

Univerza
v Ljubljani

Fakulteta za
*gradbeništvo in
geodezijo*



PODIPLOMSKI ŠTUDIJ
GRADBENIŠTVA

DOKTORSKI ŠTUDIJ

Kandidatka:

NATAŠA ZAVRTANIK, univ. dipl. inž. grad.

**MODELIRANJE OBNAŠANJA ASFALTNIH ZMESI PRI
VIŠJIH TEMPERATURAH**

Doktorska disertacija štev.: 246

**MODELING OF ASPHALT MIXTURE BEHAVIOUR AT
HIGH TEMPERATURES**

Doctoral thesis No.: 246

Soglasje k temi doktorske disertacije je dala Komisija za doktorski študij UL
na 20. redni seji, dne 21. septembra 2011.

Za mentorja je bil imenovan prof. dr. Goran Turk, za somentorja pa doc. dr. Marjan
Tušar, Kemijski inštitut, Ljubljana.

Ljubljana, 9. junij 2015

Univerza
v Ljubljani

Fakulteta za
*gradbeništvo in
geodezijo*



Komisijo za oceno ustreznosti teme doktorske disertacije v sestavi:

- prof. dr. Goran Turk,
- doc. dr. Marjan Tušar, Kemijski inštitut, Ljubljana,
- prof. dr. Janez Žmavc,
- doc. dr. Gregor Trtnik, IGMAT, Ljubljana,

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 21. redni seji, dne 25. maja 2011.

Poročevalce za oceno doktorske disertacije v sestavi:

- doc. dr. Gregor Trtnik, IGMAT, Ljubljana,
- prof. dr. Dejan Zupan,
- izr. prof. dr. Marijan Žura,

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 15. redni seji, dne 10. decembra 2014.

Komisijo za zagovor doktorske disertacije v sestavi:

- prof. dr. Matjaž Mikoš, dekan UL FGG, predsednik,
- prof. dr. Goran Turk, mentor,
- doc. dr. Marjan Tušar, Kemijski inštitut, Ljubljana, somentor
- doc. dr. Gregor Trtnik, IGMAT, Ljubljana,
- prof. dr. Dejan Zupan,
- izr. prof. dr. Marijan Žura,

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 20. redni seji, dne 27. maja 2015.

POPRAVKI

Stran z napako

Vrstica z napako

Namesto

Naj bo

IZJAVE

Podpisana Nataša Zavrtanik izjavljam, da sem avtorica doktorske disertacije z naslovom "Modeliranje obnašanja asfaltnih zmesi pri višjih temperaturah".

Izjavljam, da je elektronska različica v vsem enaka tiskani različici.

Izjavljam, da dovoljujem objavo elektronske različice v repozitoriju UL FGG.

Ljubljana, 1. junij 2015

Nataša Zavrtanik

BIBLIOGRAFSKO-DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK 625.85:678.049:519.711:(043.3)
Avtor: Nataša Zavrtanik
Mentor: prof. dr. Goran Turk
Somentor: doc. dr. Marjan Tušar
Naslov: Modeliranje obnašanja asfaltnih zmesi pri višjih temperaturah
Tip dokumenta: Doktorska disertacija
Obseg in oprema: 117 str., 54 sl., 59 pregl., 80 en., 1 pril.
Ključne besede: asfaltna zmes, triosni test, umetna nevronska mreža, grobi model, bitumen, strižni odbojni koeficient, ultrazvok

Izvleček

V doktorski disertaciji se ukvarjamo z različnimi analizami in modeliranjem asfaltnih zmesi. Naloga je vsebinsko sestavljena iz štirih delov. V prvem delu pripravimo bazo podatkov, ki predstavljajo posamezne meritve bitumenskega veziva, agregata in asfaltne zmesi. Te podatke analiziramo s statističnimi metodami, s katerimi ugotovimo, ali so vplivi faktorjev in njihovih interakcij statistično značilni. Poleg tega z umetnimi nevronskimi mrežami modeliramo zveze med različnimi parametri in deležem votlin v asfaltni zmesi in deležem votlin v zmesi kamnitega materiala. V drugem delu naloge so bili za ugotavljanje odpornosti asfaltnih vzorcev proti nastanku trajnih deformacij pri visokih temperaturah izvedeni ciklični triosni preizkusi in klasični preizkusi nastajanja kolesnic. Za uporabo pri različnih modelih so bile izvedene tudi klasične analize asfaltnih zmesi. Testi so narejeni za štiri glavne asfaltne zmesi z namenom, da bi dobili grobi model obnašanja asfaltnih zmesi, ki vsebujejo največ in najmanj zračnih votlin. Predstavljeni so različni linearni modeli, njihova validacija in preizkus razširitve na druge asfaltne zmesi. Tretji del obravnava modeliranje trajne deformacije, dobljene iz triosnega testa, z različnimi umetnimi nevronskimi mrežami. V zadnjem delu pa je prikazana možnost uporabe nedestruktivne metode odboja strižnih ultrazvočnih valov, ki na področju bitumnov še ni bila uporabljena. Za ovrednotenje te preiskave so bili testirani trije cestogradbeni bitumni in dva s polimeri modificirana bitumna. Razlike v razvoju strižnega odbojnega koeficienta s temperaturo za različne tipe bitumnov kažejo na občutljivost strižnega odbojnega koeficienta na sestavo bitumna in s tem primernost ultrazvočne metode za ugotavljanje utrjevanja različnih tipov bitumnov.

BIBLIOGRAPHIC-DOCUMENTALISTIC INFORMATION AND ABSTRACT

UDC 625.85:678.049:519.711:(043.3)
Author: Nataša Zavrtanik
Supervisor: prof. Goran Turk, Ph.D.
Co-supervisor: assist. prof. Marjan Tušar, Ph.D.
Title: Modeling the behavior of asphalt mixtures at higher temperatures
Document type: Doctoral Dissertation
Notes: 117 p., 54 fig., 59 tab., 80 eq., 1 ann.
Keywords: asphalt mixture, triaxial test, artificial neural network, rough model, bitumen, shear reflection coefficient, ultrasound

Abstract

In this thesis various analyses and modeling of asphalt mixtures are represented. It is composed of four main parts. In the first part we build up the database of individual measurements of bituminous binder, aggregate and asphalt mixtures. These data are analyzed using statistical methods which determine whether the effects of factors and their interactions are statistically significant. In addition we have used artificial neural networks for modeling relationship between different parameters and air voids content in asphalt mixtures and voids content in a mixture of aggregate. In the second part of the study cyclic triaxial tests and wheel tracking tests were performed to determine the resistance of asphalt mixtures to permanent deformation at high temperatures. Furthermore other conventional analyses of asphalt mixtures were performed to use them in different models. Experiments were done for all principal asphalt mixtures to obtain an extensive model of asphalt behaviour for mixtures which contain the most and the least air voids. Various linear models, their validation and extensions to other asphalt mixtures are featured. The third part deals with the use of different artificial neural networks for modeling permanent deformation from triaxial tests. The last part presents the use of ultrasonic shear wave reflection (USWR) method on bituminous binder. For the evaluation of this method three paving grade bitumens and two polymer modified bitumens were tested. Differences in the evolution of shear wave reflection coefficient with temperature in the case of different bitumen types indicate that the presented ultrasonic wave reflection method could represent an advanced non-destructive technique for monitoring the hardening process of different types of bitumen.

ZAHVALA

Iskrena hvala mentorju prof.dr. Goranu Turku, ki mi je pri študiju in nastanku doktorske disertacije vseskozi pomagal in svetoval. Hvala za vzpodbudo in prijateljstvo v trenutkih, ko ni šlo vse po načrtih.

Hvala somentorju doc.dr. Marjanu Tušarju za vso strokovno pomoč in nasvete pri izdelavi doktorske disertacije.

Operacijo delno financira Evropska unija iz Evropskega socialnega sklada. Za kar se jim iskreno zahvaljujem.

Za nasvete se zahvaljujem tudi dr. Carstenu Karcherju iz Univerze Karlsruhe (TH).

Hvala Javni agenciji za tehnološki razvoj Republike Slovenije za dodeljeno štipendijo in podjetju IGMAT d.d. za sodelovanje in pomoč pri nastajanju doktorske disertacije.

Zahvaljujem se mag. Franciju Kavčiču z Inštituta za gradbene materiale IGMAT d.d., ki me je podpiral ter mi omogočil raziskovalno delo na inštitutu v času študija. Za vso podporo se zahvaljujem tudi direktorju inštituta IGMAT d.d. Janezu Prosenu. Iskrena hvala Romanu Bašlju za pomoč pri raziskovalnem delu, Aleksandru Ljubiču ter vsem sodelavcem z inštituta IGMAT d.d. za sodelovanje in prijetno počutje v času raziskovalnega dela.

Hvala podjetjem CPG d.d., CPK d.d. in TAP d.o.o., ki so za potrebe eksperimentalnih preiskav odstopili vzorce asfaltnih zmesi.

Iskrena hvala vsem sodelavcem na Katedri za mehaniko Fakultete za Gradbeništvo in geodezijo Univerze v Ljubljani, ki so mi kakorkoli pomagali in naredili trenutke na faksu nepozabne.

Iskrena hvala staršem za razumevanje in podporo.

Val in Jure, hvala za vso vajino podporo, razumevanje in pomoč pri nastajanju doktorske disertacije.

Izak, hvala!

KAZALO VSEBINE

BIBLIOGRAFSKO-DOKUMENTACIJSKA STRAN IN IZVLEČEK	VII
BIBLIOGRAPHIC-DOCUMENTALISTIC INFORMATION AND ABSTRACT	VIII
ZAHVALA	IX
1 UVOD	1
1.1 Splošno	1
1.2 Vsebina in struktura doktorske disertacije	2
1.3 Pomen okrajšav	3
2 UPORABLJENE STATISTIČNE IN MATEMATIČNE METODE	4
2.1 Preizkušanje linearne povezanosti	4
2.2 Analiza variance (ANOVA)	5
2.2.1 Analiza variance za eno neodvisno spremenljivko	5
2.2.2 Analiza variance za več neodvisnimi spremenljivkami	6
2.3 Linearna regresija za več spremenljivk	8
2.4 Metoda glavnih komponent (PCA)	9
2.5 Umetne nevronske mreže	10
2.5.1 Razdelitev umetnih nevronskih mrež	14
2.5.2 Večnivojska usmerjena umetna nevronska mreža	17
2.5.3 Pravilo delta	17
2.5.4 Posplošeno pravilo delta	18
3 PRIPRAVA BAZE PODATKOV IN STATISTIČNA ANALIZA	22
3.1 Spremenjene statistične lastnosti asfaltnih mešanic	22
3.1.1 Obravnavani podatki	23
3.1.1.1 Seznam lastnosti asfaltnih zmesi, uporabljenih pri statistični analizi	24
3.1.2 Statistična analiza obravnavanih podatkov	26
3.1.3 Rezultati	27
3.2 Uporaba umetnih nevronskih mrež za oceno deleža votlin v asfaltni zmesi in deleža votlin v zmesi kamnitega materiala	33
3.2.1 Opis parametrov, ki vplivajo na učenje umetnih nevronskih mrež	33
3.2.2 Statistični kazalci uspešnosti nevronske mreže	34
3.2.3 Program NTR2003	34
3.2.4 Orodje WEKA Toolkit	35

3.2.5	Podatki	36
3.2.5.1	Zračne votline v asfaltni zmesi	36
3.2.5.2	Votline v zmesi kamnitega materiala	37
3.2.6	Rezultati	38
3.2.6.1	Zračne votline v asfaltni zmesi	38
3.2.6.2	Votline v zmesi kamnitega materiala	41
3.3	Sklep	47
4	RAZVOJ GROBEGA MODELA OBNAŠANJA ASFALTNIH ZMESI PRI VIŠJI TEMPERATURI	48
4.1	Materiali	50
4.1.1	Bitumen	50
4.1.2	Agregat	50
4.1.3	Asfaltne zmesi	51
4.2	Eksperimenti	52
4.2.1	Triosni eksperiment	52
4.2.1.1	Rezultati	56
4.2.1.2	Ponovljivost rezultatov triosnega preizkusa	56
4.2.2	Preizkus nastajanja kolesnic (WTT - Wheel tracking test)	57
4.2.2.1	Rezultati	58
4.2.3	Preizkus po Marshallu	59
4.2.4	Primerjava treh mehanskih testov asfaltnih zmesi	61
4.3	Modeliranje	62
4.3.1	Validacija modela	69
4.3.1.1	Material v validacijskih zmesih	69
4.3.1.2	Rezultati eksperimentov na validacijskih zmesih	70
4.3.1.3	Rezultati validacije	72
4.3.2	Razširitev modela	75
4.3.2.1	Material v zmesih za razširitev modelov	75
4.3.2.2	Rezultati eksperimentov na zmesih za razširitev modelov	77
4.3.2.3	Rezultati razširitve modelov	79
4.3.3	Modeli z upoštevanjem zmesi MA PmB in njihova validacija	82
4.4	Sklep	83
5	UPORABA UMETNIH NEVRONSKIH MREŽ ZA OCENO TRAJNE DEFORMACIJE ASFALTNE ZMESI	85
5.1	Podatki	85

5.2	Rezultati	87
5.3	Sklep	89
6	UPORABA ULTRAZVOČNE METODE NA BITUMENSKEM VEZIVU	91
6.1	Material	92
6.1.1	Bitumen	92
6.2	Metoda odboja strižnih ultrazvočnih valov	92
6.2.1	Splošno o metodi	92
6.2.2	Merilni inštrument USWR	96
6.3	Priprava vzorcev in procedura eksperimenta	98
6.4	Rezultati	99
6.4.1	Hlajenje bitumenskih vzorcev	99
6.4.2	Vpliv vrste bitumna na razmerje $\Delta r - T$	101
6.4.3	Ponovljivost in zanesljivost USWR metode na bitumenskih vzorcih	101
6.5	Sklep	103
7	ZAKLJUČKI	104
8	POVZETEK	107
9	SUMMARY	109
	VIRI	111
	SEZNAM PRILOG	117

KAZALO SLIK:

Slika 1:	Glavne komponente v dvodimenzionalnem prostoru.	9
Slika 2:	Shema delovanja umetne nevronske mreže.	10
Slika 3:	Pragovna oz. stopničasta funkcija.	12
Slika 4:	Eksponentna sigmoidna funkcija.	13
Slika 5:	Tangentna sigmoidna funkcija.	13
Slika 6:	Linearna funkcija.	14
Slika 7:	Shema enonivojske usmerjene nevronske mreže.	15
Slika 8:	Shema večnivojske usmerjene nevronske mreže.	15
Slika 9:	Shema večnivojske nevronske mreže s povezavami nazaj.	16
Slika 10:	Simbolični 3D prikaz ploskve napake pri večnivojskih usmerjenih nevronskih mrežah.	21
Slika 11:	a) Raztros med S in PK za asfaltno zmes AC 22 v časovnem obdobju 2006 - 2009, če gledamo le odnos S in PK, b) Raztros med S in vsebnostjo zračnih votlin za asfaltno zmes AC 22 v časovnem obdobju 2006 - 2009, če gledamo le odnos med S in vsebnostjo zračnih votlin.	23
Slika 12:	Frekvenčni histogram razlik korelacijskih koeficientov med deležem bitumna in stabilnostjo po 10000 simulacijah, ob predpostavki, da je razlika korelacijskega koeficienta enaka 0.	31
Slika 13:	Določitev osamelca med podatki.	36
Slika 14:	Dejanske vrednosti in z linearnim modelom izračunane vrednosti deleža votlin v asfaltni zmesi AC 22.	39
Slika 15:	Dejanske vrednosti in z linearnim modelom izračunane vrednosti deleža votlin v asfaltni zmesi AC 22.	40
Slika 16:	Dejanske vrednosti in z nevronske mreže ann 1 izračunane vrednosti deleža votlin v zmesi kamnitega materiala.	46
Slika 17:	Sejalne krivulje.	51
Slika 18:	Shematski prikaz haversinusoidne ciklične obtežbe vzorca.	53
Slika 19:	Shematski prikaz triosnega preizkusa (SIST EN 12697 - 25).	54
Slika 20:	a) Pripravljena vzorca za triosni preizkus, b) triosna celica ter c) temperaturna komora in računalnik, preko katerega se vodi preizkus.	54
Slika 21:	Primer krivulje tečenja.	55
Slika 22:	Deformacijske krivulje za različne asfaltne zmesi, dobljene s triosnim preizkusom.	56
Slika 23:	Naprava za ugotavljanje globine kolesnice.	58
Slika 24:	Deformacijske krivulje za različne asfaltne zmesi, dobljene s preizkusom ugotavljanja globine kolesnice (WTT).	59
Slika 25:	Naprava za izvajanje preizkusa po Marshallu.	60
Slika 26:	a) Prikaz definicije stabilnosti, tečenja in Marshallovega kvocienta, b) Tipičen rezultat Marshallovega testa za SMA asfaltno zmes.	60
Slika 27:	Trajna deformacija (ϵ_{10000}), dobljena iz triosnega preizkusa, za sedem asfaltnih zmesi.	62
Slika 28:	Proportionalna globina kolesnice za sedem asfaltnih zmesi.	62
Slika 29:	Linearna povezava proporcionalne globine kolesnice in trajne deformacije, dobljene s triosnim testom: a) model z zmesjo MA PmB; b) model brez zmesi MA PmB.	63
Slika 30:	Linearna povezava proporcionalne globine kolesnice in trajne deformacije, dobljene s triosnim testom brez zmesi PA, PA PmB, MA in MA PmB.	63
Slika 31:	Korelacija med stopnjo lezenja f_c pri triosnem testu in hitrostjo naraščanja deformacije (wts) v WTT.	64

