnú príčinu týchto rozdielných amplitúd.

Zistili sme však, že WST črty jednotlivých náprav simulovaného vlaku majú rovnaké hodnoty. Preto natrénujeme nový SVM model na črtách náhodných náprav simulovaných vlakov. A následne otestujeme, či model dokáže správne klasifikovať črty vypočítané z celého signálu. Toto by nám mohlo uľahčiť klasifikáciu dlhších signálov, pretože by sme nemuseli zo signálov vystrihávať jednotlivé nápravy.

Model sme natrénovali na 50% datasetu, ktorý obsahoval prejazdy náprav (obr. 6.22). Použitý bol kubický kernel, pretože modely s týmto kernelom doposiaľ dosahovali najlepšie výsledky. Následne sme vypočítali črty z celého signálu simulovaného prejazdu 4 vagónov a tie sme klasifikovali pomocou natrénovaného modelu. Výsledný confusion matrix je na obrázku 6.25. Problémová bola trieda číslo 5, ktorú model klasifikoval iba so 60% presnosťou. Celková presnosť modelu bola **95,6%**.

6.4. ZHODNOTENIE PRÍSTUPU NA REÁLNYCH DÁTACH




Obr. 6.25: Confusion matrix nového modelu (výpočet WST črt z celého signálu)

Týmto sme overili, že pri výpočte WST črt nezáleží na počte zákmitov v signáli. Pokiaľ budú mať jednotlivé zákmity podobný tvar, potom budú hodnoty WST črt vypočítané z jednej nápravy alebo celého vlaku rovnaké.


6.4. Zhodnotenie prístupu na reálnych dátach

V tejto kapitole sa pozrieme na dáta z reálnych železničných dráh a skúsime využiť predchádzajúce zistenia z meraní na laboratórnom modeli. Ukážkové meranie na reálnej dráhe je na obrázku 6.26. Po mieste merania prechádzal vlak RAILJET s 1 lokomotívou a 7 vagónmi.




Obr. 6.26: Meranie na reálnej železničnej dráhe (vlak RAILJET)

Vypočítali sme WST črty pre každú nápravu, rovnakým spôsobom ako v predchádzajúcej kapitole. Predtým sme zo signálu odstránili vysokofrekvenčné komponenty použitím filtra s hraničnou frekvenciou 200 Hz. Hodnoty črt pre všetky nápravy sú na obrázku 6.27. Čiernymi bodmi sú označené jednotlivé nápravy a prerušovaná čiara označuje ich priemernú hodnotu.



Obr. 6.27: Hodnoty WST črt vypočítaných pre každú nápravu vlaku RAILJET

Hodnoty črt pre väčšinu náprav boli podobné (mali nízku vzdialenosť od priemernej hodnoty). Nachádzali sa tu však 2 nápravy ktoré mali tieto hodnoty viac vzdialené od priemernej hodnoty (označené červenými bodmi). Ich odozvy mali rozdielny priebeh ako zvyšok náprav. Tieto rozdiely si môžeme všimnúť aj v napätovom priebehu (obr. 6.28). Zákmit spôsobený jedným kolesom mal odlišný priebeh od ostatných. Toto mohlo byť spôsobené napríklad vadou v odpružení nápravy, alebo vadným kolesom.




Obr. 6.28: Detail signálu (2 nápravy)

Porovnaním WST črt z meraní na reálnych dráhach a laboratórnom modeli si môžeme všimnúť, že sú medzi nimi značné rozdiely (obr. 6.29). Na ľavom grafe sú hodnoty črt z

6.4. ZHODNOTENIE PRÍSTUPU NA REÁLNYCH DÁTACH

meraní na laboratórnom modeli, pri rôznych tuhostiach lôžka a koľajnicovej podložky (farebne oddelené). Pri zmene parametrov sa ich hodnoty rôzne menili. Na základe týchto zmien sme dokázali dáta rozdeliť do určitých tried, závislých na parametroch lab. modelu. Ku klasifikácii nám stačilo využiť iba črty 1, 4, 5, 6, pretože na základe nich boli jednotlivé triedy najlepšie separovateľné.



Obr. 6.29: Porovnanie WST črt simulovaných prejazdov a reálnych meraní

Na pravom grafe sa nachádzajú priemerné hodnoty WST črt získané z reálnych meraní, pre 3 rôzne vlaky, nákladný, osobný a už spomínaný RAILJET. Merania boli vykonané na tom istom mieste a v ten istý deň (takže parametre železničnej dráhy by mali byť veľmi podobné, tým pádom aj hodnoty črt).