Slika 32:	Grafični prikaz osnovne strukture in principa obnašanja asfaltnih zmesi (Partl, Chailleux, 2013).	66
Slika 33:	Prikaz vrste asfaltnih zmesi po metodi glavnih komponent (PCA) (diagram asfaltnih zmesi).	66
Slika 34:	Prikaz lastnosti asfaltnih zmesi po metodi glavnih komponent (PCA) v koordinatnem sistemu Φ_1 in Φ_2 (diagram lastnosti).	67
Slika 35:	Prikaz lastnosti asfaltnih zmesi po metodi glavnih komponent (PCA) v koordinatnem sistemu Φ_1 in Φ_3 (diagram lastnosti).	68
Slika 36:	Sejalna krivulja asfaltne zmesi SMA LN.	70
Slika 37:	Deformacijski krivulji za validacijski asfaltni zmesi SMA 11, B20/30 LN in SMA 11 PmB10/40-65 LN, dobljeni s triosnim testom.	71
Slika 38:	Deformacijski krivulji za validacijski asfaltni zmesi SMA 11 B20/30 LN in SMA 11 PmB10/40-65 LN, dobljeni s preizkusom ugotavljanja globine kolesnice (WTT).	72
Slika 39:	Linearna povezava proporcionalne globine kolesnice in trajne deformacije, dobljene s triosnim testom za asfaltne zmesi, ki so bile vključene v modeliranje, in dve validacijski asfaltni zmesi.	73
Slika 40:	Grafični prikaz dejanske in z modelom 6 izračunane vrednosti proporcionalne globine kolesnice.	75
Slika 41:	Sejalne krivulje asfaltnih zmesi za razširitev grobega modela.	76
Slika 42:	Deformacijske krivulje, dobljene s triosnim preizkusom za asfaltne zmesi, ki smo jih uporabili pri razširitvi modelov.	78
Slika 43:	Deformacijske krivulje, dobljene s preizkusom ugotavljanja globine kolesnice za asfaltne zmesi, ki smo jih uporabili pri razširitvi modelov.	79
Slika 44:	Določitev osamelca med podatki.	86
Slika 45:	Dejanske vrednosti in z nevronske mreže ann 1 izračunane vrednosti za ϵ_{1000} .	88
Slika 46:	Dejanske vrednosti in z linearnim modelom izračunane vrednosti za ϵ_{1000} .	89
Slika 47:	Shema vpadnega in odbojnega vala na stiku pomožni material - cementna pasta (Voigt, 2004).	95
Slika 48:	Shema delovanja USWR inštrumenta.	97
Slika 49:	Ultrazvočni aparat za spremljanje procesa strjevanja bitumna USWR-4.	98
Slika 50:	a) Kalup iz ekstrudiranega polistirena. b) Merilni senzor. c) Temperaturna komora.	99
Slika 51:	$T - t$ diagram za: a) cestogradbeni bitumen, b) s polimeri modificiran bitumen.	99
Slika 52:	Tipičen razvoj koeficienta Δr s temperaturo.	100
Slika 53:	$\Delta r - t$ diagram za: a) cestogradbeni bitumen, b) s polimeri modificiran bitumen.	101
Slika 54:	$\Delta r - T$ diagram za: a) cestogradbene bitumne, b) s polimeri modificiran bitumen.	101

KAZALO PREGLEDNIC:

Preglednica 1:	Preglednica ANOVA	6
Preglednica 2:	Preglednica ANOVA za dva faktorja.	7
Preglednica 3:	Korelacijski koeficienti nekaterih lastnosti asfaltne zmesi AC 22 iz obdobja 2006 - 2009.	24
Preglednica 4:	Dejanska tveganja pri hipotezi o enakosti srednjih vrednosti in varianc pri časovni delitvi podatkov.	28
Preglednica 5:	Korelacijski koeficienti za dve obdobji in njihove absolutne razlike.	29
Preglednica 6:	Meje kritičnega območja zavrnitve ničelne hipoteze za absolutne razlike korelacijskih koeficientov po 10000 simulacijah.	30
Preglednica 7:	Dejanska tveganja pri hipotezi o enakosti srednjih vrednosti in varianc pri naključni delitvi asfaltnih analiz v dve skupini.	32
Preglednica 8:	Korelacijski koeficienti za dve skupini, kjer so asfaltne analize naključno premešane, in njihove absolutne razlike.	32
Preglednica 9:	Uporabljene umetne nevronske mreže.	38
Preglednica 10:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	39
Preglednica 11:	Uporabljene umetne nevronske mreže.	39
Preglednica 12:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	40
Preglednica 13:	Uporabljene umetne nevronske mreže.	41
Preglednica 14:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	41
Preglednica 15:	Uporabljene umetne nevronske mreže.	42
Preglednica 16:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	42
Preglednica 17:	Uporabljene umetne nevronske mreže.	42
Preglednica 18:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	43
Preglednica 19:	Uporabljene umetne nevronske mreže.	43
Preglednica 20:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	43
Preglednica 21:	Uporabljene umetne nevronske mreže.	44
Preglednica 22:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	44
Preglednica 23:	Uporabljene umetne nevronske mreže.	44
Preglednica 24:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	45
Preglednica 25:	Uporabljene umetne nevronske mreže.	45
Preglednica 26:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	45
Preglednica 27:	Uporabljene umetne nevronske mreže.	46
Preglednica 28:	r^2 in RMSE za različne nevronske mreže in linearno regresijo.	46
Preglednica 29:	Lastnosti bitumnov PmB10/40-65 in B20/30.	50
Preglednica 30:	Vsebnost bitumna, polnila, votlin in zapolnjenost votlin z bitumnom za posamezno asfaltno zmes.	52
Preglednica 31:	Vrednosti trajne deformacije ϵ za različne vrste asfaltnih zmesi pri različnem številu ciklov n in vrednosti za F in F_{krit} .	57
Preglednica 32:	Rezultat enofaktorske analize variance za $n = 10000$.	57
Preglednica 33:	Rezultati mehanskih preiskav asfaltnih zmesi.	61
Preglednica 34:	Vrednosti lastnosti asfaltnih zmesi, ki so uporabljene pri računu z metodo glavnih komponent.	65
Preglednica 35:	Pomen oznak, ki so uporabljene v modelih.	69
Preglednica 36:	Modeli, r^2 in RMSE.	69
Preglednica 37:	Vsebnost bitumna, polnila, votlin in zapolnjenost votlin z bitumnom za asfaltni zmesi SMA LN in SMA LN PmB.	70
Preglednica 38:	Rezultati mehanskih preiskav asfaltnih zmesi SMA LN.	71
Preglednica 39:	Rezultati notranje validacije z metodo LOO.	73
Preglednica 40:	Rezultati zunanje validacije.	74
Preglednica 41:	Dejanske in z modelom 6 izračunane vrednosti proporcionalne globine kolesnice.	74
Preglednica 42:	Vrste bitumnov, uporabljenih v zmesih za razširitev modelov.	76

Preglednica 43: Vsebnost bitumna, polnila, votlin in zapolnjenost votlin z bitumnom za asfaltne zmesi, ki so uporabljene za razširitev grobega modela.	77
Preglednica 44: Rezultati mehanskih preiskav asfaltnih zmesi za razširitev grobega modela.	77
Preglednica 45: Primerjava r^2 za modele in njihovo razširitev na druge zmesi.	79
Preglednica 46: Rezultati razširitve grobih modelov.	80
Preglednica 47: Primerjava r^2 za modele in njihovo razširitev na asfaltne zmesi z nazivno zrnastostjo 11 mm.	80
Preglednica 48: Rezultati razširitve grobih modelov.	81
Preglednica 49: Primerjava r^2 razširitve modelov na asfaltne zmesi z nazivno zrnastostjo 11 mm in 8 mm.	81
Preglednica 50: Modeli, r^2 , RMSE in rezultati zunanje validacije.	82
Preglednica 51: Primerjava r^2 razširitve modelov na asfaltne zmesi z nazivno zrnastostjo 11 mm in 8 mm.	83
Preglednica 52: Uporabljene umetne nevronske mreže.	87
Preglednica 53: r^2 in RMSE za različne nevronske mreže in linearno regresijo.	87
Preglednica 54: Uporabljene umetne nevronske mreže.	88
Preglednica 55: r^2 in RMSE za različne nevronske mreže in linearno regresijo.	89
Preglednica 56: Vrste bitumnov in njihove lastnosti.	92
Preglednica 57: Vrednosti hitrosti prehoda vzdolžnih in strižnih ultrazvočnih valov skozi različne materiale ter akustične impedance (Frederick, 1965).	93
Preglednica 58: Vrednosti Δr_{ijk} glede na temperature bitumna in vrste bitumna.	102
Preglednica 59: Preglednica ANOVA.	103

LIST OF FIGURES:

Figure 1: Principal components in two-dimensional space.	9
Figure 2: Scheme of operation of artificial neural network.	10
Figure 3: Threshold or step function.	12
Figure 4: Exponential sigmoid function.	13
Figure 5: Tangent sigmoid function.	13
Figure 6: Linear function.	14
Figure 7: Scheme of single-layer feedforward artificial neural network.	15
Figure 8: Scheme of multi-layer feedforward artificial neural network.	15
Figure 9: Scheme of multi-layer backward artificial neural network.	16
Figure 10: Symbolic 3D display of error surface in multi-layer feedforward neural networks.	21
Figure 11: a) Scatter between S and PK for asphalt mixture AC 22 in the period 2006 - 2009 when looking only at relationship between S and PK, b) Scatter between S and air voids content for asphalt mixture AC 22 in the period 2006 - 2009 when looking only at relationship between S and air voids content.	23
Figure 12: Frequency histogram of differences in correlation coefficients for binder content and stability after 10000 simulations, assuming that the difference of the correlation coefficient is equal to 0.	31
Figure 13: Determination of the outlier.	36
Figure 14: Actual and with linear model calculated values for air voids content in asphalt mixture AC 22.	39
Figure 15: Actual and with linear model calculated values for air voids content in asphalt mixture AC 22.	40
Figure 16: Actual and with neural network ann 1 calculated values for voids content in aggregate.	46
Figure 17: Particle size distribution curve.	51
Figure 18: Schematic representation of haversinusoidal cyclic load of the specimen.	53
Figure 19: Schematic representation of the triaxial test (SIST EN 12697 - 25).	54
Figure 20: a) Specimens for the triaxial test, b) triaxial cell and c) temperature chamber and computer.	54
Figure 21: An example of flow curve.	55
Figure 22: Deformation curves of triaxial test for different types of asphalt.	56
Figure 23: Wheel tracking test device.	58
Figure 24: Deformation curves of wheel tracking test for different types of asphalt.	59
Figure 25: Marshall test device.	60
Figure 26: a) Definition of stability, flow and Marshall quotient, b) A typical result of Marshall test for asphalt mixtures SMA.	60
Figure 27: Permanent deformation (ϵ_{10000}) of triaxial test for seven asphalt mixtures.	62
Figure 28: Proportional rut depth for seven asphalt mixtures.	62
Figure 29: Linear correlation between proportional rut depth and permanent deformation of triaxial test: a) model with mixture MA PmB; b) model without mixture MA PmB.	63
Figure 30: Linear correlation between proportional rut depth and permanent deformation of triaxial test without mixtures PA, PA PmB, MA and MA PmB.	63
Figure 31: Correlation between creep rate f_c of triaxial test and wheel - tracking slope (wts).	64
Figure 32: Graphical representation of the basic structure and behaviour of the asphalt mixtures (Partl, Chailleux, 2013).	66

Figure 33: Principal component analysis (PCA) for different types of asphalt mixtures (score plot).	66
Figure 34: Principal component analysis (PCA) in the coordinate system Φ_1 and Φ_2 for properties of asphalt mixtures (loading plot).	67
Figure 35: Principal component analysis (PCA) in the coordinate system Φ_1 and Φ_3 for properties of asphalt mixtures (loading plot).	68
Figure 36: Particle size distribution curve for asphalt mixture SMA LN.	70
Figure 37: Deformation curves of triaxial test for asphalt mixtures SMA 11 B20/30 LN and SMA 11 PmB10/40-65 LN.	71
Figure 38: Deformation curves of wheel tracking test (WTT) for validation asphalt mixtures SMA 11 B20/30 LN and SMA 11 PmB10/40-65 LN.	72
Figure 39: Linear correlation of proportional rut depth and permanent deformation of triaxial test for asphalt mixtures, included in modeling, and two validation asphalt mixtures.	73
Figure 40: Graphical presentation of actual and with model 6 calculated values for proportional rut depth.	75
Figure 41: Particle size distribution curve for model extension.	76
Figure 42: Deformation curves of triaxial test for asphalt mixtures used for model extension.	78
Figure 43: Deformation curves of wheel tracking test for asphalt mixtures used for model extension.	79
Figure 44: Determination of the outlier.	86
Figure 45: Actual and with neural network ann 1 calculated values for ϵ_{1000} .	88
Figure 46: Actual and with linear model calculated values for ϵ_{1000} .	89
Figure 47: Scheme of incident and reflected wave at buffer - cement paste interface (Voigt, 2004).	95
Figure 48: Block scheme of USWR instrument.	97
Figure 49: Ultrasonic apparatus for monitoring hardening process of bitumen USWR-4.	98
Figure 50: a) Styrodur mould. b) Measuring sensor. c) Temperature chamber.	99
Figure 51: $T - t$ diagram for: a) paving grade bitumen, b) polymer modified bitumen.	99
Figure 52: Typical development of the Δr coefficient with temperature.	100
Figure 53: $\Delta r - t$ diagram for: a) paving grade bitumen, b) polymer modified bitumen.	101
Figure 54: $\Delta r - T$ diagram for: a) paving grade bitumen, b) polymer modified bitumen.	101

LIST OF TABLES:

Table 1:	ANOVA table	6
Table 2:	ANOVA table for two factors.	7
Table 3:	Correlation coefficients of some properties for asphalt mixture AC 22 in the period 2006 - 2009.	24
Table 4:	P - values for hypothesis of equality of averages and variances for two periods.	28
Table 5:	The correlation coefficients for two periods and their absolute differences.	29
Table 6:	The boundaries of the critical area of rejection of the null hypothesis for absolute limits of differences in correlation coefficients after 10000 simulations.	30
Table 7:	P - values for hypothesis of equality of averages and variances for random divided asphalt analyses into two groups.	32
Table 8:	The correlation coefficients for two groups, where asphalt analyses are randomly divided and their absolute differences.	32
Table 9:	Used artificial neural networks.	38
Table 10:	r^2 and RMSE for different neural networks and linear regression.	39
Table 11:	Used artificial neural networks.	39
Table 12:	r^2 and RMSE for different neural networks and linear regression.	40
Table 13:	Used artificial neural networks.	41
Table 14:	r^2 and RMSE for different neural networks and linear regression	41
Table 15:	Used artificial neural networks.	42
Table 16:	r^2 and RMSE for different neural networks and linear regression	42
Table 17:	Used artificial neural networks.	42
Table 18:	r^2 and RMSE for different neural networks and linear regression.	43
Table 19:	Used artificial neural networks.	43
Table 20:	r^2 and RMSE for different neural networks and linear regression.	43
Table 21:	Used artificial neural networks.	44
Table 22:	r^2 and RMSE for different neural networks and linear regression.	44
Table 23:	Used artificial neural networks.	44
Table 24:	r^2 and RMSE for different neural networks and linear regression.	45
Table 25:	Used artificial neural networks.	45
Table 26:	r^2 and RMSE for different neural networks and linear regression.	45
Table 27:	Used artificial neural networks.	46
Table 28:	r^2 and RMSE for different neural networks and linear regression.	46
Table 29:	Properties of bitumen binder PmB10/40-65 and B20/30.	50
Table 30:	Binder content, filler content, air void content and voids filled with bitumen for different asphalt mixtures.	52
Table 31:	Values of permanent deformation ϵ at different cycles n for different types of asphalt mixtures and values for F and F_{krit} .	57
Table 32:	The result of single factor analysis of variance at $n = 10000$.	57
Table 33:	Results of mechanical tests of asphalt mixtures.	61
Table 34:	The values of the properties of asphalt mixtures which were used in principal component analysis.	65
Table 35:	Symbols used in models.	69
Table 36:	Models, r^2 and RMSE.	69
Table 37:	Binder content, filler content, air void content and voids filled with bitumen for asphalt mixtures SMA LN and SMA LN PmB.	70
Table 38:	Results of mechanical tests of asphalt mixtures SMA LN.	71
Table 39:	The results of the internal validation method LOO.	73
Table 40:	The results of the external validation.	74
Table 41:	Actual and with model 6 calculated values for proportional rut depth.	74
Table 42:	Bitumen types used in mixtures for models extension.	76

Table 43: Binder content, filler content, air void content and voids filled with bitumen for asphalt mixtures used for model extension.	77
Table 44: Results of mechanical tests of asphalt mixtures for model extension.	77
Table 45: Comparison of r^2 for models and their extension to other mixtures.	79
Table 46: The results of the models extension.	80
Table 47: Comparison of r^2 for models and their extension to asphalt mixtures with nominal particle size 11 mm.	80
Table 48: The results of the models extension.	81
Table 49: Comparison of r^2 for models extension to asphalt mixtures with nominal particle size 11 mm and 8 mm.	81
Table 50: Models, r^2 , RMSE and results of the external validation.	82
Table 51: Comparison of r^2 for models extension to asphalt mixtures with nominal particle size 11 mm and 8 mm.	83
Table 52: Used artificial neural networks.	87
Table 53: r^2 and RMSE for different neural networks and linear regression.	87
Table 54: Used artificial neural networks.	88
Table 55: r^2 and RMSE for different neural networks and linear regression.	89
Table 56: Characteristics and labeling of bitumen used in the study.	92
Table 57: Values of speed of longitudinal and speed of shear ultrasonic waves for different materials and values of acoustic impedance (Frederick, 1965).	93
Table 58: Values of Δr_{ijk} with respect to different bitumen temperatures and bitumen types.	102
Table 59: ANOVA table.	103

1 UVOD

1.1 Splošno

Asfalt je zmes kamnitih zrn, veziva in zračnih votlin. Bitumen, ki nastopa kot vezivo v asfaltni kompoziciji, je viskoelastični material in zato časovno in temperaturno odvisne lastnosti asfalta prihajajo s strani bitumna. Druga komponenta asfalta je kamniti material, ki ne izkazuje nobenih temperaturno in časovno odvisnih lastnosti in predstavlja mehansko odpornost. V splošnem se asfalt uporablja za voziščne konstrukcije, kjer vemo, da je izpostavljen različnim zunanjim dejavnikom. Zato tehnologi s predhodno izbiro ustreznih materialov iščejo načine za sestavo take asfaltna zmesi, ki bi imela lastnosti, katere bi preprečevale negativne posledice, kot so trajne deformacije, razpoke zaradi utrujanja in temperature ter podobno. Ukvarjajo se z različnimi načini modeliranja, analiziranja, eksperimentiranja in obdelave podatkov. Poleg proizvodnje same zmesi je pomembno tudi vgrajevanje zmesi. Kontrola kakovosti oz. vrednotenje ustreznosti posamezne asfaltna zmesi in plasti se izvaja na osnovi evropskih standardov SIST EN.

Negativne posledice na voziščih, kot so trajne deformacije in razpoke zaradi temperature in utrujanje, so osnova za uvajanje novega načina opisovanja lastnosti v zadnjih letih. Te negativne posledice se na različnih plasteh voziščne konstrukcije kažejo v različnih oblikah in tudi njihov vpliv na posamezno plast ni enak. Asfaltna zmes, kakršno si želimo, mora imeti lastnosti, ki preprečujejo tovrstne posledice. Za opisovanje značilnosti asfaltnih zmesi se v zadnjem času največkrat uporabljajo lastnosti, povezane z obnašanjem (ang. performance-related), ali pa lastnosti, temelječe na obnašanju (ang. performance-based) (Ljubič, poglavje 2.4 v Asfalt, 2011, Gestrata, 2010).

Za načrtovanje asfaltnih zmesi se uporabljajo različni načini. Luminari in Fidato (1998) sta v svojem delu razdelila načrtovanje asfaltnih mešanic v šest kategorij: po receptu, empirično, analitično, volumsko, povezano z lastnostmi in temelječe na obnašanju. Metoda po receptu temelji na določanju deleža bitumna, agregata, debeline plasti, lastnosti zmesi med proizvodnjo in vgradnjo, glede na izkušnje, ki izhajajo iz tradicionalnih zmesi poznane sestave. Pri tej metodi se ne upoštevajo lastnosti posameznih materialov. Empirične metode temeljijo na določitvi vsebnosti bitumna na osnovi optimizacije več spremenljivk in ozirajo se na meje, postavljene v specifikacijah, ki so osnovane na preteklih izkušnjah. Najpogosteje uporabljena empirična metoda je Marshallov postopek. Spremenljivke, ki se merijo pri teh metodah, niso direktne mere za obnašanje asfaltna zmesi. Stabilnost po Marshallu, je na primer, ocena za strižno trdnost, tečenje pa ocena za trajno deformacijo. Pri volumskem načrtovanju mešanic se delež bitumna in sejalna krivulja določi na osnovi analize vsebnosti zračnih votlin, bitumna in agregata za zmesi, ki so bile zgoščene v laboratoriju na način, čimbolj podoben zgoščevanju na terenu. Pri tej metodi se ne upoštevajo nobeni mehanski testi asfaltnih zmesi. Pri metodah, povezanih z obnašanjem, se asfaltni zmesi, kateri želimo določiti delež bitumna, določi lastnost, ki je povezana z obnašanjem asfaltna plasti. Najboljša zmes je nato izbrana na osnovi kriterijev, ki so povezani z lastnostjo obnašanja asfaltna plasti (ang. Performance-related criteria). Med tovrstne testne metode spada preizkus ugotavljanja globine kolesnice (ang. wheel tracking test - WTT). Pri načrtovanju zmesi, ki temelji na obnašanju, pa je izbrana asfaltna zmes izpostavljena sistemu testov, temelječih na obnašanju, in s tem procesu ugotavljanja, kako se bo ta zmes obnašala po nekem časovnem obdobju. Pri nas se je do sedaj kot standardna preiskava za načrtovanje asfaltnih zmesi in njihovo kontrolo običajno uporabljal Marshallov postopek, s katerim določimo vsebnost zračnih votlin v asfaltni zmesi, vsebnost votlin v kamniti zmesi, stabilnost in deformacije po Marshallu. Preiskave, s katerimi določamo lastnosti, kot so modul elastičnosti, modul togosti, indirektna natezna trdnost, odpornost proti trajnim deformacijam in druge, se za enkrat

večinoma uporabljajo v raziskovalne namene in ne kot standardne preiskave za načrtovanje zmesi ali kontrolo kakovosti (Ljubič, poglavje 2.4 v Asfalt, 2011). Med take preiskave spada tudi ciklični triosni tlačni preskus, ki je bil na slovenskih zmesih izveden prvič in je ena izmed pomembnih komponent doktorske disertacije.

1.2 Vsebina in struktura doktorske disertacije

Struktura doktorske disertacije je smiselno sestavljena iz štirih delov:

- priprava baze podatkov in statistična analiza,
- grobi model obnašanja asfaltnih zmesi pri višji temperaturi,
- uporaba umetnih nevronske mreže za oceno trajne deformacije asfaltne zmesi,
- uporaba ultrazvočne metode na bitumenskem vezivu.

Prvi del se nanaša na izdelano bazo že obstoječih rezultatov večletnih preiskav asfaltnih zmesi na inštitutu Igmat d.d. Podatke, ki predstavljajo posamezno lastnost asfaltnih zmesi, smo obdelali s statistično analizo, s katero smo ugotovili, ali so vplivi faktorjev in njihovih interakcij statistično značilni. Z večkratnim, zaporednim in naključnim deljenjem podatkov v dve skupini smo določili meje za razlike korelacijskih koeficientov posameznih lastnosti s stabilnostjo in tečenjem. Z razvojem take metode smo ugotovili vpliv sprememb na rezultate meritev, ki jih ne moremo pripisati naključju, ampak nekim drugim dejavnikom. Poleg tega smo v tem delu z umetnimi nevronskimi mrežami modelirali delež votlin v asfaltni zmesi in delež votlin v zmesi kamnitega materiala za nekatere asfaltne zmesi. Analiza z umetnimi nevronskimi mrežami bo pokazala, ali so podatki med seboj dovolj povezani, da lahko na njihovi podlagi sklepamo o obnašanju drugih asfaltnih zmesi, ali pa je med njimi prevelik raztros.

Drugi del opisuje obnašanje asfalta pri povišanih temperaturah, kjer je največja negativna posledica nastanek trajne deformacije oz. kolesnice na vozišču, in oblikovanje grobega modela za napoved globine kolesnice. Preverili smo povezavo med triosnim preskusom, preskusom tvorbe kolesnic v asfaltni plasti in nekaterimi drugimi lastnostmi asfaltnih zmesi za štiri osnovne vrste asfaltov, katerih sejalne krivulje zajemajo zgornjo in spodnjo mejo, ki se še uporablja v asfalterstvu. Na ta način smo določili grobi model, ki predstavlja široko območje obnašanja za mnogo vrst asfaltov.

Tretji del doktorske disertacije se nanaša na triosni ciklični tlačni test asfaltne zmesi, ki se vgrajuje v obrabno zaporne plasti voziščne konstrukcije z največjim premerom zrna agregata 11 mm. V nadaljevanju doktorske disertacije triosni ciklični tlačni test imenujemo triosni test. Opravili smo veliko število triosnih testov in rezultate trajnih deformacij uporabili v analizi z umetnimi nevronskimi mrežami, ki so na področju umetne inteligence najbolj razširjena metoda in se uporablja tudi v inženirskih namene. Za analizo podatkov z umetnimi nevronskimi mrežami smo uporabili dva programa, in sicer WEKA in NTR2003.

Zadnji del naloge obsega nov način določanja lastnosti bitumna, ki v asfaltni zmesi predstavlja vezivo in je pomembna komponenta pri sestavi asfaltne zmesi. V delu smo predstavili uporabo nedestruktivne metode odboja strižnih ultrazvočnih valov za spremljanje temperaturno odvisnega procesa strjevanja bitumna. Na osnovi omenjene metode deluje merilni inštrument USWR-4 (Valič, 2000), ki je bil do sedaj uporabljen za spremljanje hidratacijskih procesov cementnih materialov. V okviru doktorske disertacije smo ga uporabili za pomembno razširitev omenjene USWR metode na področju spremljanja strjevalnega procesa različnih vrst bitumenskega veziva v širokem temperaturnem intervalu.

1.3 Pomen okrajšav

V doktorski disertaciji je uporabljenih veliko izrazov, ki jih v nekaterih primerih nadomestijo okrajšave. V nadaljevanju je podan seznam okrajšav:

- bitumenski beton - AC,
- bitumenski beton s polimernim bitumnom - AC PmB,
- drobir z bitumenskim mastiksom - SMA,
- drobir z bitumenskim mastiksom s polimernim bitumnom - SMA PmB,
- liti asfalt - MA,
- liti asfalt s polimernim bitumnom - MA PmB,
- drenažni asfalt - PA,
- drenažni asfalt s polimernim bitumnom - PA PmB,
- točka zmehčišča bitumna po metodi prstana in kroglice - PK,
- viskoznost bitumna - visk.,
- penetracija bitumna - pen.,
- duktilnost bitumna - dukt.,
- indeks penetracije bitumna - IP,
- pretrgališče po Fraassu - Fraass,
- stopnja lezenja - f_c ,
- trajna deformacija po 1000 ciklih obremenjevanja - $\epsilon_{1000,calc}$,
- stopnja tvorjenja kolesnice - wts ,
- trajna deformacija - ϵ_{10000} ,
- stabilnost asfaltne zmesi - S ,
- tečenje asfaltne zmesi - F ,
- tangencialno tečenje asfaltne zmesi - F_t ,
- Marshallov kvocient - S/F ,
- kvocient - S/F_t ,
- prostorninska gostota asfaltne zmesi - prostor. gost.,
- največja gostota asfaltne zmesi - največja gost.,
- vsebnost zračnih votlin v asfaltni zmesi - vsebnost zrač. votl.,
- stopnja zapolnjenosti votlin v asfaltni zmesi - stop. zapol. votl.,
- presejek skozi sito x mm - sito x (primer: presek skozi sito 2 mm - sito 2).

2 UPORABLJENE STATISTIČNE IN MATEMATIČNE METODE

Statistične metode razen metode PCA povzemam po učbeniku Verjetnostni račun in statistika G. Turka (2012).

2.1 Preizkušanje linearne povezanosti

S preizkušanjem linearne povezanosti ugotavljamo, ali sta dve spremenljivki med sabo linearno povezani. Linearno povezanost med dvema spremenljivkama X in Y merimo s kovarianco oz. koeficientom korelacije. Iz vzorčnih podatkov X_i in Y_i , $i = 0, \dots, n$, lahko ocenimo kovarianco in standardni deviaciji vzorca po spodnjih treh enačbah:

$$\hat{\sigma}_{XY} = S_{XY} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{n}, \quad S_X = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}}, \quad S_Y = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n}} \quad (1)$$

kjer je:

n ... število opazovanj,
 $\bar{X}$... povprečje vzorca X_i ,
 $\bar{Y}$... povprečje vzorca Y_i .

Ocena koeficienta korelacije pa je:

$$\hat{\rho}_{XY} = r_{XY} = \frac{S_{XY}}{S_X S_Y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}}, \quad (2)$$

kjer je:

S_{XY} ... kovarianca,
 S_Y, S_X ... standardni deviaciji vzorca.

Koeficient korelacije r_{XY} je kvadratni koren koeficienta determinacije r_{XY}^2 , ki je v nalogi večkrat uporabljen. Če je vrednost koeficienta korelacije r_{XY} blizu 0, pomeni, da sta spremenljivki X in Y zelo slabo linearno povezani, če je vrednost r_{XY} blizu 1, sta spremenljivki močno pozitivno linearno povezani, če pa se njegova vrednost približuje -1 , sta spremenljivki močno negativno linearno povezani.

Poleg kovariance in koeficienta korelacije smo za oceno ustreznosti modelov (tudi nelinearnih) uporabili kvadratni koren povprečja kvadratov napak (RMSE) med izračunanimi vrednostmi in dejanskimi vrednostmi spremenljivke. Izračunamo ga s spodnjo enačbo:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2}, \quad (3)$$

kjer je:

$\hat{Y}_i$... z modelom izračunana vrednost spremenljivke Y ,
 Y_i ... dejanska vrednost spremenljivke Y .

Koeficient determinacije r_{XY}^2 je mera za linearno povezanost dveh spremenljivk, RMSE pa meri odstopanja med spremenljivkama. Lahko se zgodi, da je r_{XY}^2 blizu 1 in RMSE velik, kar kaže na velika odstopanja in obratno, da je r_{XY}^2 blizu 0 in RMSE majhen, kar pa kaže na majhna odstopanja med spremenljivkama.

2.2 Analiza variance (ANOVA)

Z analizo variance ugotavljamo, ali ena ali več neodvisnih spremenljivk (faktorjev) X vpliva na slučajno spremenljivko Y .

2.2.1 Analiza variance za eno neodvisno spremenljivko

Vrednosti neodvisne spremenljivke X razdelimo v a razredov, kjer vsak razred vsebuje n elementov. Model tako razdeljenih podatkov zapišemo z naslednjo enačbo:

$$Y_{ij} = \mu + \alpha_i + \varepsilon_{ij}, \quad i = 1, \dots, a, \quad j = 1, \dots, n, \quad (4)$$

kjer je:

Y_{ij} ... vzorčna vrednost slučajne spremenljivke Y ,
 μ ... pričakovana vrednost,
 α_i ... vplivi posameznih razredov faktorja,
 ε_{ij} ... odstopanja vzorca od modela.

Običajno se predpostavi, da so ε_{ij} porazdeljena normalno s pričakovano vrednostjo nič in standardno deviacijo σ . Postavimo ničelno in alternativno domnevo:

$H_0: \alpha_i = 0$, za vse $i = 1, \dots, a$ (faktor ne vpliva),
 $H_1: \alpha_i \neq 0$, za vsaj en $i = 1, \dots, a$ (faktor vpliva).

Pri analizi variance preizkusimo ničelno domnevo, da faktor X ne vpliva na spremenljivko Y . Ničelno domnevo preizkusimo s statistiko F . Za njeno določitev moramo najprej izračunati povprečja za posamezne razrede vzorca ter skupno povprečje po spodnjih enačbah:

$$\bar{Y}_i = \frac{1}{n} \sum_{j=1}^n Y_{ij}, \quad \bar{Y} = \frac{1}{na} \sum_{i=1}^a \sum_{j=1}^n Y_{ij}. \quad (5)$$

Sledi izračun vsote kvadratov razlik:

$$SS_T = \sum_{i=1}^a \sum_{j=1}^n (Y_{ij} - \bar{Y})^2, \quad SS_A = n \sum_{i=1}^a (\bar{Y}_i - \bar{Y})^2, \quad SS_E = \sum_{i=1}^a \sum_{j=1}^n (Y_{ij} - \bar{Y}_i)^2, \quad (6)$$

kjer je:

SS_T ... celotna vsota kvadratov,
 SS_A ... vsota kvadratov zaradi razlik med povprečnimi vrednostmi $\bar{Y}_i$ v razredih,
 SS_E ... vsota kvadratov zaradi vpliva napak je vsota kvadratov razlik med posameznimi elementi vzorca Y_{ij} in povprečji $\bar{Y}_i$ posameznih razredov.

Velja:

$$SS_T = SS_A + SS_E. \quad (7)$$

Rezultat analize variance je preglednica ANOVA, ki jo pripravimo na osnovi vsote kvadratov:

Preglednica 1: Preglednica ANOVA

Table 1: ANOVA table

Vir odstopanj	Vsota kvadratov	Prostostne stopnje	Povprečni kvadrati	Statistika F
Faktor	SS_A	n_{psA}	MS_A	F
Napaka	SS_E	n_{psE}	MS_E	
Skupaj	SS_T	n_{psT}		

Prostostne stopnje so:

$$n_{psA} = a - 1, \quad n_{psE} = a(n - 1), \quad n_{psT} = an - 1 \quad (8)$$

in tudi tu velja:

$$n_{psT} = n_{psA} + n_{psE}. \quad (9)$$

Povprečne kvadrate in statistiko F izračunamo z naslednjimi enačbami:

$$MS_A = \frac{SS_A}{n_{psA}}, \quad MS_E = \frac{SS_E}{n_{psE}}, \quad F = \frac{MS_A}{MS_E}. \quad (10)$$

Statistika F se porazdeljuje po porazdelitvi F s prostostnimi stopnjami $\nu_1 = n_{psA}$ in $\nu_2 = n_{psE}$, kritično območje zavrnitve ničelne hipoteze H_0 je $[F_{1-\alpha}, \infty)$. V primeru, da je statistika F večja od kritične vrednosti $F_{krit} = F_{1-\alpha, \nu_1, \nu_2}$ oz. presega mejo območja zavrnitve ničelne hipoteze, ničelno hipotezo zavrnilo in trdimo, da je vpliv neodvisne spremenljivke X (faktorja) na spremenljivko Y statistično značilen.

2.2.2 Analiza variance za več neodvisnimi spremenljivkami

Z analizo variance za več faktorjev ugotavljamo, ali faktorji in interakcije med njimi vplivajo na slučajno spremenljivko Y . Prvi faktor A razdelimo v a razredov, drugi faktor B v b razredov in predpostavimo, da je v vsakem razredu n elementov. Model tako razdeljenih podatkov zapišemo z naslednjo enačbo:

$$Y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk}, \quad i = 1, \dots, a, \quad j = 1, \dots, b, \quad k = 1, \dots, n. \quad (11)$$

kjer je:

Y_{ijk} ... vzorčna vrednost slučajne spremenljivke Y ,
 μ ... pričakovana vrednost,
 α_i ... vpliv posameznih razredov faktorja A ,
 β_j ... vpliv posameznih razredov faktorja B ,
 $(\alpha\beta)_{ij}$... vpliv interakcije med A in B ,

ε_{ijk} ... vzorčno odstopanje od modela.

Običajno predpostavimo, da so odstopanja ε_{ijk} porazdeljena normalno s pričakovano vrednostjo nič in standardno deviacijo σ . V primeru dveh faktorjev moramo postaviti tri ničelne in tri alternativne hipoteze, saj moramo opraviti tri ločene in neodvisne preizkuse:

$H_0: \alpha_i = 0$, za vse $i = 1, \dots, a$ (faktor A ne vpliva),
 $H_1: \alpha_i \neq 0$, za vsaj en $i = 1, \dots, a$ (faktor A vpliva),
 $H_0: \beta_j = 0$, za vse $j = 1, \dots, b$ (faktor B ne vpliva),
 $H_1: \beta_j \neq 0$, za vsaj en $j = 1, \dots, b$ (faktor B vpliva),
 $H_0: (\alpha\beta)_{ij} = 0$, za vse $i = 1, \dots, a$ in $j = 1, \dots, b$ (interakcija med faktorjema A in B ne vpliva),
 $H_1: (\alpha\beta)_{ij} \neq 0$, za vsaj en $i = 1, \dots, a$ in $j = 1, \dots, b$ (interakcija med faktorjema A in B vpliva).