Pri lab. modeli mala 1. črta najvyššiu hodnotu (relatívna energia signálu vo frekvencii 14,5 Hz) a ostatné črty mali značne nižšie hodnoty (relatívna energia signálu vo vyšších frekvenciách). No pri reálnych meraniach, mali črty vo vyšších frekvenciách väčšie hodnoty, (energia reálnych signálov bola rovnomernejšie rozdelená do vyšších frekvencií).

Hodnoty črt pre všetky 3 vlaky by mali byť rovnaké, pretože bolo meranie vykonané na tom istom mieste a v ten istý čas, no sú mierne rozdielne. Tieto rozdiely sú pravdepodobne spôsobené tým, že každý vlak zaťažil koľajnicu trochu iným spôsobom. Napríklad z dôvodu rozdielnych rýchlostí vlakov, konštrukcie odpruženia nápravy a pod.

Ak by sme chceli využiť informácie získané z lab. modelu na identifikáciu zmien tuhostí v reálnych dráhach, lab. model by musel byť pravdepodobne upravený. Bolo by vhodné upraviť mechanizmus na zaťažovanie koľajníc, tak aby sa namerané signály viac podobali reálnym. Pri momentálnej verzii lab. modelu, boli medzi simulovanými a reálnymi signálmi značné rozdiely. Tento mechanizmus by nám zároveň mohol umožniť zmenu rýchlosti simulovaného prejazdu, aby sme dokázali vyšetriť, ako bude vplývať rýchlosť na odozvu koľajníc. Ďalej by bolo vhodné vykonávať dlhodobé merania na železničných dráhach, tieto merania spracovať spôsobom ktorý bol popísaný v tejto práci a sledovať, ako sa budú vyvíjať hodnoty WST črt vo väčších časových úsekoch. A zároveň sledovať aké budú v črtách rozdiely medzi jednotlivými vlakmi.

7. Záver

V rešeršnej časti sme zistili, z akých častí sa skladajú železničné dráhy a aké poruchy sa môžu v nich vyskytovať. Preskúmali sme niekoľko štúdií, v ktorých autori predstavovali rôzne metódy určené na detekciu porúch v dráhach. Väčšina týchto metód, spočívala vo zvolení vhodných senzorov a spracovaní získaných dát. Najčastejšie využívaným spôsobom spracovania signálov bola ich transformácia do časovo-frekvenčnej domény. Ako ďalšie sme vytvorili teoretický základ pre rôzne spôsoby spracovania signálov a klasifikáciu dát pomocou support vector machine (SVM) algoritmu.

V kapitole 4 sme predstavili laboratórny model, ktorý simuloval zmenšenú časť železničnej dráhy. Model sa skladal z 2 koľajníc, ktoré boli na 3 miestach pripevnené k podvalom. V modeli bolo možné nastavovať tuhosť spojenia koľajnica-podval (reprezentovala tuhosť koľajnicovej podložky v reálnych dráhach) a tuhosť spojenia podval-rám (reprezentovala tuhosť lôžka reálnej dráhy). Tieto parametre boli nastaviteľné a pomocou nich sme dokázali simulovať vznik poruchy, napríklad opotrebovanie štrkového lôžka dráhy. Ďalej tu bol popísaný merací reťazec. Merali sme deformácie koľajnice pri simulovanom prejazde vlaku pomocou piezo-elektrických senzorov.

Ďalšia kapitola spočívala v meraní na lab. modeli. Prvé sme stanovili vhodné nastavenie tuhostí jednotlivých častí, na základe rozsahov ktoré sa nachádzajú na reálnych železničných dráhach (tabuľka 5.1). Koľajnice lab. modelu dokážeme zatažovať pomocou pneumatických piestov. Preto bolo potrebné nájsť takú sekvenciu spúšťania piestov, pri ktorej budú mať namerané signály podobný priebeh ako signály z reálnych dráh. Ukázali sme si, ako tieto reálne signály vyzerajú, a čo na nich môžeme pozorovať. Použitím troch susedných piestov, ktoré naraz zatlačili na koľajnicu, sme dosiahli najlepších výsledkov. Pri tomto spôsobe zataženia sa nameraný napäťový zákmit senzoru najviac podobal napäťovému zákmitu, ktorý bol spôsobený prejazdom jedného kolesa reálneho vlaku. v signáloch boli však stále značné rozdiely ktoré sa nám nepodarilo eliminovať. Reálne signály obsahovali plynulý nárast napätia, ktorý bol spôsobený postupným približovaním kolesa k miestu merania. V simulovaných signáloch tento plynulý nárast chýbal, čo bolo spôsobené tým, že piesty zatažovali koľajnicu na diskretných miestach. Zároveň bola šírka zákmitu pri simulácii približne 2-násobne dlhšia ako v reálnych meraniach. Pri simulácii by sme potrebovali dobu, počas ktorej piesty tlačili na koľajnicu, skrátiť. No narazili sme na časový limit otvorenia ventilov, ktorého prekročením piesty nezatažili koľajnicu. Aby sme simulované signály ešte viac priblížili realite, bolo by potrebné upraviť zatažovací mechanizmus laboratórneho modelu. Najlepšiu záťažnú sekvenciu sme následne využívali na simuláciu prejazdu jedného kolesa vlaku, pri zmene parametrov.

V poslednej kapitole sme hľadali spôsob, ako v nameraných signáloch detekovať tieto zmeny parametrov. Prvé sme analyzovali, ako sa menila veľkosť deformácie koľajnice pri zmene tuhosti jednotlivých parametrov. Zvyšovaním tuhosti lôžka sa hodnota maximálnej deformácie znižovala. Na základe tejto hodnoty sme teda dokázali detekovať zmenu tuhosti lôžka. Použitím tohto prístupu však vzniklo hneď niekoľko problémov. V lab. modeli sme všetky prejazdy simulovali použitím rovnakej záťaže (piesty zatažovali koľajnicu vždy rovnakou veľkosťou sily). Ale v meraniach na reálnych železniciach veľkosť sily nebude vždy rovnaká, pretože vlaky môžu mať rozdielne hmotnosti. Takže by sme potrebovali aj informáciu o hmotnostiach jednotlivých vagónov. S použitím iba hodnoty maximálnej deformácie, by sme zároveň nedokázali rozlíšiť medzi zmenou tuhosti lôžka a zmenou tuhosti koľajnicovej podložky.

Ako ďalšie sme pre každý signál vypočítali hodnoty 2 črt v časovej doméne. Tieto črty boli efektívna hodnota signálu (RMS) a rozdiel medzi maximom a minimom signálu (P2P). Pre všetky namerané signály boli vypočítané tieto 2 hodnoty, takže sme obdržali dataset o rozmeroch 792x2 (792 meraní). Dataset obsahoval merania pri všetkých kombináciách nastavení parametrov lab. modelu (tab. 6.1). Na tomto datasete sme natrénovali SVM model ktorý na testovacej množine dosahoval presnosť 92%. Takže pomocou hodnôt RMS a P2P sa nám podarilo správne detekovať zmenu tuhosti lôžka a koľajnicovej podložky lab. modelu. Ich hodnoty však boli závislé na amplitúde signálu a preto boli pri náhodnej zmene amplitúd nepoužiteľné. Ďalej sme použili tzv. bezrozmerné črty signálov v časovej doméne, ktorých výhodou je že, nie sú závislé na amplitúde signálu, ale iba jeho tvare. Pomocou nich dokázal model správne určiť parametre lab. modelu s presnosťou 92,4%. No použitie týchto črt pri klasifikácii reálnych dát by bolo náročné.

Ďalej sme analyzovali namerané signály v časovo-frekvenčnej doméne, kde sme zistili, že pri zmene parametrov lab. modelu sa menilo rozmiestnenie energie signálov medzi frekvenciami 0 až 150 Hz. Na základe tohoto zistenia sme pomocou koeficientov z wavelet scattering transformácie (WST) vytvorili črty, určené na tréning SVM. Tieto črty niesli informáciu o relatívnej energii signálov v rôznych frekvenčných pásmach. Hodnoty relatívnej energie sme získali normalizáciou na základe celkovej energie signálu. Týmto sme docielili, že hodnoty črt neboli závislé na amplitúde signálov, ale iba na ich tvare. Identifikovali sme 4 najvhodnejšie WST črty pomocou ktorých dosahoval SVM model na testovacej množine presnosť 98,2%. Podarilo sa nám teda zvoliť vhodný prístup, ktorý nám umožnil detekciu zmien nastavených parametrov lab. modelu.