Podobno kot pri analizi variance za en faktor preizkusimo ničelne domneve s statistikami F , ki so v tem primeru tri. Za njihovo določitev najprej izračunamo povprečja za razrede faktorja A in faktorja B ($\bar{Y}_i$ in $\bar{Y}_j$), povprečja za posamezne razrede $\bar{Y}_{ij}$, ter skupno povprečje $\bar{Y}$ po spodnjih enačbah:

$$\bar{Y}_i = \frac{1}{bn} \sum_{j=1}^b \sum_{k=1}^n Y_{ijk}, \quad \bar{Y}_j = \frac{1}{an} \sum_{i=1}^a \sum_{k=1}^n Y_{ijk}, \quad \bar{Y}_{ij} = \frac{1}{n} \sum_{k=1}^n Y_{ijk}, \quad \bar{Y} = \frac{1}{abn} \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n Y_{ijk}. \quad (12)$$

Sledi izračun vsote kvadratov razlik:

$$SS_A = bn \sum_{i=1}^a (\bar{Y}_i - \bar{Y})^2, \quad SS_B = an \sum_{j=1}^b (\bar{Y}_j - \bar{Y})^2, \quad SS_{AB} = n \sum_{i=1}^a \sum_{j=1}^b (\bar{Y}_{ij} - \bar{Y}_i - \bar{Y}_j + \bar{Y})^2, \\ SS_T = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (Y_{ijk} - \bar{Y})^2, \quad SS_E = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (Y_{ijk} - \bar{Y}_{ij})^2. \quad (13)$$

kjer je:

SS_A ... vpliv faktorja A ,
 SS_B ... vpliv faktorja B ,
 SS_{AB} ... vpliv interakcije med faktorjema A in B ,
 SS_T ... celotna vsota kvadratov razlik in
 SS_E ... vpliv napake.

Velja:

$$SS_T = SS_A + SS_B + SS_{AB} + SS_E. \quad (14)$$

Podobno kot pri analizi variance za en faktor lahko sedaj pripravimo preglednico ANOVA za dva faktorja:

Preglednica 2: Preglednica ANOVA za dva faktorja.
Table 2: ANOVA table for two factors.

Vir odstopanj	Vsota kvadratov	Prostostne stopnje	Povprečni kvadrati	Statistika F
Faktor A	SS_A	n_{psA}	MS_A	F_A
Faktor B	SS_B	n_{psB}	MS_B	F_B
Interakcija AB	SS_{AB}	n_{psAB}	MS_{AB}	F_{AB}
Napaka	SS_E	n_{psE}	MS_E	
Skupaj	SS_T	n_{psT}		

Prostostne stopnje so:

$$\begin{aligned} n_{psA} &= a - 1, & n_{psB} &= b - 1, & n_{psAB} &= (a - 1)(b - 1), \\ n_{psE} &= ab(n - 1), & n_{psT} &= abn - 1 \end{aligned} \quad (15)$$

in tudi tu velja:

$$n_{psT} = n_{psA} + n_{psB} + n_{psAB} + n_{psE}. \quad (16)$$

Povprečne kvadrate in statistike F izračunamo z naslednjimi enačbami:

$$MS_A = \frac{SS_A}{n_{psA}}, \quad MS_B = \frac{SS_B}{n_{psB}}, \quad MS_{AB} = \frac{SS_{AB}}{n_{psAB}}, \quad MS_E = \frac{SS_E}{n_{psE}}, \quad (17)$$

$$F_A = \frac{MS_A}{MS_E}, \quad F_B = \frac{MS_B}{MS_E}, \quad F_{AB} = \frac{MS_{AB}}{MS_E}. \quad (18)$$

Statistike F se porazdeljujejo po porazdelitvi F s prostostnimi stopnjami $\nu_1 = n_{psA}$, n_{psB} ali n_{psAB} in $\nu_2 = n_{psE}$. V primeru, da je statistika F večja od kritične vrednosti $F_{krit} = F_{1-\alpha, \nu_1, \nu_2}$ oz. presega mejo območja zavrnitve ničelne hipoteze, ničelno hipotezo zavrnemo in trdimo, da je vpliv faktorja A , B oz. interakcije med njima na spremenljivko Y statistično značilen.

2.3 Linearna regresija za več spremenljivk

V primeru, ko je regresijska funkcija $f(X)$, ki opisuje kakšen je vpliv spremenljivke X na spremenljivko Y , linearna, govorimo o linearni regresiji ene neodvisne spremenljivke:

$$\hat{Y} = f(X) = a + bx \quad Y = a + bx + \varepsilon, \quad (19)$$

kjer je ε napaka oz. slučajno odstopanje.

Ko govorimo o vplivu več neodvisnih spremenljivk X_j na slučajno spremenljivko Y , pa je to linearna regresija več spremenljivk oz. multipla regresija in je posplošitev linearne regresije ene spremenljivke. Vzorec je običajno podan z vrednostmi X_{ij} , $i = 1, \dots, n$, $j = 1, \dots, k$ neodvisnih spremenljivk in vrednostmi Y_i , $i = 1, \dots, n$ spremenljivke Y . Zapišemo spodnjo regresijsko enačbo:

$$Y = \hat{Y} + \varepsilon = a + b_1 X_1 + b_2 X_2 + \dots + b_k X_k + \varepsilon, \quad (20)$$

kjer je ε podobno kot pri linearni regresiji ene spremenljivke odstopanje od modela. Običajno predpostavimo, da je ε porazdeljena normalno s srednjo vrednostjo nič in standardno deviacijo σ . Zapišimo regresijsko enačbo za posamezni element vzorca:

$$Y_i = a + b_1 X_{i1} + b_2 X_{i2} + \dots + b_{ik} X_{ik} + \varepsilon_i = a + \sum_{j=1}^k b_j X_{ij} + \varepsilon_i. \quad (21)$$

Z metodo najmanjših kvadratov določimo ocene neznanih regresijskih parametrov $\hat{a}$ in $\hat{b}_j$ tako, da bodo odstopanja dejanskih vrednosti Y_i od modela čim manjša v smislu vsote kvadratov. Torej iščemo minimum funkcije:


$$S(a, b_j) = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - a - \sum_{j=1}^k b_j X_{ij})^2 = \sum_{i=1}^n (Y_i - a - b_1 X_{i1} - b_2 X_{i2} - \dots - b_k X_{ik})^2. \quad (22)$$

Minimum zgornje funkcije določimo z odvajanjem le te po a in b_j in postavimo pogoj, da so ti odvodi enaki 0. Tako dobimo sistem enačb, ki je zapisan v nadaljevanju.

$$\begin{bmatrix} n & \sum X_{i1} & \sum X_{i2} & \dots & \sum X_{ik} \\ \sum X_{i1} & \sum X_{i1}^2 & \sum X_{i2} \sum X_{i1} & \dots & \sum X_{ik} \sum X_{i1} \\ \sum X_{i2} & \sum X_{i1} \sum X_{i2} & \sum X_{i2}^2 & \dots & \sum X_{ik} \sum X_{i2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sum X_{ik} & \sum X_{i1} \sum X_{ik} & \sum X_{i2} \sum X_{ik} & \dots & \sum X_{ik}^2 \end{bmatrix} \begin{bmatrix} \hat{a} \\ \hat{b}_1 \\ \hat{b}_2 \\ \vdots \\ \hat{b}_k \end{bmatrix} = \begin{bmatrix} \sum Y_i \\ \sum Y_i X_{i1} \\ \sum Y_i X_{i2} \\ \vdots \\ \sum Y_i X_{ik} \end{bmatrix} \quad (23)$$

2.4 Metoda glavnih komponent (PCA)

Metoda glavnih komponent je matematična metoda, ki z ortogonalno transformacijo pretvori odvisne spremenljivke v linearno neodvisne spremenljivke, katere imenujemo glavne komponente. Z uporabo PCA želimo iz velikega števila odvisnih spremenljivk opredeliti nekaj prvih komponent, ki pojasnjujejo čim večji delež celotne variance spremenljivk. Te nove komponente so linearna kombinacija odvisnih spremenljivk in so med sabo nekorelirane. Na sliki 1 je prikazana geometrijska določitev glavnih komponent v dvodimenzionalnem prostoru. Prva glavna os Φ_1 oz. komponenta leži v smeri največje variabilnosti spremenljivk x_1 in x_2 , druga glavna komponenta Φ_2 pa je neodvisna od prve in zato leži pravokotno nanjo. Ker lahko s prvo komponento Φ_1 pojasnimo dovolj variabilnosti spremenljivk x_1 in x_2 , lahko zaključimo, da ju lahko dovolj dobro opišemo in nadomestimo že z eno spremenljivko Φ_1 .



Slika 1: Glavne komponente v dvodimenzionalnem prostoru.
Figure 1: Principal components in two-dimensional space.

V nadaljevanju je na kratko predstavljen osnovni postopek metode glavnih komponent.

Računski postopek določitve glavnih komponent temelji na izračunu lastnih vektorjev in lastnih vrednosti kovariančne matrike odvisnih spremenljivk. Ekvivalentno temu je iskanje koordinatnega sistema, v katerem je kovariančna matrika diagonalna. Lastni vektor z največjo pripadajočo lastno vrednostjo predstavlja smer največje variacije, lastni vektor z drugo največjo lastno vrednostjo predstavlja smer z drugo največjo variacijo itd.

Naj bo Σ kovariančna matrika odvisnih spremenljivk, Φ ortogonalna matrika, katere stolpci predstavljajo lastne vektorje matrike Σ in Λ diagonalna matrika, katere diagonalni element predstavljajo lastne vrednosti matrike Σ . Zaradi normalizacije lastnih vektorjev velja tudi:

$$\Phi\Phi^T = \Phi^T\Phi = I. \quad (24)$$


Sedaj lahko zapišemo enačbo, po kateri določimo lastne vrednosti oz. glavne komponente metode PCA:

$$\Phi^T\Sigma\Phi = \Lambda. \quad (25)$$

Vidimo, da matrika lastnih vektorjev Φ predstavlja linearno transformacijo odvisnih spremenljivk iz xy koordinatnega sistema v $\Phi_1\Phi_2$ koordinatni sistem.

2.5 Umetne nevronske mreže

Umetne mreže delujejo na podoben način kot biološke mreže. Gradniki umetnih nevronske mreže so umetni nevroni oz. krajše nevroni, ki so med seboj povezani z vezmi, imenovanimi uteži. Preko povezav sprejme nevron signal od drugih nevronov, signal ojača ali oslabi in ga pošlje naprej drugim nevronom. Kako močno so nevroni med seboj povezani, določajo vrednosti uteži (slika 2).



Slika 2: Shema delovanja umetne nevronske mreže.
Figure 2: Scheme of operation of artificial neural network.

Kjer je:

u_i ... i -ti nevron,
 w_{ij} ... utež povezave med i -tim in j -tim nevronom,
 b_i ... prag i -tega nevrona,
 f_i ... funkcija, ki pretvori stanje aktivnosti nevrona v izhodni signal o_i ali izhodna funkcija,
 o_i ... izhodni signal i -tega nevrona.

Posebnost pri umetnih nevronskih mrežah je, da jih ne programiramo, ampak učimo. Proces učenja pomeni spreminjanje povezav med nevroni. Spreminjanje povezav lahko poteka na tri načine:

- ukinitve obstoječih povezav,
- vzpostavitev novih povezav,
- sprememba vrednosti uteži.

Nevronska mreža ima "spomin", kjer hrani vse informacije, pridobljene med učenjem. Učenje zahteva učne in testne podatke, kjer so vhodni in pripadajoči izhodni podatki poimenovani vhodno - izhodni pari. Učni so tisti, na katerih se mreža uči, spreminja povezave oz. vrednosti uteži med nevroni. Nevronska mreža na osnovi vhodnih podatkov postavi uteži na povezavah, ki se primerjajo s pragom nevrona. Postavitev uteži v naslednjem nivoju je odvisna od vrednosti uteži na predhodnem nivoju. Tako dobimo na izhodnih nevronih končne vrednosti, ki jih primerjamo z dejansko vrednostjo izhodnih podatkov. Če bo z mrežo izračunana vrednost znotraj določenih meja, bomo z vrednostmi uteži in pragov nevronov zadovoljni, v nasprotnem primeru postopek ponovimo, začne se nova iteracija. Testni vhodno - izhodni pari se uporabijo za ugotavljanje, kako dobro zna nevronska mreža posplošiti naučene zveze.

Način učenja je odvisen od tipa mreže in od učnega algoritma, ki ga mreža uporablja za učenje. Pri nevronskih mrežah z nadzorovanim učenjem je največkrat kot učni algoritem uporabljeno pravilo delta, imenovano tudi Widrow-Hoffovo učno pravilo, ki je izpeljanka Hebbovega pravila. Pravilo delta temelji na razliki, ki jo običajno označimo z oznako δ , med dejanskimi in z nevronske mreže izračunanimi vrednostmi. Ta učni algoritem oz. njegovo nadaljno posplošitev uporabljajo tudi večnivojske usmerjene nevronske mreže, zato je podrobneje prikazan v poglavjih 2.5.3 in 2.5.4.

Nevron

Nevron je osnovna procesna enota za obdelavo informacij. Na vhodu mreže nastopajo vhodni nevroni, na koncu mreže ležijo izhodni nevroni, vmes pa so skriti nivoji s poljubnim številom skritih nevronov. Naloga i -tega nevrona je, da izhodni signal, ki ga oddaja j -ti nevron, pomnoži z ustrežno utežjo in podobno še za vse ostale nevrone, s katerimi je povezan. Nato vse omenjene produkte med sabo sešteje, kar predstavlja neto vhodni signal nevrona, ki ga primerja s pragom. Zatem preko izhodne funkcije generira izhodni signal.

Povezave med nevroni

Posamezni nevroni v umetni nevronske mreži so med seboj povezani z vezmi, v katerih je shranjeno naučeno znanje. Povezava med nevronoma u_i in u_j je opisana z utežjo w_{ij} . Moč in smer povezave je določena z absolutno vrednostjo uteži. Negativen predznak pomeni, da nevron u_j zavira delovanje nevrona u_i . Pozitivno število w_{ij} pomeni, da nevron u_j spodbuja delovanje nevrona u_i . Če pa je vrednost uteži enaka 0, nevrona u_i in u_j med seboj nista povezana.

Vhodni signal

Vhodni signal nevrona u_i je vsota produktov posameznih uteži w_{ij} , ki povezujejo nevron u_i z ostalimi nevroni, z izhodnimi vrednostmi o_j teh nevronov. Ker so nevroni združeni v mreže, imamo več nevronov, več neto vhodnih signalov in več uteži.

Stanje aktivnosti

To je stanje oz. vrednost posameznega nevrona v nevronske mreži v določenem trenutku. Stanje nevrona lahko opišejo diskretne vrednosti 1 ali 0, lahko pa so te vrednosti zvezne npr. na intervalu med 0 in 1. Stanje aktivnosti je odvisno od neto vhodnega signala in praga b .

Izhodna funkcija


Izhodna funkcija pretvori stanje aktivnosti nevrona u_i v izhodni signal o_i . Z njo skrčimo vrednost izhodnega signala na območje nekega intervala. Vsak nevron v mreži lahko vsebuje svojo izhodno funkcijo. Najpogosteje se uporabljajo naslednje izhodne funkcije:

- pragovna oz. stopničasta funkcija (slika 3):

$$f(a) = \begin{cases} 1 & \dots a \geq 0 \\ 0 & \dots \text{sicer} \end{cases}, \quad (26)$$

kjer je $a = w_{ij}o_j + b_i$.


Pragovna funkcija vrne diskretne izhodne vrednosti. In sicer vrednost 1, če je stanje aktivnosti a pri nekem nevronu nenegativno, in vrednost 0, če je negativno.



Slika 3: Pragovna oz. stopničasta funkcija.
Figure 3: Threshold or step function.


- sigmoidna funkcija:

$$f(a) = \frac{1}{1 + e^{-a}} \quad (27)$$




Slika 4: Eksponentna sigmoidna funkcija.
Figure 4: Exponential sigmoid function.

Sigmoidna izhodna funkcija je zvezna, zvezno odvedljiva in strogo naraščajoča funkcija z zalogo vrednosti na intervalu $[0,1]$. Vrsta sigmoidne funkcije je tudi tangentna sigmoidna funkcija (slika 5), ki ima za razliko od eksponentne sigmoidne funkcije zalogo vrednosti na intervalu $[-1,1]$.



Slika 5: Tangentna sigmoidna funkcija.
Figure 5: Tangent sigmoid function.

- Poleg omenjenih izhodnih funkcij se uporabljajo tudi linearne funkcije (slika 6).



Slika 6: Linearna funkcija.
Figure 6: Linear function.


2.5.1 Razdelitev umetnih nevronske mreže

Umetne nevronske mreže lahko razdelimo glede na različne kriterije:

Geometrija


Geometrija mreže se nanaša na število nevronov na vhodu v mrežo, na izhodu iz mreže, na število skritih nivojev in na število nevronov na posameznem skitem nivoju. Če je mreža premajhna, ne bo sposobna predstaviti želene funkcije, če je prevelika, lahko pride do prekomernega prilaganja (angl. overfitting).

- Enonivojska usmerjena nevronska mreža (angl. single-layer feedforward network): Zanja je značilno, da je sestavljena iz enega vhodnega in enega izhodnega nivoja nevronov (slika 7). Vhodnemu nivoju so posredovani vhodni podatki, ki jih ta pošlje preko vezi izhodnemu nivoju nevronov, v katerem poteka procesiranje in izračuna izhodne vrednosti. Oznaka "usmerjena" se nanaša na potek informacij v le eni smeri, in sicer od vhodnih nevronov do izhodnih in ne obratno.




Slika 7: Shema enonivojske usmerjene nevronske mreže.
Figure 7: Scheme of single-layer feedforward artificial neural network.

- Večnivojska usmerjena nevronska mreža (angl. multi-layer feedforward network):
Ta tip mreže ima poleg vhodnega in izhodnega nivoja še enega ali več skritih nivojev, v katerih se nahajajo skriti nevroni (slika 8). Nevroni v prvem skitem nivoju prejmejo informacije od vhodnih nevronov in jih oddajo naprej izhodnemu nivoju ali naslednjemu skitemu nivoju. Torej predstavljajo izhodni signali prvega skritega nivoja vhodne signale drugega skritega nivoja in podobno. Število vhodnih nevronov je enako številu vhodnih spremenljivk oz. podatkov. Število izhodnih nevronov je enako številu izhodnih spremenljivk oz. od števila spremenljivk, ki jih hočemo izračunati z mrežo.



Slika 8: Shema večnivojske usmerjene nevronske mreže.
Figure 8: Scheme of multi-layer feedforward artificial neural network.

- Nevronska mreža s povezavami nazaj (angl. recurrent network):
Zanjo je značilno, da ima za razliko od zgornjih dveh mrež vsaj eno vzvratno povezavo med nivoji nevronov (slika 9).



Slika 9: Shema večnivojske nevronske mreže s povezavami nazaj.
Figure 9: Scheme of multi-layer backward artificial neural network.

- Kohonenova umetna nevronska mreža:
Sestavljena je iz vhodnega nivoja in Kohonenovega nivoja s povezavami samo naprej. Zanja je značilno samoorganizirano, kompetitivno in nenadzorovano učenje. To pomeni, da se mreža sama organizira tako, da je sposobna dati koristne informacije. Primerna je za zvezne vhodne podatke in reševanje problemov aproksimacije neznane funkcije.
- Hopfieldova umetna nevronska mreža:
Hopfieldova nevronska mreža shrani učne vzorce kot množico stabilnih stanj. Ob vnosu testnega vzorca nevronska mreža konvergira k tistemu stabilnemu (naučenemu) stanju, ki leži najbližje vhodu. Vsak nevron lahko zavzame samo dve stanji 1 ali -1 , pri čemer stanje 1 pomeni prisotnost, stanje -1 pa odsotnost neke lastnosti.