Ako posledné sme tento prístup použili na realistickejších meraniach, kde sme pomocou lab. modelu simulovali prejazd 4 vagónov. Predchádzajúci SVM model sme na klasifikáciu týchto nových signálov použiť nepodarilo, pretože nastala zmena v simulovanej odozve, a hodnoty WST črt boli oproti minulému datasetu mierne odlišné. Zmena mohla byť spôsobená buď tým, že sme simulovali prejazd viacerých kolies blízko pri sebe, čo zmenilo odozvu koľajnice, alebo chybou v pneumatickej časti lab. modelu. Posledné sme prístup aplikovali na signály z reálnych meraní. Tu sme si všimli, že hodnoty WST črt simulovaných a reálnych signálov boli odlišné. Tieto rozdiely mohli byť spôsobené tým, že sa nám pri simuláciách na lab. modeli nepodarilo vytvoriť signály ktoré mali rovnaký priebeh ako reálne. Ak by sme chceli aplikovať zistenia z lab. modelu na reálnych železničiach, bolo by potrebné model upraviť. Vhodné by bolo zmeniť záťažný mechanizmus, ktorý by realistickejšie simuloval zataženie dráhy a ktorý by zároveň umožňoval zmenu rýchlosti.

Ako ďalšie by bolo vhodné vykonávať dlhodobé merania na reálnych železničných dráhach. Tieto merania následne spracovať spomínaným prístupom a sledovať, ako sa budú meniť hodnoty WST črt vo väčších časových úsekoch, a aké budú rozdiely v týchto hodnotách pre rôzne vlaky.

Literatúra

- [1] Track Structure. In: *http://railsystem.net* [online]. [b.r.] [cit. 2022-5-18]. Dostupné z: <http://railsystem.net/track-structure/>
- [2] KÖLLÖ, Szabolcs a Attila PUSKAS, Gavril KÖLLÖ. *Comparison of ballasted and slab track* [online]. 2015 [cit. 2022-5-18]. Dostupné z: https://www.researchgate.net/publication/281613820_Ballasted_Track_versus_Ballastless_Track
- [3] FERREIRA, Patrícia. *Modelling and prediction of the dynamic behaviour of railway infrastructures at very high speeds*. Lisabon, 2010 [cit. 2022-5-18]. Dizertačná práca. Instituto Superior Técnico. Dostupné z: https://fenix.tecnico.ulisboa.pt/downloadFile/286156491070137/Tese_PhD_Patricia_Ferreira.pdf
- [4] NEJLAOUI, Mohamed, Ajmi HOUIDI, Zouhir AFFI, Lotfi ROMDHANE. *Dynamic Modeling of Rail Vehicle Traveling at High Speed*. 2013 [cit. 2022-5-18]. DOI: 10.1007/978-3-642-37143-1_27
- [5] ZHAI, Wanming. *Vehicle–Track Coupled Dynamics (Theory and Applications)*. 2020 [cit. 2022-5-18]. DOI: 10.1007/978-981-32-9283-3
- [6] GALLEGO, Inmaculada, Ana RIVAS, Santos CAMBRONERO, Julián CAMACHO. *Dynamic Modelling of High Speed Ballasted Railway Tracks: Analysis of the Behaviour*. 2016 [cit. 2022-5-18]. DOI: 10.1016/j.trpro.2016.12.058
- [7] NGUYEN, Khanh, José RUIGÓMEZ, Felipe CASTILLO. *Influence of rail track properties on vehicle–track responses*. 2015 [cit. 2022-5-18]. DOI: 10.1680/jtran.13.00090
- [8] GILANI Vahid, Mohammad HABIBZADEH, Seyed HOSSEINIAN, Reza SALEH-FARD. *A Review of Railway Track Laboratory Tests with Various Scales for Better Decision-Making about More Efficient Apparatus Using TOPSIS Analysis*. 2022-3-22 [cit. 2022-5-18]. Dostupné z: <https://www.hindawi.com/journals/ace/2022/9374808/>
- [9] BERGGREN, Eric. *Railway Track Stiffness Dynamic Measurements and Evaluation for Efficient Maintenance*. Borlänge, 2009 [cit. 2022-5-18]. Dizertačná práca. Royal Institute of Technology (KTH) Aeronautical and Vehicle Engineering, Stockholm. Dostupné z: <https://www.diva-portal.org/smash/get/diva2:216214/FULLTEXT01.pdf>
- [10] SYSYN, Mykola, Olga NABOCHENKO, Vitalii KOVALCHUK. *Experimental investigation of the dynamic behavior of railway track with sleeper voids*. 2020-8-27 [cit. 2022-5-18]. Dostupné z: <https://link.springer.com/article/10.1007/s40534-020-00217-8>
- [11] KIM, Hongsin. *TRACKSIDE MEASUREMENT OF CRITICAL ZONES IN RAILWAY TRACKS*. 2016 [cit. 2022-5-18]. Dizertačná práca. University of Birmingham. Dostupné z: <https://etheses.bham.ac.uk/id/eprint/6969/1/Kim16PhD.pdf>