Način učenja

Ločimo dva načina učenja:

- Nadzorovano učenje:
Pri tovrstnem učenju so mreži podani vhodni in izhodni podatki. Skuša se učiti tako, da je izračunana vrednost izhodnega podatka čimbolj podobna dejanski vrednosti izhodne spremenljivke.
- Nenadzorovano učenje:
Podani so le vhodni podatki, izhodnih ni.

Vrsta vhodnih podatkov

Ločimo diskretne in zvezne vhodne podatke. Običajnejši so zvezni vhodni podatki, ki lahko zavzamejo poljubno vrednost na nekem območju (temperatura, vlaga, pomiki, hitrosti, itd.).

2.5.2 Večnivojska usmerjena umetna nevronska mreža

Tovrstna nevronska mreža je sestavljena iz vhodnih, izhodnih in iz dveh ali več skritih nivojev, ki vsebujejo poljubno število skritih nevronov. Zanja je značilno nadzorovano učenje, najpogosteje po algoritmu z vzratnim širjenjem napake (angl. error-backpropagation algorithm), ki temelji na posplošenem pravilu delta. Poleg značilne geometrije je za večnivojske umetne nevronske mreže značilno še:

- Povezanost nivojev:
Vsak nevron v nivoju je povezan z vsakim nevronom naslednjega nivoja. Nevroni istega nivoja med seboj niso povezani.
- Zveznost in odvedljivost:
Za izhodno funkcijo je pomembno, da je zaradi učnega algoritma zvezno odvedljiva. Običajno se uporablja sigmoidna funkcija.
- Hierarhija nivojev:
Pomembna je zaradi potovanja signala. Le ta mora vedno potovati v smeri od najnižje ležečih nivojev (vhodni nivo) do najvišje ležečega nivoja (izhodni nivo).

2.5.3 Pravilo delta

Umetna nevronska mreža se uči na podlagi učnega algoritma, ki določa, kako se spreminjajo uteži v nevronih. Signal potuje od vhodnega nevrona preko vseh skritih nivojev do izhodnega nivoja, ki poda izračunano izhodno spremenljivko. Nato na podlagi razlike med dejansko in z mrežo izračunano vrednostjo spreminja uteži v vzratni smeri, torej od izhodnega nivoja proti vhodnemu, na osnovi učnega algoritma. Učenje večnivojske umetne nevronske mreže poteka na podlagi posplošenega pravila delta. V nadaljevanju je najprej predstavljen učni algoritem, ki ga uporabljajo umetne nevronske mreže s samo vhodnim in izhodnim nivojem nevronov (Haykin, 1994, Kartam, 1997, Topping, 1997). Algoritem imenujemo pravilo delta in temelji na formuli:

$$\Delta_p w_{ji} = \eta (t_{pj} - o_{pj}) i_{pi} = \eta \delta_{pj} i_{pi} , \quad (28)$$

kjer je:

- $\Delta_p w_{ji}$... sprememba uteži, ki se zgodi ob upoštevanju p -tega vhodno - izhodnega para,
- η ... velikost učnega koraka,
- t_{pj} ... želena vrednost izhodnega nevrona oz. spremenljivke j za p -ti vhodno - izhodni par,
- o_{pj} ... z umetno nevronske mreže izračunana vrednost izhodne spremenljivke j za p -ti vhodno - izhodni par,
- i_{pi} ... vrednost vhodnega nevrona oz. vhodne spremenljivke i za p -ti vhodno - izhodni par,
- δ_{pj} ... razlika med želeno in z umetno nevronske mreže izračunano vrednostjo izhodne spremenljivke j za p -ti vhodno - izhodni par.

Napaka E_p je definirana kot vsota kvadratov odstopanj med želenimi in z umetno nevronske mreže izračunanimi vrednostmi za p -ti vhodno - izhodni par na izhodnem nivoju umetne nevronske mreže:

$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2. \quad (29)$$

Napaka celotnega niza vhodno - izhodnih parov na izhodnem nivoju je:

$$E = \sum E_p. \quad (30)$$

Iščemo minimum napake v odvisnosti od uteži. Zato E_p odvajamo po w_{ji} in odvod razbijemo na produkt odvoda napake glede na izhodno vrednost j -tega nevrona in odvoda izhodne vrednosti j -tega nevrona glede na ustrezno utež:

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial w_{ji}}. \quad (31)$$

Prvi odvod desne strani zgornje enačbe predstavlja spreminjanje napake s spreminjanjem izhodne vrednosti j -tega nevrona, drugi odvod pa pove, za koliko se spremeni izhodna vrednost j -tega nevrona pri spremembi uteži w_{ji} . Iz enačbe (29) sledi:

$$\frac{\partial E_p}{\partial o_{pj}} = -(t_{pj} - o_{pj}) = -\delta_{pj}, \quad (32)$$

kar pomeni, da je prispevek j -tega nevrona k napaki E_p sorazmeren razliki δ_{pj} . Enačbo (32) upoštevamo v (31):

$$-\frac{\partial E_p}{\partial w_{ji}} = \delta_{pj} \frac{\partial o_{pj}}{\partial w_{ji}}.$$

Odvod napake celotnega niza vhodno - izhodnih parov je potem enak:

$$\frac{\partial E}{\partial w_{ji}} = \sum_p \frac{\partial E_p}{\partial w_{ji}}. \quad (33)$$

Zgoraj smo dokazali, da je sprememba uteži Δw_{ji} sorazmerna odvodu napake, zato lahko rečemo, da pravilo delta temelji na gradientu napake. Izračunane popravke prištejemo utežem in postopek ponavljamo do želene natančnosti. V naslednjem poglavju je prikazano posplošeno pravilo delta, ki ga uporabljajo nevronske mreže, ki vsebujejo skrite nivoje nevronov.

2.5.4 Posplošeno pravilo delta

Pri večnivojskih mrežah je potrebno osnovno pravilo delta prilagoditi tako, da bo veljalo tudi za uteži med nevroni na skritih nivojih. Rumelhart in sodelavci (1986) so v ta namen podali posplošeno pravilo delta, ki je prilagojeno osnovno pravilo delta. Uporaba posplošenega pravila delta je sestavljena iz dveh faz. V prvi fazi se vhodnim nevronom umetne nevronske mreže posreduje vhodni podatek vhodno - izhodnega para. Vhodni nevroni pričnejo širiti signal po mreži do izhodnih nevronov, kjer se generirajo vrednosti izhodnih signalov o_{pj} . Izhodne vrednosti se primerjajo z želenimi in glede na to razliko se določi signal napake δ na izhodnih nevronih. V drugi fazi se v vzratni smeri pošilja signal napake nevronom na

skritih nivojih, tako da se spreminjajo uteži tudi na teh nivojih. Pri tem je zanimivo, da se lahko določeno število uteži fiksira in se njihovih vrednosti ne spreminja.

Pri posplošenem pravilu delta je smiselno uporabiti nelinearne izhodne funkcije. Poleg tega pa to pravilo deluje samo pri zvezno odvedljivih izhodnih funkcijah. Vsem tem zahtevam zadoščajo sigmoidne funkcije.

Izraz za celotni neto vhodni signal nevrona u_j je:

$$net_{pj} = \sum_i w_{ji} o_{pi}, \quad (34)$$

izhodni signal pa je:

$$o_{pj} = f_j (net_{pj}), \quad (35)$$

kjer je f_j odvedljiva na j -tem skritem nivoju.

Pri posplošenem pravilu delta vrednosti uteži spreminjamo v sorazmerju z odvodi napake E_p po uteži:

$$\Delta_p w_{ji} \propto -\frac{\partial E_p}{\partial w_{ji}}, \quad (36)$$

kjer je E_p napaka, ki smo jo vpeljali že pri pravilu delta (enačba (29)). Tudi tukaj lahko odvod v enačbi (36) razdelimo na dva dela. Prvi del je sprememba napake v odvisnosti od vhodnega signala, drugi del pa opisuje spremembo vhodnega signala nevrona v odvisnosti od spremembe ustrezne uteži:

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial net_{pj}} \frac{\partial net_{pj}}{\partial w_{ji}}. \quad (37)$$

Drugi člen zapišemo kot:

$$\frac{\partial net_{pj}}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} \sum_k w_{jk} o_{pk} = o_{pi}. \quad (38)$$

Upoštevamo:

$$\delta_{pj} = -\frac{\partial E_p}{\partial net_{pj}} \quad (39)$$

in dobimo:

$$-\frac{\partial E_p}{\partial w_{ji}} = \delta_{pj} o_{pi}. \quad (40)$$

Za manjšanje napake E_p v smeri gradienta moramo uteži spreminjati podobno kot pri pravilu delta:

$$\Delta_p w_{ji} = \eta \delta_{pj} o_{pi}, \quad (41)$$

kjer pa δ_{pj} določimo na drugačen način. Vrednosti δ_{pj} izračunamo s pošiljanjem signala napake v mreži v vzvratni smeri. Torej je za določitev signala napake potrebna vzvratna pot, ki se začne na izhodnem nivoju nevronov in konča na vhodnem nivoju nevronov umetne nevronske mreže. Za izračun δ_{pj} po enačbi (39) uporabimo verižno pravilo za odvajanje. Prvi del opisuje spremembo napake v odvisnosti od izhodnega signala, drugi del pa se nanaša na spremembo izhodnega signala nevrona v odvisnosti od sprememb na vhodnem signalu:

$$\delta_{pj} = -\frac{\partial E_p}{\partial net_{pj}} = -\frac{\partial E_p}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial net_{pj}}. \quad (42)$$

Drugi člen izrazimo iz enačbe (34):

$$\frac{\partial o_{pj}}{\partial net_{pj}} = f'_j(net_{pj}) \quad (43)$$

in predstavlja odvod izhodne funkcije nevrona.

Prvi člen ločimo na dva primera. V prvem primeru predpostavimo, da je nevron u_j izhodni nevron:

$$\frac{\partial E_p}{\partial o_{pj}} = -(t_{pj} - o_{pj}). \quad (44)$$

Račun spremembe uteži za izhodne nevrone je drugačen kot za skrite. Pri izhodnih nevronih je izračun napake preprost, ker vsakemu pripada želena izhodna vrednost. Velja:

$$\delta_{pj} = (t_{pj} - o_{pj}) f'_j(net_{pj}). \quad (45)$$

Če u_j ni izhodni nevron, uporabimo verižno pravilo za odvajanje:

$$\sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial net_{pk}}{\partial o_{pj}} = \sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial}{\partial o_{pj}} \sum_i w_{ki} o_{pi} = \sum_k \frac{\partial E_p}{\partial net_{pk}} w_{kj} = -\sum_k \delta_{pk} w_{kj}. \quad (46)$$

Za nevrone na ostalih nivojih velja:

$$\delta_{pj} = f'_j(net_{pj}) \sum_k \delta_{pk} w_{kj}. \quad (47)$$

δ_{pj} so podlaga za nadaljnji izračun sprememb uteži po enačbi (41). Zgornji postopek za večnivojske umetne nevronske mreže se imenuje posplošeno pravilo delta.

Spodaj sta povzeti glavni enačbi, ki določata posplošeno pravilo delta:


$$\Delta_p w_{ji} = \eta \delta_{pj} o_{pi}, \quad (48)$$

$$\delta_{pj} = \begin{cases} f'_j(net_{pj})(t_{pj} - o_{pj}); & \text{uteži ob izhodnih nevronih,} \\ f'_j(net_{pj}) \sum_k \delta_{pk} w_{kj}; & \text{uteži med skritimi nevroni.} \end{cases} \quad (49)$$

Sprememba uteži je torej sorazmerna odvodu napake nevrona, ki jo različno določimo za izhodne in ostale nivoje nevronov.

Pri večnivojskih umetnih nevronskih mrežah je veliko možnosti, da gradient napake med učenjem mreže naleti na minimum, ki je lokalni in ne globalni, kar pomeni, da vrednosti uteži niso optimalne.

Ploskev napake pri umetnih nevronskih mrežah ima mnogo dimenzij. Na sliki 10 smo jo simbolično prikazali v 3D prikazu. Metoda padajočega gradienta zahteva ustrezno velikost učnega koraka η . Na območju, ki je dovolj oddaljeno od globalnega minimuma, je lahko korak velik, s tem bo velika tudi sprememba uteži v eni iteraciji in mreža se bo hitreje učila. Ko se na ploskvi, ki opisuje napako, približujemo minimumu in smo od njega oddaljeni za nekaj dolžin koraka, ga z velikim korakom hitreje dosežemo. Vendar je velika verjetnost, da ga bomo s prevelikim η zgrešili. Zato je dobro, da na ožjem območju globalnega minimuma učni korak ustrezno zmanjšamo.



Slika 10: Simbolični 3D prikaz ploskve napake pri večnivojskih usmerjenih nevronskih mrežah.

Figure 10: Symbolic 3D display of error surface in multi-layer feedforward neural networks.

3 PRIPRAVA BAZE PODATKOV IN STATISTIČNA ANALIZA

Sestavili smo bazo podatkov, ki predstavljajo meritve posameznih lastnosti asfaltnih zmesi in obsega 17296 asfaltnih analiz. Meritve so bile izvedene na inštitutu Igmat v časovnem obdobju 1998 – 2009 (Interna baza meritev, Igmat d.d., 1998 - 2009). V tem poglavju doktorske disertacije opisujemo statistično metodo, s katero ugotavljamo, ali je prišlo do sprememb v meritvah in ali so med podatki prisotni osamelci (angl. outlier). Osredotočili smo se na ugotavljanje sprememb, ki se zgodijo v odnosu med stabilnostjo oz. tečenjem in preostalimi lastnostmi asfaltne zmesi. Poleg tega smo z umetnimi nevronskimi mrežami pripravili model za izračun zračnih votlin v asfaltne zmesi in votlin v zmesi kamnitega materiala. S področjem statistične obdelave standardnih mehanskih lastnosti asfaltnih zmesi so se v preteklosti že ukvarjali nekateri raziskovalci. Ozgan (2009) je modeliral Marshallovo stabilnost asfaltne zmesi pri spreminjanju temperature in časovne izpostavljenosti določeni temperaturi. Izkazalo se je, da imajo rezultati eksperimenta, modela mehke logike in statističnega modela dobre korelacije. To pomeni, da lahko tako statistični model kot model mehke logike uporabimo za modeliranje stabilnosti asfaltne zmesi pri spreminjanju temperature in časa izpostavljenosti tej temperaturi. Ravno tako sta se Tušar in Novič (2009) ukvarjala s statistično analizo rezultatov preiskav asfaltne zmesi in asfaltne plasti. Iskala sta korelacije med sestavo asfalta in mehanskimi lastnostmi po Marshallu. Za analizo sta uporabila linearno regresijo in umetne nevronske mreže. Chou in sodelavci (2009) so predstavili simulacije modelov, ki se lahko uporabijo za izračun verjetnosti stroškov nadomestnih projektov na mostovih avtocest. Uporabili so porazdelitvene funkcije kot uporabniku prijazne grafikone za tiste, ki sprejemajo odločitve v začetni idejni fazi. Franz in sodelavci so se ukvarjali z različnimi virtualnimi simulacijami in analizami korelacij na področju arhitekture. Pripravili so kvantitativne študije razmerij med arhitekturnim prostorom in fizikalnimi lastnostmi. Poleg tega se na področju simulacij veliko uporablja metoda Monte Carlo za ponavljajoče naključno vzorčenje z namenom pridobivanja numeričnih rezultatov (Touran, Wiser, 1992, Wall, 1996).

3.1 Spremenjene statistične lastnosti asfaltnih mešanic

Statistike, kot sta srednja vrednost in varianca, opisujejo osnovne lastnosti obravnavane populacije. Sprememba le-teh običajno kaže na spremembo v populaciji. Korelacijski koeficienti pa opisujejo linearno povezavo med posameznimi parametri populacije. Spremembe korelacijskih koeficientov ne kažejo na spremembo v osnovnih lastnostih populacije, temveč na spremembe v povezavah med parametri. Razlogi za te spremembe so najpogostejše spremenjeni načini meritev. Če torej ugotovimo, da so se korelacijski koeficienti v dveh časovnih obdobjih spremenili bolj, kot bi to lahko pričakovali zaradi naključnih odstopanj, moramo sklepati, da je v procesu meritev prišlo do sprememb. Statistična metoda je dovolj preprosta, da bi lahko bila pogosto uporabljena, saj uporablja le osnovne statistične izračune, ki jih omogočajo vsi računalniški programi, namenjeni urejanju, zbiranju in analiziranju podatkov.


Zanimata nas dve različni situaciji glede sprememb korelacijskih koeficientov med različnimi testi (Zavrtanik, Ljubič, Kavčič, Turk, 2010):

- Če podatke posamezne asfaltne zmesi časovno razdelimo na obdobje 1998 - 2005 in na obdobje 2006 - 2009, ugotavljamo, kako je vplivala sprememba standardov v letu 2005 na rezultate preiskav oziroma ali so razlike nastale naključno.
- Če iste podatke naključno razporedimo v dve skupini, ugotovimo, kateri podatek močno odstopa in na podlagi tega lahko preverimo, zakaj je prišlo do odstopanja. Velikost skupin je enaka velikosti skupin pri časovni razdelitvi.

3.1.1 Obravnavani podatki

Zbrani podatki so rezultati preiskav vzorcev bitumna, agregata in asfaltnih zmesi v časovnem obdobju 1998 - 2009 na Inštitutu za gradbene materiale IGMAT d.d. Podatki, ki smo jih obravnavali, so: zmečišče bitumna po postopku prstana in kroglice (PK), penetracija, pretrgališče po Fraassu, indeks penetracije (IP), viskoznost, duktilnost, elastični povratek, deleži posameznih frakcij kamnitega materiala, delež bitumna, stopnja zapolnjenosti votlin v bitumizirani zmesi, votline v kamnitem materialu, največja gostota kamnitega materiala, največja gostota asfalta, stabilnost, tečenje, Marshallov kvocient, prostorninska gostota asfalta in vsebnost zračnih votlin. Prvih sedem podatkov predstavlja lastnosti bitumna, ki je uporabljen v asfaltni zmesi, ostali podatki pa se nanašajo na asfaltno zmes.