- [12] BARKHORDARI, Pegah, R. GALEAZZI, A. TEJADA, I. SANTOS. *Identification of Behavioural Models for Railway Turnouts Monitoring*. 2019-10-19 [cit. 2022-5-18]. Dostupné z: <https://arxiv.org/pdf/1910.06582.pdf>
- [13] MIN, Yongzhi, B. XIAO, J. DANG, B. YUE, T. CHENG. *Real time detection system for rail surface defects based on machine vision*. 2018-1-11 [cit. 2022-5-18]. Dostupné z: <https://jivp-urasipjournals.springeropen.com/articles/10.1186/s13640-017-0241-y>
- [14] MOLODOVA, Maria, Z. LI, A. NÚÑEZ, R. DOLLEVOET. *Automatic Detection of Squats in Railway Infrastructure*. 2014 [cit. 2022-5-18]. DOI: 10.1109/TITS.2014.2307955
- [15] ALVARENGA, Tiago, A. CARVALHO, L. HONORIO, A. CERQUEIRA, L. FILHO, R. NOBREGA. *Detection and Classification System for Rail Surface Defects Based on Eddy Current*. 2021-11-28 [cit. 2022-5-18]. Dostupné z: https://mdpi-res.com/d_attachment/sensors/sensors-21-07937/article_deploy/sensors-21-07937-v2.pdf
- [16] SYSYN, Mykola, M. PRZYBYLOWICZ, O. NABOCHENKO, L. KOU. *Identification of Sleeper Support Conditions Using Mechanical Model Supported Data-Driven Approach*. 2021-5-22 [cit. 2022-5-18]. Dostupné z: <https://www.mdpi.com/1424-8220/21/11/3609>
- [17] FITZGERALD, Paul, A. MALEKJAFARIAN, D. CANTERO, E. OBRIEN, L. PRENDERGAST. *Drive-by scour monitoring of railway bridges using a wavelet-based approach*. 2019-7-15 [cit. 2022-5-18]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0141029618326208#b0070>
- [18] TAN, Lizhe. SIGNAL SAMPLING AND QUANTIZATION. In: *Digital Signal Processing: Fundamentals and Applications*. 2019 [cit. 2022-5-18]. doi:10.1016/B978-0-12-815071-9.00002-6
- [19] PeterSchaldenbrand. *Digital Signal Processing: Sampling Rates, Bandwidth, Spectral Lines, and more....*. In: SIEMENS Simcenter [online]. 2020-7-10 [cit. 2022-5-18]. Dostupné z: <https://community.sw.siemens.com/s/article/digital-signal-processing-sampling-rates-bandwidth-spectral-lines-and-more>
- [20] A/D Converter and D/A Converter. *rohm.com* [online]. [b.r.] [cit. 2022-5-18]. Dostupné z: <https://www.rohm.com/electronics-basics/ad-da-converters/what-are-ad-da-converters>
- [21] IBTEHAZ, Nabil, M. Saifur RAHMAN, M. Sohel RAHMAN. *VFPred: A Fusion of Signal Processing and MachineLearning techniques in Detecting Ventricular-Fibrillation from ECG Signals*. 2018-11-19 [cit. 2022-5-18]. Dostupné z: https://www.researchgate.net/publication/326290307_VFPred_A_Fusion_of_Signal_Processing_and_Machine_Learning_techniques_in_Detecting_Ventricular_Fibrillation_from_ECG_Signals
- [22] Preprocessing. In: *neurotechedu.com* [online]. [b.r.] [cit. 2022-5-18]. Dostupné z: <http://learn.neurotechedu.com/preprocessing/>