V preglednici 3 so prikazane vrednosti korelacijskih koeficientov za nekatere lastnosti asfaltne zmesi AC 22 iz časovnega obdobja 2006 - 2009. Za uporabljene lastnosti asfaltne zmesi je značilen raztros med stabilnostjo in ostalimi lastnostmi. V skladu s pričakovanjem je razvidno, da imajo lastnosti bitumna (PK, penetracija in duktilnost) med sabo zmerno dobre korelacije ter da je korelacija med največjo gostoto asfaltne zmesi in prostorninsko gostoto dobra. Vse ostale lastnosti izkazujejo slabe medsebojne korelacije. Če za primer pogledamo le odvisnost med PK bitumna in stabilnostjo asfaltne zmesi, vidimo, da je njuna povezava slaba, saj na stabilnost vplivajo še druge lastnosti (slika 11a). Podobno velja za povezavo med stabilnostjo in vsebnostjo zračnih votlin v asfaltni zmesi (slika 11b). To je pričakovano, saj se iz korelacijske preglednice vidi, da obe lastnosti pojasnjujeta le majhen delež povezanosti stabilnosti z vsemi lastnostmi. Iz prakse je znan vpliv vsebnosti bitumna in polnila na stabilnost in votlavost. Če vsebnost zračnih votlin zmanjšamo z dodajanjem polnila, se stabilnost poveča, v primeru, ko votline napolnimo z bitumnom, pa se stabilnost večinoma zmanjša.



Slika 11: a) Raztros med S in PK za asfaltno zmes AC 22 v časovnem obdobju 2006 - 2009, če gledamo le odnos S in PK, b) Raztros med S in vsebnostjo zračnih votlin za asfaltno zmes AC 22 v časovnem obdobju 2006 - 2009, če gledamo le odnos med S in vsebnostjo zračnih votlin.

Figure 11: a) Scatter between S and PK for asphalt mixture AC 22 in the period 2006 - 2009 when looking only at relationship between S and PK, b) Scatter between S and air voids content for asphalt mixture AC 22 in the period 2006 - 2009 when looking only at relationship between S and air voids content.

Preglednica 3: Korelacijski koeficienti nekaterih lastnosti asfaltne zmesi AC 22 iz obdobja 2006 - 2009.

Table 3: Correlation coefficients of some properties for asphalt mixture AC 22 in the period 2006 - 2009.

	PK	Pen.	Visk.	Delež bit.	Sito 0.09	Sito 2	Sito 8	Prost. gost. asf.	Največ. gost. asf.	Vseb. zrač. votl.	S
PK	1										
Pen.	-0.708	1									
Visk.	0.700	-0.651	1								
Delež bit.	-0.200	0.322	-0.284	1							
Sito 0.09	0.085	-0.051	0.033	0.255	1						
Sito 2	0.052	-0.066	0.073	0.221	0.433	1					
Sito 8	0.057	-0.025	0.045	0.266	0.400	0.592	1				
Prost. gost. asf.	0.180	-0.225	0.324	-0.030	0.370	0.149	0.010	1			
Največ. gost. asf.	0.307	-0.368	0.476	-0.353	0.103	0.033	-0.010	0.814	1		
Vseb. zrač. votl.	0.199	-0.222	0.233	-0.522	-0.448	-0.192	-0.030	-0.354	0.254	1	
S	-0.041	-0.142	0.118	-0.166	-0.089	0.077	-0.014	0.266	0.304	0.046	1
F	0.146	-0.102	0.192	-0.064	0.129	0.135	0.118	0.395	0.396	-0.018	-0.11

Podatke smo razdelili v dve skupini, ki se ločita glede na časovno obdobje, v katerem so se izvajale meritve. Prva skupina zajema meritve iz obdobja 1998 - 2005, druga pa meritve, ki so se izvajale v obdobju 2006 - 2009. Razlog za takšno delitev je v uveljavitvi novih standardov leta 2005. Poleg tega so podatki ločeni še glede na tip uporabljenega veziva, in sicer asfaltne zmesi s cestogradbenim bitumnom in asfaltne zmesi s polimernim bitumnom. V nadaljevanju so na kratko opisane posamezne lastnosti, ki se običajno določajo pri vrednotenju ustreznosti posamezne asfaltne zmesi in so natančno določene v standardih SIST EN 12697.

Ker so statistične analize pri večjih vzorcih bolj zanesljive, smo obravnavali zmesi AC 11, AC 16, AC 22 in AC 32 s cestogradbenim bitumnom.

3.1.1.1 Seznam lastnosti asfaltnih zmesi, uporabljenih pri statistični analizi

- Zmehčišče bitumna po postopku prstana in kroglice (PK):
Segreti vzorec bitumna se vlije v prstan, ki je postavljen v kopel vode ali glicerina. Kopel se segreva 5 °C/min in nato odčitamo temperaturo, pri kateri je pod bremenom jeklene kroglice dosežena določena deformacija bitumna (SIST EN 1427:2007).
- Penetracija:
Vzorec bitumna vlijemo v posodico, ki jo postavimo v vodo z določeno temperaturo (25 °C). Zatam v vzorec bitumna potisnemo iglo, ki ima točno definirano velikost in težo. Penetracija, ki je izražena v 1/10 mm, je definirana kot globina, pri kateri se igla ustavi (SIST EN 1426:2007).
- Pretrgališče po Fraassu:
V določeno tekočino (običajno alkohol ali suhi led) položimo epruveto, v kateri je na tanki ploščici namazana tanka plast bitumna. To ploščico upogibamo toliko časa, dokler ne počne. Temperatura, pri kateri plast bitumna počne, je definirana kot pretrgališče po Fraassu (SIST EN 12593:2007).

- Indeks penetracije (IP):
Indeks penetracije določa temperaturno občutljivost bitumna in se določi na osnovi standarda SIST EN 12591/A:2009. Izračunamo ga iz vrednosti penetracije in temperature zmehčišča:

$$I_p = \frac{20t_{RaB} + 500I_gP - 1952}{t_{RaB} - 50I_gP + 120}, \quad (50)$$

kjer je:

t_{RaB} ... temperatura zmehčišča,
 I_gP ... naravni logaritem penetracije P pri temperaturi 25 °C.

- Viskoznost:
Viskoznost določamo na osnovi standarda SIST EN 12596:2007. Dinamična viskoznost je razmerje med strižno napetostjo in gradientom hitrosti. Njena enota je Pa·s. Poleg omenjene ločimo še kinematično viskoznost, ki je definirana kot razmerje med dinamično viskoznostjo in gostoto tekočine pri temperaturi merjenja viskoznosti.
- Duktilnost:
Duktilnost je sposobnost deformiranja bitumna v neelastično območje. Izražena je kot dolžina, do katere se lahko točno določen vzorec bitumna pri temperaturi 25 °C raztegne, ne da bi se pri tem pretrgal (standard DIN 52013:2007).
- Elastični povratek:
Elastično povratno deformacijo določimo na vzorcu polimernega bitumna na osnovi standarda SIST EN 13398:2010. Merimo skrček predhodno raztegnjenega vzorca, potem ko le-tega na sredini prerežemo.
- Delež bitumna:
Vzorec asfaltne zmesi vstavimo v napravo za ekstrakcijo veziva, kjer se s topilom loči vezivo od kamnitih delcev. Na ta način določimo delež bitumenskega veziva v asfaltni zmesi (standard SIST EN 12697 - 1).
- Sejalna analiza:
S sejalno analizo določimo deleže posameznih frakcij kamnitega materiala v asfaltni zmesi (standard SIST EN 12697 - 2). Porazdelitev velikosti zrn kamnitega materiala je pomembna značilnost asfaltne zmesi, saj je med drugim tudi od nje odvisna uporabnost zmesi. Posamezna frakcija zmesi kamnitih zrn je označena z nazivnima velikostma odprtin sit, t.j. spodnjo in zgornjo mejno velikostjo kvadratnih odprtin na sitih. Na osnovi sejanja skozi sita, ki imajo ustrezne dimenzije odprtin, kamnita zrna razvrstimo v osnovno frakcijo in vmesne frakcije. Osnovno frakcijo izberemo glede na debelino asfaltne plasti in glede na prometno obremenitev.
- Prostorninska gostota asfalta, največja gostota asfalta, največja gostota kamnitega materiala:
Iz vzorca asfaltne zmesi po standardu SIST EN 12697 - 30 pripravimo Marshallove preizkušance. Vzorec asfaltne zmesi postavimo pod standardizirano nabijalo in ga izpostavimo določenemu številu udarcev (2x50), ki jih predpisuje standard. Na osnovi standarda SIST EN 12697 - 6 se Marshallove preizkušance najprej stehta na suhem, nato položi v vodo, kjer se jih po določenem času ponovno stehta. Sledi tehtanje mokrih preizkušancev na suhem, iz razlike mas pa nato ocenimo prostorninsko gostoto.

Največja gostota je definirana kot gostota asfaltne zmesi brez vsebnosti zračnih votlin. Postopek določitve največje gostote asfaltne zmesi je določen v standardu SIST EN 12697 - 5, kjer je postopek A namenjen določitvi največje gostote s piknometrom (prostorninski postopek). Na osnovi različnih mas (masa praznega piknometra, masa polnega piknometra skupaj z nastavkom in masa polnega piknometra skupaj z vodo po vakuumiranju, s katerim se odstrani zajeti zrak) se izračuna največja gostota vzorca asfaltne zmesi.

Največjo gostoto kamnitega materiala izračunamo iz največje gostote asfaltne zmesi in gostote bitumna.

- Vsebnost zračnih votlin, stopnja zapolnjenosti votlin, votline v kamnitem materialu: Vsebnost zračnih votlin v asfaltni zmesi določimo iz razmerja prostorninske gostote in največje gostote Marshallovih preizkušancev.

Stopnjo zapolnjenosti votlin izračunamo iz prostorninske gostote, gostote in vsebnosti bitumna ter iz deleža votlin v kamnitem materialu.

Delež votlin v kamnitem materialu izračunamo iz prostorninske gostote, vsebnosti zračnih votlin ter iz gostote in vsebnosti bitumna.

3.1.2 Statistična analiza obravnavanih podatkov

Statistična analiza temelji na primerjavi povprečnih vrednosti, varianc in korelacij med merjenimi količinami. Podatke razdelimo na dve skupini. Delitev lahko opravimo glede na dve časovni obdobji, v katerih so bile meritve opravljene, lahko pa tudi glede na dve skupini laborantov, dva laboratorija in podobno. V našem primeru, smo eksperimentalne podatke, ki predstavljajo posamezno lastnost asfaltne zmesi, razdelili glede na časovno obdobje. S tem smo želeli ugotoviti, ali sprememba standardov v letu 2005 vpliva na meritve.

Da bi lahko ugotovili, kolikšne so lahko razlike med korelacijami in kaj so lahko razlogi za te razlike, računamo korelacije za dva različna primera:

- osnovni podatki, razdeljeni v dve skupini glede na časovno obdobje,
- osnovni podatki, naključno razvrščeni v dve skupini, ki sta enake velikosti kot v prvem primeru.

Prvi primer je osnovni in je tisti, ki ga pregledujemo. Z drugim primerom ugotavljamo, ali so podatki vsebovali osamelce, ki povzročijo, da se korelacije med skupinama razlikujejo.

V programu Mathematica smo pripravili kodo za simuliranje podatkov, ki predstavljajo posamezno lastnost asfaltne zmesi. V našem primeru s simulacijami večkrat zaporedoma naključno razdelimo podatke v dve skupini. V vsaki simulaciji smo izračunali korelacijsko matriko za vsako skupino (Anderson, 2003) in iz njiju določili korelacije oz. vplive različnih lastnosti asfaltnih zmesi na stabilnost in tečenje ter njihove razlike. Na ta način smo določili meje za razlike med korelacijskimi koeficienti. Postopek smo izvedli za štiri vrste asfaltnih zmesi AC: AC 11, AC 16, AC 22 in AC 32.

Statistika (povprečje vzorca, varianca vzorca, korelacijski koeficient,...) je količina, ki jo določimo iz vzorca. Zato na tem mestu opozorimo, da se v nadaljevanju vse prikazane vrednosti nanašajo na ocene parametrov populacije.

3.1.3 Rezultati

Za podatke, ki predstavljajo posamezne izmerjene lastnosti asfaltne zmesi, smo izračunali korelacijske matrike. Ker nas zanima vpliv različnih lastnosti asfaltne zmesi na stabilnost oz. tečenje, smo se osredotočili na tiste korelacije, ki predstavljajo vpliv le-teh na stabilnost oz. tečenje.

Zaradi velikega števila asfaltnih analiz so v nadaljevanju prikazani le rezultati obravnave asfaltne zmesi AC 22, rezultati za zmesi AC 11, AC 16 in AC 32 so prikazani v prilogi A. Na razpolago imamo 2193 analiz različnih lastnosti asfaltne zmesi AC 22 za obdobje med letoma 1998 in 2009 (Interna baza meritev, Igmat d.d., 1998 - 2009). V vsaki asfaltni analizi so meritve za 22 lastnosti (PK, penetracija, viskoznost, IP, delež bitumna, presejki skozi sito s premerom 0.09 mm, 0.25 mm, 0.71 mm, 2 mm, 4 mm, 8 mm, 11.2 mm, 16 mm, 22.4 mm, prostorninska gostota asfalta, največja gostota asfalta, vsebnost zračnih votlin, stopnja zapolnjenosti votlin, votline v kamnitem materialu in največja gostota kamnitega materiala).

- Delitev asfaltnih analiz na dve časovni obdobji:

2193 asfaltnih analiz razdelimo v dve skupini (Interna baza meritev, Igmat d.d., 1998 - 2009). V prvi skupini je 1777 asfaltnih analiz iz obdobja od leta 1998 do leta 2005, v drugi pa 416 asfaltnih analiz pridobljenih med leti 2006 in 2009. Naredili smo primerjavo povprečnih vrednosti, varianc in korelacijskih koeficientov med obema skupinama. Postavili smo ničelno hipotezo H_0 , da so variance in srednje vrednosti med obema skupinama enake. Iz preglednice 4 je v splošnem razvidno, da se vrednosti podatkov iz novejšega obdobja spremenijo v primerjavi s starejšim časovnim obdobjem, saj so tveganja za povprečja in variance za večino lastnosti manjša od 5 %. Torej lahko za večino meritev ničelno hipotezo zavrremo. To ne drži le pri presejku skozi sito 11.2 mm, kjer povprečje in varianca nista statistično značilno različna.

Preglednica 4: Dejanska tveganja pri hipotezi o enakosti srednjih vrednosti in varianc pri časovni delitvi podatkov.

Table 4: *P* - values for hypothesis of equality of averages and variances for two periods.

Lastnost	Tveganje za srednjo vrednost	Tveganje za varianco
PK	$6.3573 \cdot 10^{-36}$	0.0003
Penetracija	0.0006	0.0223
Viskoznost	0.0011	0.0520
IP	$1.5202 \cdot 10^{-80}$	$6.2720 \cdot 10^{-10}$
Delež bitumna	$9.2155 \cdot 10^{-26}$	0.0007
Sito 0.09 mm	$2.5333 \cdot 10^{-18}$	0.0048
Sito 0.25 mm	$9.1032 \cdot 10^{-16}$	0.2113
Sito 0.71 mm	$4.9452 \cdot 10^{-27}$	0.0220
Sito 2 mm	$2.3509 \cdot 10^{-19}$	0.0608
Sito 4 mm	$1.4889 \cdot 10^{-18}$	0.3509
Sito 8 mm	$3.8835 \cdot 10^{-14}$	0.1162
Sito 11.2 mm	0.0568	0.0551
Sito 16 mm	0.0017	0.0035
Sito 22.4 mm	$5.8567 \cdot 10^{-32}$	$1.0822 \cdot 10^{-15}$
Prostor. Gost.	0.0002	0.0001
Največja gost.	0.0080	0.0001
Vsebnost zrač. votl.	$2.2267 \cdot 10^{-20}$	0.0021
Stopnja zapol. votl.	$8.6988 \cdot 10^{-24}$	0.0004
Votline v kam. mat.	0.0196	0.0249
Največja gost. kam. mat.	0.4375	$2.2630 \cdot 10^{-7}$
<i>S</i>	0.00002	0.0049
<i>F</i>	$7.4066 \cdot 10^{-79}$	0.0001
<i>S/F</i>	$2.3739 \cdot 10^{-68}$	0.0001

V preglednici 5 so prikazani korelacijski koeficienti med stabilnostjo oz. tečenjem in ostalimi lastnostmi asfaltna zmesi za obe skupini asfaltnih analiz ter njihove razlike. S simulacijami v programu Mathematica smo določili meje kritičnega območja zavrnitve ničelne hipoteze pri 5% tveganju za razlike korelacijskih koeficientov, ki so prikazane v preglednici 6. Z njimi primerjamo razlike iz preglednice 5. Razlike, ki malo odstopajo od mej so posledica naključja. Bistveno večje razlike pa kažejo na večja odstopanja v rezultatih meritev, ki so posledica sprememb pri eksperimentih v časovnih obdobjih. V preglednici 5 so posebej označene razlike koeficientov korelacij, ki presegajo kritično vrednost območja zavrnitve ničelne hipoteze pri 5% tveganju za absolutne razlike korelacijskih koeficientov, ki so prikazane v preglednici 6. To pomeni, da so razlike korelacij statistično značilno različne od 0, s tveganjem, manjšim od 5 %. Do večjih sprememb pride pri lastnostih bitumenskega veziva, deležu bitumna, pri presejkih skozi nekatera sita, pri nekaterih lastnostih asfaltna zmesi, votlinah v kamnitem materialu in največji gostoti kamnitega materiala. Dejansko je v tem času prišlo do sprememb standardov iz starih JUS na nove evropske standarde SIST EN.

Pred uporabo metod iz standardov SIST EN 12697 - 1 do 43 so se preizkusi izvajali po metodah, ki so jih narekovali standardi JUS U.M8.086 do 105. Najpomembnejše razlike med metodami so v pripravi Marshallovih preizkušancev, kar ima za posledico tudi razlike v prostorninski gostoti, stopnji zapolnjenosti votlin, votlinah v kamnitem materialu ter razliko v določanju topnega in dodajanju netopnega deleža veziva po JUS standardih. Z uvedbo SIST EN standardov se pojavi tudi dodatno sito za polnilo, ki ima velikost odprtini 0.063 mm (prej je imelo najmanjše sito velikost odprtini 0.09 mm).

Preglednica 5: Korelacijski koeficienti za dve obdobji in njihove absolutne razlike.
Table 5: The correlation coefficients for two periods and their absolute differences.