- [23] ISUKAPALLI, Yogananda. *Introduction to Digital Filters* [online prezentacia]. [b.r.] [cit. 2022-5-18]. Dostupné z: https://web.ece.ucsb.edu/~yoga/courses/DSP/P9_Intro_Digital_Filters.pdf
- [24] SMITH, Julius. *INTRODUCTION TO DIGITAL FILTERS* [online]. 2021-11-22 [cit. 2022-5-18]. Dostupné z: <https://ccrma.stanford.edu/~jos/filters/>
- [25] WANG, Xiang, Y. ZHENG, Z. ZHAO, J. WANG. *Bearing Fault Diagnosis Based on Statistical Locally Linear Embedding*. 2015 [cit. 2022-5-18]. Dostupné z: https://www.researchgate.net/publication/279991612_Bearing_Fault_Diagnosis_Based_on_Statistical_Locally_Linear_Embedding
- [26] CHEN, Junjun, B. XU, X. ZHANG. *A Vibration Feature Extraction Method Based on Time-Domain Dimensional Parameters and Mahalanobis Distance*. 2021-7-17 [cit. 2022-5-18]. Dostupné z: <https://www.hindawi.com/journals/mpe/2021/2498178/>
- [27] NAZMI, Nurhazimah, M. RAHMAN, S. YAMAMOTO, S. AHMAD, H. ZAMZURI, S. MAZLAN. *A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions*. 2016 [cit. 2022-5-18]. Dostupné z: https://www.researchgate.net/publication/306269759_A_Review_of_Classification_Techniques_of_EMG_Signals_during_Isotonic_and_Isometric_Contractions
- [28] TKACH, Dennis, H. HUANG, T. KUIKEN. <https://jneuroengrehab.biomedcentral.com/articles/10.1186/1743-0003-7-21>. 2010-5-21 [cit. 2022-5-18]. Dostupné z: <https://jneuroengrehab.biomedcentral.com/articles/10.1186/1743-0003-7-21>
- [29] PANDIYAN, Vigneashwara, R. DAOUDI, S. SHEVCHIK, G. MASINELLI, R. LOGÉ, K. WASMER. *Analysis of time, frequency and time-frequency domain features from acoustic emissions during Laser Powder-Bed fusion process*. 2020 [cit. 2022-5-18]. Dostupné z: https://www.dora.lib4ri.ch/empa/islandora/object/empa%3A23453/datastream/PDF/Pandiyan-2020-Analysis_of_time%2C_frequency_and-%28published_version%29.pdf
- [30] KAPLAN, Ian. *DFT of a non-stationary time series*. 2001 [cit. 2022-5-18]. Dostupné z: http://bearcave.com/misl/misl_tech/signal/nonstat/index.html
- [31] MCFEE, Brian. *The Short-time Fourier Transform (STFT)*. 2020 [cit. 2022-5-18]. Dostupné z: <https://brianmcfree.net/dstbook-site/content/ch08-stft/STFT.html>
- [32] spectrogram, Signal Processing Toolbox, Matlab. *The MathWorks, Inc.* 2022. Dostupné z: <https://www.mathworks.com/help/signal/ref/spectrogram.html>
- [33] danielle.patoner, tommaso.mastropasqua. *Time-frequency analysis*. 2020-12-10 [cit. 2022-5-18]. Dostupné z: <https://wiki.cimec.unitn.it/tiki-index.php?page=Time-frequency+analysis>
- [34] HEINZEL, Gerhard, A. RUDIGER, R. SCHILLING. *Spectrum and spectral density estimation by the Discrete Fourier transform (DFT), including a comprehensive list of window functions and some new flat-top windows*. 2002 [cit. 2022-5-18]. Dostupné

- z: https://www.researchgate.net/publication/267956210_Spectrum_and_spectral_density_estimation_by_the_Discrete_Fourier_transform_DFT_including_a_comprehensive_list_of_window_functions_and_some_new_flat-top_windows
- [35] Gabriel Galeote-Checa. In: *dsp.stackexchange.com*. 2020-4-8 [cit. 2022-5-18]. Dostupné z: <https://dsp.stackexchange.com/questions/66166/determine-the-haar-wavelet-function-is-linear-or-nonlinear>
- [36] ADDISON, S. Paul. *The Illustrated Wavelet Transform Handbook*. 2nd ed. Boca Raton, FL: CRC Press, Taylor & Francis Group, 2017. ISBN 978-1-4822-5132-6
- [37] POLIKAR, Robi. *THE WAVELET TUTORIAL PART I*. 1996-6-5 [cit. 2022-5-18]. Dostupné z: <https://ccrma.stanford.edu/%7Eunjung/mylec/WTpart1.html>
- [38] COHEN, X Mike. *Morlet wavelets in time and in frequency*. In: *YouTube* [online]. 2019-12-20 [cit. 2022-5-18]. Dostupné z: <https://www.youtube.com/watch?v=7ahrcB5HL0k&list=PLn00Liympak2BYu--bROADNBJS4kuRWs>
- [39] Time-Frequency Analysis and Continuous Wavelet Transform, Matlab. *The MathWorks, Inc.* 2022. Dostupné z: <https://www.mathworks.com/help/wavelet/ug/time-frequency-analysis-and-continuous-wavelet-transform.html>
- [40] KHUSHABA, Rami. *Wavelets-based Feature Extraction*. In: *YouTube* [online]. 2021-12-10 [cit. 2022-5-18]. Dostupné z: <https://www.youtube.com/watch?v=JyonDStpISY>
- [41] SORO, Bedionita, Chaewoo LEE. *A Wavelet Scattering Feature Extraction Approach for Deep Neural Network Based Indoor Fingerprinting Localization*. 2019-4-14 [cit. 2022-5-18]. Dostupné z: https://mdpi-res.com/d_attachment/sensors/sensors-19-01790/article_deploy/sensors-19-01790.pdf?version=1555243035
- [42] Wavelet Scattering, Matlab. *The MathWorks, Inc.* 2022. Dostupné z: <https://www.mathworks.com/help/wavelet/ug/wavelet-scattering.html>
- [43] Machine Learning. *IBM Cloud Education*. 2020-7-15 [cit. 2022-5-18]. Dostupné z: <https://www.ibm.com/cloud/learn/machine-learning>
- [44] GANDHI, Rohith. *Support Vector Machine — Introduction to Machine Learning Algorithms*. 2018-6-7 [cit. 2022-5-18]. Dostupné z: <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>
- [45] StatQuest with Josh Starmer. *Support Vector Machines*. In: *YouTube* [online]. 2019-9-30 [cit. 2022-5-18]. Dostupné z: <https://www.youtube.com/watch?v=efR1C6CvhmE&list=PLblh5JK0oLUL3IJ4-yorOHzkqDQ3JmJkc>
- [46] BROWNLEE, Jason. *How to Choose a Feature Selection Method For Machine Learning*. 2020-8-20 [cit. 2022-5-18]. Dostupné z: <https://machinelearningmastery.com/feature-selection-with-real-and-categorical-data/>

- [47] RADOVIC, Milos, M. GHALWASH, N, FILIPOVIC, Z. OBRADOVIC. *Minimum redundancy maximum relevance feature selection approach for temporal gene expression data*. 2017-1-3 [cit. 2022-5-18]. Dostupné z: <https://bmcbioinformatics.biomedcentral.com/articles/10.1186/s12859-016-1423-9>
- [48] DING, Chris, Hanchuan PENG. *MINIMUM REDUNDANCY FEATURE SELECTION FROM MICROARRAY GENE EXPRESSION DATA*. 2004-6-16 [cit. 2022-5-18]. Dostupné z: <https://www.worldscientific.com/doi/epdf/10.1142/S0219720005001004>
- [49] SIROHI, Jayant, Inderjit CHOPRA. *Fundamental Understanding of Piezoelectric Strain Sensors*. 2000 [cit. 2022-5-18]. Dostupné z: https://sites.utexas.edu/sirohi/files/2017/07/002_sirohi00_jimss.pdf
- [50] BUDYNAS, G. Richard, J. Keith NISBETT. *Shigley's Mechanical Engineering Design*. 9th ed. New York, McGraw-Hill, 2011. ISBN 978-0-07-352928-8
- [51] The Mathworks, Inc. *Matlab R2021b* [software]. Dostupné z: <https://www.mathworks.com/>
- [52] Boundary Effects and the Cone of Influence, Matlab. *The MathWorks, Inc.* 2022. Dostupné z: <https://www.mathworks.com/help/wavelet/ug/boundary-effects-and-the-cone-of-influence.html>