Lastnost	r_{xy}				Razlike v r_{xy} med obdobjema	
	1998/2005		2006/2009		S	F
	S	F	S	F		
PK	0.094	0.090	-0.041	0.146	0.135*	0.056
Penetracija	-0.306	-0.189	-0.142	-0.102	0.164*	0.087
Viskoznost	0.300	0.176	0.118	0.192	0.182*	0.016
IP	-0.160	-0.053	-0.211	0.093	0.051	0.146*
Delež bitumna	0.290	0.189	-0.166	-0.064	0.456*	0.253*
Sito 0.09 mm	0.361	0.244	-0.089	0.129	0.450*	0.116*
Sito 0.25 mm	0.322	0.116	0.156	0.278	0.166*	0.162*
Sito 0.71 mm	0.239	0.057	0.199	0.214	0.041	0.157
Sito 2 mm	0.143	0.016	0.077	0.135	0.066	0.119*
Sito 4 mm	0.196	0.048	0.055	0.105	0.141	0.057
Sito 8 mm	0.109	-0.024	-0.014	0.118	0.124	0.142*
Sito 11.2 mm	0.053	-0.059	-0.096	-0.008	0.148	0.051
Sito 16 mm	-0.053	-0.040	-0.103	-0.004	0.051	0.036
Sito 22.4 mm	0.133	0.044	-0.088	-0.114	0.221*	0.158*
Prostor. gost.	0.570	0.308	0.266	0.395	0.305*	0.087
Največja gost.	0.594	0.302	0.304	0.396	0.291*	0.095
Vsebnost zrač. votl.	-0.020	-0.033	0.046	-0.018	0.066	0.015
Stopnja zapol. votl.	0.185	0.128	-0.089	0.038	0.275*	0.089
Votline v kam. mat.	0.323	0.174	-0.085	-0.018	0.407*	0.192*
Največja gost. kam. mat.	0.634	0.335	0.255	0.403	0.379*	0.068

*Odstopanja so prevelika, da bi bila lahko naključna.


Za absolutne vrednosti razlik korelacijskih koeficientov ne obstajajo standardne porazdelitve in zato smo uporabili simulacije, s katerimi smo podatke naključno razdelili v dve skupini (1777 analiz v prvi skupini in 416 analiz v drugi skupini). V vsaki simulaciji smo izračunali korelacije in postopek ponovili 10000-krat. Za vse lastnosti smo opravili statistično preizkušanje domneve z ničelno hipotezo H_0 : absolutna razlika korelacijskega koeficienta je enaka 0. Meje kritičnega območja zavrnitve ničelne hipoteze smo določili s simulacijami. V preglednici 6 so prikazane meje kritičnega območja zavrnitve ničelne hipoteze pri 5% tveganju.

Preglednica 6: Meje kritičnega območja zavrnitve ničelne hipoteze za absolutne razlike korelacijskih koeficientov po 10000 simulacijah.

Table 6: The boundaries of the critical area of rejection of the null hypothesis for absolute limits of differences in correlation coefficients after 10000 simulations.

Lastnost	Vrednosti mej za razlike v r_{xy}	
	<i>S</i>	<i>F</i>
PK	0.101	0.096
Penetracija	0.092	0.106
Viskoznost	0.120	0.113
IP	0.094	0.098
Delež bitumna	0.142	0.114
Sito 0.09 mm	0.118	0.105
Sito 0.25 mm	0.121	0.103
Sito 0.71 mm	0.132	0.103
Sito 2 mm	0.152	0.109
Sito 4 mm	0.150	0.114
Sito 8 mm	0.167	0.128
Sito 11.2 mm	0.170	0.121
Sito 16 mm	0.154	0.125
Sito 22.4 mm	0.130	0.103
Prostor. gost.	0.109	0.117
Največja gost.	0.113	0.140
Vsebnost zrač. votl.	0.139	0.128
Stopnja zapol. votl.	0.125	0.114
Votline v kam. mat.	0.157	0.134
Največja gost. kam. Mat.	0.112	0.121

Na sliki 12 je prikazan frekvenčni diagram absolutne razlike korelacijskega koeficienta med deležem bitumna in stabilnostjo po 10000 simulacijah. Iz slike je razvidno, da je verjetnost, da se preseže meja 0.142, približno 5 %, kar ustreza 5% tveganju. Ker je bila ocenjena razlika korelacij za ta dva parametra 0.456 in presega mejno vrednost 0.142, moramo zavrniti ničelno hipotezo in sklepati, da je razlika statistično značilna s tveganjem precej manjšim od 5 %.



Slika 12: Frekvenčni histogram razlik korelacijskih koeficientov med deležem bitumna in stabilnostjo po 10000 simulacijah, ob predpostavki, da je razlika korelacijskega koeficienta enaka 0.

Figure 12: Frequency histogram of differences in correlation coefficients for binder content and stability after 10000 simulations, assuming that the difference of the correlation coefficient is equal to 0.

- Delitev glede na naključno razvrščene asfaltne analize:

Za kontrolo 2193 asfaltnih analiz naključno razporedimo v dve skupini (Interna baza meritev Igmat d.d., 1998 - 2009). Velikost obeh skupin je enaka kot pri časovni razdelitvi (v prvi skupini je 1777, v drugi pa 416 asfaltnih analiz). Za vse lastnosti smo najprej preverili, kako se med dvema skupinama spremenijo statistične lastnosti, kot sta srednja vrednost in varianca.

Na tem mestu je potrebno poudariti, da preglednici 7 in 8 predstavljata samo en primer naključnega deljenja asfaltnih analiz. Z vsako simulacijo so se tveganja za povprečja in tveganja za variance ter absolutne razlike korelacij spremenile. Torej sta omenjeni preglednici le ilustracija, kaj se zgodi s podatki. Če so bile pri ponavljanju simulacij vrednosti v preglednici 7 konstantno zelo majhne, je bil to sum na napačne podatke v bazi. Taki podatki so bili iz analize izključeni.

V tem primeru je razvidno, da so vrednosti v preglednici 7 večje od 5 %, kar predstavlja stopnjo tveganja. To pomeni, da srednje vrednosti in variance v splošnem niso statistično značilno različne, kar smo tudi pričakovali. Ko se naključna delitev podatkov ponovi, se lahko zgodi, da so tveganja pri katerem od parametrov majhna. V takih primerih, ko so tveganja manjša od 5 %, je to posledica naključja.

V preglednici 8 so prikazani koeficienti korelacij med stabilnostjo oz. tečenjem in ostalimi lastnostmi asfaltne zmesi za obe skupini analiz ter njihove razlike. Razberemo lahko, da so vse absolutne razlike korelacij manjše od mej kritičnega območja zavrnitve ničelne hipoteze pri 5% tveganju iz preglednice 6. To pomeni, da absolutne razlike korelacij niso statistično značilno različne od 0.

Preglednica 7: Dejanska tveganja pri hipotezi o enakosti srednjih vrednosti in varianc pri naključni delitvi asfaltnih analiz v dve skupini.

Table 7: *P* - values for hypothesis of equality of averages and variances for random divided asphalt analyses into two groups.

Lastnost	Tveganje za srednjo vrednost	Tveganje za varianco
PK	0.1264	0.1568
Penetracija	0.4648	0.3301
Viskoznost	0.2785	0.0015
IP	0.1016	0.4885
Delež bitumna	0.4745	0.2728
Sito 0.09 mm	0.0755	0.4960
Sito 0.25 mm	0.4970	0.1422
Sito 0.71 mm	0.4725	0.0340
Sito 2 mm	0.1077	0.8421
Sito 4 mm	0.2772	0.0567
Sito 8 mm	0.0563	0.0383
Sito 11.2 mm	0.0593	0.7571
Sito 16 mm	0.3324	0.0606
Sito 22.4 mm	0.4609	0.0204
Prostor. gost.	0.3121	0.0007
Največja gost.	0.2688	0.0023
Vsebnost zrač. votl.	0.0841	0.0144
Stopnja zapol. votl.	0.1235	0.0817
Votline v kam. mat.	0.0967	0.0193
Največja gost. kam. mat.	0.3160	0.0031
<i>S</i>	0.3741	0.3268
<i>F</i>	0.1471	0.4897
<i>S/F</i>	0.2944	0.3613

Preglednica 8: Korelacijski koeficienti za dve skupini, kjer so asfaltne analize naključno premešane, in njihove absolutne razlike.

Table 8: The correlation coefficients for two groups, where asphalt analyses are randomly divided and their absolute differences.

<i>r_{xy}</i>	Razlike v <i>r_{xy}</i> med 1. in 2. skupino analiz					
	1. skupina analiz		2. skupina analiz			
Lastnost	<i>S</i>	<i>F</i>	<i>S</i>	<i>F</i>	<i>S</i>	<i>F</i>
PK	0.064	0.223	−0.016	0.178	0.080	0.046
Penetracija	−0.287	−0.115	−0.266	−0.055	0.021	0.060
Viskoznost	0.291	0.121	0.195	0.091	0.097	0.031
IP	−0.174	0.184	−0.231	0.153	0.057	0.031
Delež bitumna	0.180	0.223	0.150	0.227	0.030	0.003
Sito 0.09 mm	0.261	0.260	0.304	0.308	0.043	0.049
Sito 0.25 mm	0.276	0.216	0.271	0.227	0.004	0.011
Sito 0.71 mm	0.204	0.203	0.225	0.162	0.021	0.041
Sito 2 mm	0.104	0.137	0.159	0.131	0.055	0.006

Se nadaljuje ...

... nadaljevanje preglednice 8

Sito 4 mm	0.146	0.164	0.180	0.093	0.034	0.071
Sito 8 mm	0.048	0.096	0.172	0.120	0.124	0.024
Sito 11.2 mm	-0.001	-0.031	0.120	0.032	0.121	0.063
Sito 16 mm	-0.068	0.008	-0.063	0.019	0.005	0.011
Sito 22.4 mm	0.129	-0.088	0.070	-0.158	0.059	0.070
Prostor. gost.	0.470	0.340	0.480	0.334	0.011	0.007
Največja gost.	0.518	0.256	0.470	0.220	0.047	0.036
Vsebnost zrač. votl.	0.025	-0.131	-0.058	-0.161	0.083	0.030
Stopnja zapol. votl.	0.101	0.204	0.142	0.220	0.040	0.016
Votline v kam. mat.	0.277	0.089	0.168	0.050	0.109	0.038
Največja gost. kam. mat.	0.559	0.307	0.514	0.283	0.045	0.023

S pomočjo naključnega deljenja podatkov v dve skupini in s primerjavo srednjih vrednosti in varianc, smo ugotovili kateri podatki so napačni in smo jih posledično tudi izključili iz analize. Ugotovili smo, da so se korelacijski koeficienti za večino meritev, v dveh časovnih obdobjih spremenili bolj, kot bi to lahko pričakovali zaradi naključnih odstopanj. Zato lahko sklepamo, da je v procesu meritev, po spremembi standardov, prišlo do sprememb. Ravno tako, je iz primerjave srednjih vrednosti in varianc razvidno, da je prišlo pri spremembi standardov tudi do sprememb v vrednostih podatkov (meritev).

3.2 Uporaba umetnih nevronske mreže za oceno deleža votlin v asfaltni zmesi in deleža votlin v zmesi kamnitega materiala

V fazi priprave recepture asfaltna zmesi, je najpomembnejše ugotavljanje deleža zračnih votlin v asfaltni zmesi, ki je določen v standardih. V tem delu disertacije skušamo ugotoviti, ali je možno vnaprej napovedati recepturo asfaltna zmesi. Za določitev deleža votlin v asfaltni zmesi ter deleža votlin v zmesi kamnitih zrn smo izbrali večnivojske umetne nevronske mreže z učnim algoritmom vzvratnega širjenja napake. Na učenje umetne nevronske mreže vpliva vrsta parametrov, kot so: maksimalno število iteracij, velikost učnega koraka, geometrija mreže, multiplikacijski faktor, maksimalna velikost napake in tudi sami podatki, na katerih se mreža uči. Glede geometrije umetne nevronske mreže ni mogoče točno določiti, katera ustreza konkretnim podatkom. Pri obeh primerih smo se odločili za obravnavo mrež z dvema ali tremi skritimi nivoji. Uporabili smo fortranski program NTR2003 in knjižnico nevronske mreže v programu WEKA. Oba programa in parametri, ki vplivajo na učenje umetnih nevronske mreže, so opisani v poglavjih 3.2.1, 3.2.3 in 3.2.4. Opozorimo, da uporabljeni algoritmi niso povsem primerljivi, saj nastanejo razlike med programoma predvsem zaradi izhodne funkcije in zaradi postopkov v fazi učenja.

3.2.1 Opis parametrov, ki vplivajo na učenje umetnih nevronske mreže

Na uspešnost učenja nevronske mreže vplivajo mnogi parametri. Naštejmo in na kratko opišimo najpomembnejše.

Geometrija mreže

Geometrija umetne nevronske mreže se nanaša na število vhodnih in izhodnih nevronov ter na število skritih nivojev in število nevronov na posameznem skritem nivoju. Mi smo uporabili mreže z dvema ali tremi skritimi nivoji.

Izhodne funkcije

Opisali smo jih že v poglavju 2.5. Za naše primere uporabimo eksponentno sigmoidno izhodno funkcijo v programu NTR2003 in v programu WEKA, ki na zunanem sloju izhodne funkcije ne uporablja.

Maksimalno število iteracij

Na osnovi vhodnih podatkov umetna nevronska mreža izračuna vrednost izhodnega podatka v več iteracijah. Vrednost izhodnega podatka je odvisna od vrednosti uteži, določeni pri predhodni iteraciji. Nato mreža primerja izračunane izhodne vrednosti z želenimi in na podlagi teh razlik po posplošenem pravilu delta spremeni vrednosti uteži. Z maksimalnim številom iteracij omejimo število ciklov učenja. Mi smo upoštevali od 5000 do 10000 iteracij (glej preglednice 9, 11, 13, 15, 17, 19, 21, 23, 25 in 27).

Največja dovoljena napaka

Velikost dovoljene napake pomeni razliko med dejanskimi in z nevronskimi mrežami izračunanimi izhodnimi vrednostmi podatkov oz. rezultatov. Mi smo privzeli največjo dovoljeno napako 0.10.

Velikost učnega koraka

Pri izbiri velikosti učnega koraka v splošnem velja, da manjša velikost učnega koraka zahteva večje število iteracij in obratno. Mi smo upoštevali velikost učnega koraka od 0.1 do 0.5 (glej preglednice 9, 11, 13, 15, 17, 19, 21, 23, 25 in 27).

3.2.2 Statistični kazalci uspešnosti nevronske mreže

Uspešnost umetne nevronske mreže pri učenju ugotovimo, ko ji posredujemo nize testnih parov. Mreža na osnovi vrednosti uteži, ki so bile izračunane v zadnji iteraciji učenja, izračuna izhodne vrednosti za testne podatke in jih primerja z dejanskimi vrednostmi. Razlike med dejanskimi in izračunanimi vrednostmi so prikazane s statističnima kazalcema r_{XY}^2 in RMSE (enačbi 2 in 3).

3.2.3 Program NTR2003

Program NTR2003 je namenjen učenju in testiranju večnivojskih usmerjenih umetnih nevronskih mrež. Proces učenja poteka na osnovi algoritma z vzratnim širjenjem napake, ki temelji na posplošenem pravilu delta.

Za zagon programa je potrebno pripraviti tri datoteke:

- datoteke s splošnimi podatki s končnico *.inp*,
- datoteke z učnimi podatki s končnico *.dat*,
- datoteke s testnimi podatki s končnico *.tst*.

V datoteki s splošnimi podatki podajamo naslednje parametre:

- dovoljena velikost napake,
- velikost učnega koraka,
- maksimalno število iteracij,

- geometrija umetne nevronske mreže:
 - število nevronov vhodnega nivoja,
 - število nevronov izhodnega nivoja,
 - število skritih nivojev,
 - število nevronov na posameznem skitem nivoju.

V datoteko z učnimi podatki podamo nize vhodno - izhodnih učnih podatkov, v datoteko s testnimi podatki pa podamo nize vhodno - izhodnih testnih podatkov. V obeh datotekah je potrebno v prvih stolpcih podati vhodne podatke vhodno - izhodnih parov, v zadnje stolpce pa izhodne podatke vhodno - izhodnih parov podatkov.

Rezultate program shrani v dve datoteki:

- datoteka z utežmi s končnico *.wgt*
- datoteka s končnico *.out*.

V programu NTR2003 zaradi lažjega obvladovanja velikosti posameznih spremenljivk in večje stabilnosti računa vse vrednosti količin preslikamo na interval [0.1, 0.9]. To dosežemo z normiranjem podatkov po preprosti linearni formuli:

$$U_i = 0.1 + \frac{(X_i - X_{\min})}{(X_{\max} - X_{\min})} 0.8, \quad (51)$$

kjer je:

U_i ... vrednost normirane spremenljivke,
 X_i ... vrednost spremenljivke,
 $X_{\min}$... vrednost najmanjše spremenljivke v nizu vseh spremenljivk,
 $X_{\max}$... vrednost največje spremenljivke v nizu vseh spremenljivk.

Postopek učenja mreže v NTR2003 je iterativen in poteka na osnovi spreminjanja uteži med nevroni. To pomeni, da večkrat zapored procesira podane nize vhodno - izhodnih podatkov in si skuša "zapomniti" čimveč le-teh. Na podlagi "spomina" bo nato umetna nevronska mreža zmožna izračunati za neznan vhodni podatek, ki je podoben učnim, ustrezno izhodno vrednost.

3.2.4 Orodje WEKA Toolkit

Programsko orodje WEKA je sestavljeno iz zbirke algoritmov strojnega učenja. Omogoča predprocesiranje podatkov, klasifikacijo, ugotavljanje povezav znotraj nabora podatkov, grozdenje ter vizualizacijo baze podatkov.

Za zagon programa je potrebno pripraviti tekstovno datoteko s končnico *.arrf*, kamor vnesemo podatkovno bazo. Če želimo ločiti učno in testno bazo podatkov, pripravimo dve tekstovni datoteki s končnico *.arrf*. V datoteko z učnimi podatki podamo nize vhodno - izhodnih učnih podatkov, v datoteko s testnimi podatki pa nize vhodno - izhodnih testnih podatkov. V obeh datotekah je potrebno v prvih stolpcih podati vhodne podatke vhodno - izhodnih parov, v zadnji stolpec pa izhodni podatek vhodno - izhodnih parov podatkov.


Rezultati analize z umetnimi nevronskimi mrežami se prikažejo s statističnimi kazalci, kot so: determinacijski koeficient r^2 , povprečna absolutna napaka ter povprečna relativna napaka.

3.2.5 Podatki

Z umetnimi nevronskimi mrežami smo obravnavali pripravljeno bazo podatkov iz časovnega obdobja 1998 - 2009. Modelirali smo delež votlin v asfaltni zmesi in delež votlin v zmesi kamnitega materiala.