Zoznam obrázkov

2.1	Železničná dráha so štrkovým lôžkom [1]	4
2.2	Vertikálny model vlaku a železničnej dráhy [5]	5
2.3	Zmenšený model železničnej dráhy s 3 podvalmi [8]	6
2.4	Vzorkovanie spojitého signálu	9
2.5	Frekvenčná odozva rôznych typov filtrov	10
2.6	FFT transformácia signálu zloženého z 3 sinusoíd o 3 frekvenciách	11
2.7	STFT chirp signálu [32]	12
2.8	Rôzne wavelet funkcie [35]	13
2.9	Porovnanie STFT a wavelet transformácie hyperbolického chirp signálu [39]	14
2.10	Strom wavelet scattering transformácie [42]	14
2.11	SVM - nájdenie hranice medzi 2 triedami	15
2.12	Rozšírenie vstupu do vyššej dimenzie pomocou kernel funkcie	16
2.13	Confusion matrix pre dáta s 8 triedami	16
4.1	CAD model laboratórneho prípravku	19
4.2	Rozmery prierezu koľajnice	19
4.3	Detail pružného spojenia koľajníc a podvalu	20
4.4	Detail pružného spojenia podvalu a rámu	20
4.5	Zjednodušený model popisujúci laboratórny prípravok	21
4.6	Pozície piezo-elektrických senzorov na koľajnici	21
4.7	Schéma nosníku, votknutého na oboch koncoch	22
4.8	Priebeh ohybového momentu M_y v závislosti na polohe x	23
5.1	Získaný signál z reálnej železničnej dráhy (prejazd nákladného vlaku)	25
5.2	Detail nameraného signálu (prejazd 1 nápravy vlaku) a prepočet na deformáciu	25
5.3	Simulácia prejazdu jedného kolesa (1 piest)	26
5.4	Simulácia prejazdu jedného kolesa (postupná vlna)	27
5.5	Simulácia prejazdu jedného kolesa (3 piesty)	27
5.6	Porovnanie simulovaných a reálnych signálov (prejazd 1 kolesa)	28
5.7	Závislosť tuhosti nosníka na jeho dĺžke	29
5.8	Porovnanie simulovaných a reálnych signálov (prejazd 4 vagónov)	30
6.1	Priebeh pomernej deformácie pri simulácii prejazdu jedného kolesa	32
6.2	Hodnoty maximálnej deformácie v závislosti na tuhosti lôžka k_L ($k_P = 62 \text{ N/mm}$)	32
6.3	Hodnoty maximálnej deformácie v závislosti na tuhosti lôžka k_L ($k_P = 31 \text{ N/mm}$)	33
6.4	RMS a P2P hodnoty nameraných signálov	33
6.5	Confusion matrix modelu s kubickým kernelom (črty RMS, P2P)	34
6.6	RMS a P2P hodnoty nameraných signálov (náhodná zmena amplitúd)	35
6.7	Confusion matrix modelu s kubickým kernelom (črty skew, kurt)	36
6.8	Ohodnotenie bezrozmerných črt pomocou mRMR algoritmu	36
6.9	Namerané signály pri 3 rôznych tuhostiach k_L a ich CWT	37
6.10	Energia signálov v závislosti na frekvencii	38
6.11	Korelačná matica pre 5 signálov	38
6.12	Energia signálov v závislosti na frekvencii (odstránené odľahlé signály)	39
6.13	Energia signálov v závislosti na frekvencii (náhodná zmena amplitúd)	39

6.14	Frekvenčná odozva použitého filtra	40
6.15	WST signálu simulovaného prejazdu jedného kolesa	41
6.16	Prvých 9 wavelet scattering filtrov	42
6.17	Hodnoty WST črt pre rôzne kombinácie k_L a k_P	42
6.18	Ohodnotenie WST črt pomocou mRMR algoritmu	43
6.19	Confusion matrix modelu s kubickým kernelom (WST črty 1,4,5,6)	44
6.20	Nameraný signál pri simulácii prejazdu 4 vagónov	45
6.21	Umelo vytvorený signál dvoch zákmitov a jeho hodnoty WST črt	45
6.22	WST signálu simulovaného prejazdu 4 vagónov	46
6.23	Confusion matrix predchádzajúceho modelu na novom datasete (4 vagónov)	46
6.24	Porovnanie WST črt signálov zo simulácií prejazdu jedného kolesa a 4 vagónov	47
6.25	Confusion matrix nového modelu (výpočet WST črt z celého signálu) . . .	48
6.26	Meranie na reálnej železničnej dráhe (vlak RAILJET)	48
6.27	Hodnoty WST črt vypočítaných pre každú nápravu vlaku RAILJET . . .	49
6.28	Detail signálu (2 nápravy)	49
6.29	Porovnanie WST črt simulovaných prejazdov a reálnych meraní	50

Zoznam použitých skratiek a symbolov

f_s	[Hz] Vzorkovacia frekvencia
DFT	Diskrétna Fourierova transformácia
FFT	Rýchla Fourierova transformácia
STFT	Krátkodobá Fourierova transformácia
SVM	Support vector machines
mRMR	Minimum Redundancy Maximum Relevance algoritmus
CAD	Computer aided design
k_L	[N/mm] Tuhosť lôžka laboratórneho modelu
k_P	[N/mm] Tuhosť koľajnicovej podložky laboratórneho modelu
CWT	Kontinuálna wavelet transformácia
RMS	Efektívna hodnota signálu
P2P	Rozdiel medzi maximálnou a minimálnou hodnotou signálu
CM	Confusion matrix
WST	Wavelet scattering transformácia