V obeh primerih najprej identificiramo parametre, ki pomembno vplivajo na določeno lastnost (izhodni podatek). Nato za tak parameter (vhodni podatek) ugotavljamo, katere vrednosti so osamelci. Natančen postopek določevanja osamelcev je opisan v nadaljevanju:

1. Vse vhodne podatke naključno premešamo.
2. Postavimo ničelno hipotezo H_0 : posamezna lastnost oz. vhodni podatek in izhodni podatek (t.j. delež votlin v asfaltni zmesi oz. delež votlin v zmesi kamnitega materiala) nista linearno povezana.
3. Določimo koeficiente linearne regresije.
4. Določimo tveganje ob zavrnitvi ničelne domneve P .
5. Pri tistem koeficientu, kjer je dejansko tveganje $P < \alpha = 0.01$, je vrednost koeficienta statistično značilno različna od 0 in lahko ničelno hipotezo H_0 zavrnemo.
6. V takih primerih preverimo posamezne vrednosti parametra (lastnosti), saj je utemeljen sum, da se med temi podatki nahaja osamelec.
7. Na osnovi podatkov ocenimo parametre normalne porazdelitve in podatke standardiziramo. Nato ugotovimo, ali posamezne vrednosti odstopajo od predpostavke o normalni porazdelitvi. Če zelo odstopajo od te predpostavke oz. če je verjetnost, da se taka vrednost zgodi zelo majhna, potem podatek označimo za osamelec. Verjetnost, pri kateri podatek označimo za osamelec, je $p = 1/\text{število podatkov}/10$ (slika 13).



Slika 13: Določitev osamelca med podatki.
Figure 13: Determination of the outlier.

3.2.5.1 Zračne votline v asfaltni zmesi

Delež zračnih votlin v asfaltni zmesi je za tehnologe, inženirje in proizvajalce eden od najpomembnejših parametrov, ki vplivajo na primernost asfaltne zmesi za uporabo v določenih pogojih. Zanimalo nas je, če je modeliranje z večnivojskimi umetnimi nevronskimi

mrežami z učnim algoritmom vzratnega širjenja napake uspešno pri napovedi deleža zračnih votlin v asfaltni zmesi.

Pri pregledu podatkov v bazi smo ugotovili, da se tisti, ki opisujejo lastnosti bitumna, v nekaterih primerih izključujejo (PK in pen. se ne ujemata s tipom bitumna ali PK in pen. se ne ujemata z viskoznostjo bitumna ali PK in pen. se ne ujemata s pretrgališčem po Fraassu). Nekaj neskladnosti je opaziti tudi glede vsebnosti bitumna in polnila ter votlavosti (višji vsebnosti bitumna in polnila smiselno sledi nižja votlavost in obratno). Zato smo se odločili, da je smiselno natančno pregledati podatke le za eno od asfaltnih zmesi iz baze podatkov. Glede na velik obseg sestavljene baze iz časovnega obdobja 1998 - 2009 (poglavje 3) smo preizkusili modeliranje deleža zračnih votlin v asfaltni zmesi le na zmesi AC 22 iz časovnega obdobja 2006 - 2009, ki ima dovolj velik vzorec podatkov. Najbolj nekonsistentne vrednosti smo izločili iz podatkov in s tem dobili 322 vhodno - izhodnih parov podatkov za modeliranje deleža zračnih votlin v asfaltni zmesi AC 22.

Obravnavali smo dva primera vhodno - izhodnih parov podatkov, ki se razlikujeta v vključenosti podatkov o bitumnu:

- V prvem primeru kot vhodni podatki nastopajo: PK, pen., visk., IP, Fraass, delež bitumna, sito 0.063, sito 0.09, sito 0.25, sito 0.71, sito 2, sito 4, sito 8, sito 11.2, sito 16 in gostota kamnitega materiala, kot izhodni podatek pa delež zračnih votlin v asfaltni zmesi. Teh 17 lastnosti, ki so razdeljene na 16 vhodnih spremenljivk in eno izhodno spremenljivko, predstavlja en vhodno - izhodni par. Če je par namenjen učenju, se imenuje učni vhodno - izhodni par, če je uporabljen za testiranje, se imenuje testni vhodno - izhodni par. Od 322 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 312. Od tega smo 252 parov uporabili za učenje umetne nevronske mreže in 60 za testiranje.
- V drugem primeru kot vhodni podatki nastopajo: delež bitumna, sito 0.063, sito 0.09, sito 0.25, sito 0.71, sito 2, sito 4, sito 8, sito 11.2, sito 16 in gostota kamnitega materiala, kot izhodni podatek pa delež zračnih votlin v asfaltni zmesi. Prvih 11 lastnosti oz. spremenljivk in delež zračnih votlin predstavljajo en vhodno - izhodni par učnih podatkov oz. testnih, če so namenjeni testiranju. Od 322 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 312. Od tega smo 252 parov uporabili za učenje in 60 za testiranje umetne nevronske mreže.

3.2.5.2 Votline v zmesi kamnitega materiala

Votline v kamnitem materialu določamo zato, da ugotovimo optimalno sestavo frakcij kamnitega materiala. Optimalna sestava frakcij agregata nam določa maksimalno gostoto oz. minimalno količino votlin v kamnitem materialu. Še posebej pri bitumenskih betonih (asfaltna zmesi AC) je pomembno poiskati najugodnejši kamniti sklad za določeno zmes frakcij kamnitega materiala, saj so te zmesi po definiciji najbližje najgostejšemu kamnitemu skladu.

Ker deleža votlin v zmesi kamnitega materiala ni možno natančno določiti iz gostote kamnitega materiala, deleža bitumna in sejalne krivulje, smo ga skušali modelirati z umetnimi nevronskimi mrežami. Obstajata dva razloga, zakaj ni možno deleža votlin v zmesi kamnitega materiala natančno izračunati:

- Najgostejši sklad lahko izračunamo, če imajo vsa zrna agregata enako obliko. Zaradi naključne oblike zrn je najgostejši sklad nelinearen, optimizacijski problem.
- Dodatno motnjo predstavlja bitumenska malta in naključno obračanje zrn, ki preprečita zlaganje v najgostejši sklad.

V zahtevah (standardih, specifikacijah, smernicah) je določeno dovoljeno območje vsebnosti zračnih votlin v asfaltni zmesi. Obenem je velikokrat določena dovoljena vsebnost bitumna ali zapolnjenost votlin v kamnitem materialu z bitumnom. Z upoštevanjem obeh omejitev si lahko izračunamo dovoljeno območje vsebnosti votlin v kamnitem materialu. Votline v kamnitem materialu so torej pomembne, ker so posredno določene v zahtevah.

Najprej smo ločeno obravnavali spodnje asfaltne zmesi iz pripravljene baze podatkov, ki vsebujejo zadostno število podatkov:

- AC 32 (iz časovnega obdobja 2006 - 2009),
- AC 22 (iz časovnega obdobja 2006 - 2009),
- AC 16 (iz časovnega obdobja 2006 - 2009),
- AC 11 (iz časovnega obdobja 2006 - 2009),
- AC/SMA 11 PmB (iz časovnega obdobja 2006 - 2009),
- AC 8 (iz časovnega obdobja 2006 - 2009),
- AC/SMA 8 PmB (iz časovnega obdobja 1998 - 2005),
- modeliranje na vseh sedmih zmesih skupaj.

V vseh primerih kot vhodni podatki nastopajo: delež bitumna, sejalna analiza (število presejkov skozi sita je odvisno od vrste asfaltne zmesi) in gostota kamnitega materiala, izhodni podatek pa je delež votlin v zmesi kamnitega materiala.

3.2.6 Rezultati

3.2.6.1 Zračne votline v asfaltni zmesi

Za modeliranje deleža zračnih votlin v asfaltni zmesi AC 22 (časovno obdobje 2006 - 2009) smo uporabili različne večnivojske usmerjene nevronske mreže. V preglednicah 9 in 11 so prikazane tri za program NTR2003 in tri za programsko orodje WEKA.


Primer 1:

Preglednica 9: Uporabljene umetne nevronske mreže.
Table 9: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	16 - 15 - 10 - 1	0.5	5000
ann 2	16 - 15 - 10 - 1	0.5	10000
ann 3	16 - 10 - 15 - 20 - 1	0.5	10000
ann 4	16 - 15 - 10 - 1	0.3	5000
ann 5	16 - 5 - 10 - 5 - 1	0.1	10000
ann 6	16 - 10 - 15 - 20 - 1	0.2	10000

Preglednica 10: r^2 in RMSE za različne nevronske mreže in linearno regresijo.
Table 10: r^2 and RMSE for different neural networks and linear regression.

	r^2	RMSE
NTR2003		
ann 1	0.369	1.07
ann 2	0.369	1.07
ann 3	0.250	1.12
WEKA		
ann 4	0.455	1.13
ann 5	0.337	1.21
ann 6	0.411	1.22
Linearna regresija	0.658	0.79



Slika 14: Dejanske vrednosti in z linearnim modelom izračunane vrednosti deleža votlin v asfaltni zmesi AC 22.

Figure 14: Actual and with linear model calculated values for air voids content in asphalt mixture AC 22.


Primer 2:

Preglednica 11: Uporabljene umetne nevronske mreže.
Table 11: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	11 - 15 - 10 - 1	0.5	5000
ann 2	11 - 5 - 10 - 5 - 1	0.5	8000
ann 3	11 - 10 - 15 - 20 - 1	0.5	10000
ann 4	11 - 5 - 7 - 1	0.1	5000
ann 5	11 - 15 - 10 - 1	0.2	8000
ann 6	11 - 5 - 10 - 5 - 1	0.1	8000

Preglednica 12: r^2 in RMSE za različne nevronske mreže in linearno regresijo.Table 12: r^2 and RMSE for different neural networks and linear regression.

	r^2	RMSE
NTR2003		
ann 1	0.133	1.23
ann 2	0.439	0.88
ann 3	0.558	0.73
WEKA		
ann 4	0.721	0.64
ann 5	0.577	0.86
ann 6	0.496	0.81
Linearna regresija	0.763	0.59



Slika 15: Dejanske vrednosti in z linearnim modelom izračunane vrednosti deleža votlin v asfaltni zmesi AC 22.

Figure 15: Actual and with linear model calculated values for air voids content in asphalt mixture AC 22.

V prvem primeru je linearni model boljši od modeliranja z umetnimi nevronskimi mrežami (slika 14). To pomeni, da je zveza bolj ali manj linearna, saj linearni model razmeroma dobro opiše problem. Nelinearnost, ki se je izkazala na učnih podatkih, je nastala le zaradi slučaja. Pri drugem primeru, ki ne vsebuje podatkov o bitumnu, sta linearni model in model z nevronske mreže (ann 4) primerljiva (preglednica 12 in slika 15), zato lahko zaključimo, da ni nujno modelirati z umetno nevronske mreže, saj lahko z linearnim modelom povsem zadovoljivo opišemo zvezo med deležem votlin v asfaltni zmesi in sejalno krivuljo. V splošnem je drugi primer, ki pri vhodnih podatkih ne upošteva lastnosti bitumna, boljši od prvega primera, ki jih upošteva. Torej, če želimo modelirati delež votlin v asfaltni zmesi, je bolje, da pri vhodnih podatkih ne upoštevamo podatkov o bitumnu, saj imajo prevelik raztros in so manj zanesljivi. Iz prakse je znano, da viskoznost bitumna vpliva na zgostljivost asfaltne zmesi in s tem na vsebnost zračnih votlin v asfaltni plasti. Ta vpliv je v primeru naših podatkov precej manjši od vpliva raztrosa podatkov in ga v nadaljnjem lahko zanemarimo.

3.2.6.2 Votline v zmesi kamnitega materiala

Za modeliranje deleža votlin v zmesi kamnitega materiala smo preizkusili različne večnivojske usmerjene nevronske mreže. V preglednicah 13, 15, 17, 19, 21, 23, 25 ter 27 so za vsako zmes prikazane tri za program NTR2003 in tri za programsko orodje WEKA. Preglednice 14, 16, 18, 20, 22, 24, 26 in 28 pa prikazujejo vrednosti za determinacijski koeficient r^2 in kvadratni koren povprečja kvadratov napak (RMSE) za posamezni model.

- AC 32 (iz časovnega obdobja 2006 - 2009)

Od 251 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 248. Od tega smo 210 parov podatkov uporabili za učenje in 38 za testiranje umetnih nevronske mreže.

Preglednica 13: Uporabljene umetne nevronske mreže.
Table 13: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	11 - 15 - 10 - 1	0.5	8000
ann 2	11 - 5 - 10 - 5 - 1	0.5	8000
ann 3	11 - 10 - 10 - 1	0.5	8000
ann 4	11 - 5 - 7 - 1	0.1	5000
ann 5	11 - 15 - 10 - 1	0.2	5000
ann 6	11 - 5 - 10 - 5 - 1	0.1	8000

Preglednica 14: r^2 in RMSE za različne nevronske mreže in linearno regresijo.
Table 14: r^2 and RMSE for different neural networks and linear regression

	r^2	RMSE
NTR2003		
ann 1	0.675	0.71
ann 2	0.391	0.94
ann 3	0.673	0.73
WEKA		
ann 4	0.599	0.89
ann 5	0.554	0.94
ann 6	0.693	0.68
Linearna regresija	0.697	0.68

- AC 22 (iz časovnega obdobja 2006 - 2009)

Od 390 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 381. Od tega smo 341 parov podatkov uporabili za učenje in 40 za testiranje umetnih nevronske mreže.

Preglednica 15: Uporabljene umetne nevronske mreže.

Table 15: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	10 - 15 - 10 - 1	0.5	5000
ann 2	10 - 5 - 10 - 5 - 1	0.5	8000
ann 3	10 - 10 - 15 - 20 - 1	0.5	8000
ann 4	10 - 5 - 7 - 1	0.2	8000
ann 5	10 - 5 - 10 - 5 - 1	0.3	10000
ann 6	10 - 10 - 15 - 20 - 1	0.2	10000

Preglednica 16: r^2 in RMSE za različne nevronske mreže in linearno regresijo.Table 16: r^2 and RMSE for different neural networks and linear regression

	r^2	RMSE
NTR2003		
ann 1	0.588	0.71
ann 2	0.140	0.98
ann 3	0.016	1.04
WEKA		
ann 4	0.425	1.17
ann 5	0.232	0.99
ann 6	0.312	1.12
Linearna regresija	0.512	0.73

- AC 16 (iz časovnega obdobja 2006 - 2009)

Od 285 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 276. Od tega smo 246 parov podatkov uporabili za učenje in 30 za testiranje umetnih nevronske mreže.

Preglednica 17: Uporabljene umetne nevronske mreže.

Table 17: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	10 - 15 - 10 - 1	0.5	5000
ann 2	10 - 15 - 10 - 1	0.5	7000
ann 3	10 - 5 - 10 - 5 - 1	0.5	10000
ann 4	10 - 5 - 7 - 1	0.1	5000
ann 5	10 - 5 - 10 - 5 - 1	0.1	8000
ann 6	10 - 10 - 15 - 20 - 1	0.2	10000

Preglednica 18: r^2 in RMSE za različne nevronske mreže in linearno regresijo.

Table 18: r^2 and RMSE for different neural networks and linear regression.

	r^2	RMSE
NTR2003		
ann 1	0.527	0.85
ann 2	0.424	0.96
ann 3	0.417	0.95
WEKA		
ann 4	0.512	0.99
ann 5	0.520	1.00
ann 6	0.423	1.29
Linearna regresija	0.545	1.02

- AC 11 (iz časovnega obdobja 2006 - 2009)

Od 206 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 202. Od tega smo 172 parov podatkov uporabili za učenje in 30 za testiranje umetnih nevronske mreže.

Preglednica 19: Uporabljene umetne nevronske mreže.

Table 19: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	9 - 15 - 10 - 1	0.5	5000
ann 2	9 - 15 - 10 - 1	0.5	10000
ann 3	9 - 5 - 10 - 5 - 1	0.5	10000
ann 4	9 - 15 - 10 - 1	0.3	5000
ann 5	9 - 5 - 10 - 5 - 1	0.1	10000
ann 6	9 - 10 - 15 - 20 - 1	0.1	10000

Preglednica 20: r^2 in RMSE za različne nevronske mreže in linearno regresijo.

Table 20: r^2 and RMSE for different neural networks and linear regression.

	r^2	RMSE
NTR2003		
ann 1	0.489	0.65
ann 2	0.461	0.70
ann 3	0.144	0.83
WEKA		
ann 4	0.280	0.92
ann 5	0.162	0.87
ann 6	0.164	1.02
Linearna regresija	0.325	0.74

- AC/SMA 11 PmB (iz časovnega obdobja 2006 - 2009)

Od 178 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 176. Od tega smo 150 parov podatkov uporabili za učenje in 26 za testiranje umetnih nevronske mreže.

Preglednica 21: Uporabljene umetne nevronske mreže.

Table 21: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	8 - 15 - 10 - 1	0.5	8000
ann 2	8 - 5 - 10 - 1	0.5	5000
ann 3	8 - 5 - 10 - 5 - 1	0.5	8000
ann 4	8 - 5 - 7 - 1	0.1	5000
ann 5	8 - 15 - 10 - 1	0.2	5000
ann 6	8 - 5 - 10 - 5 - 1	0.3	8000

Preglednica 22: r^2 in RMSE za različne nevronske mreže in linearno regresijo.Table 22: r^2 and RMSE for different neural networks and linear regression.

	r^2	RMSE
NTR2003		
ann 1	0.600	0.64
ann 2	0.579	0.74
ann 3	0.423	0.81
WEKA		
ann 4	0.731	0.57
ann 5	0.726	0.67
ann 6	0.852	0.42
Linearna regresija	0.652	0.61

- AC 8 (iz časovnega obdobja 2006 - 2009)

Od 388 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 385. Od tega smo 345 parov podatkov uporabili za učenje in 40 za testiranje umetnih nevronske mreže.

Preglednica 23: Uporabljene umetne nevronske mreže.

Table 23: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	8 - 15 - 10 - 1	0.5	8000
ann 2	8 - 5 - 10 - 5 - 1	0.5	8000
ann 3	8 - 10 - 15 - 20 - 1	0.5	8000
ann 4	8 - 5 - 7 - 1	0.2	8000
ann 5	8 - 15 - 10 - 1	0.1	8000
ann 6	8 - 10 - 15 - 20 - 1	0.3	5000

Preglednica 24: r^2 in RMSE za različne nevronske mreže in linearno regresijo.

Table 24: r^2 and RMSE for different neural networks and linear regression.

	r^2	RMSE
NTR2003		
ann 1	0.526	1.01
ann 2	0.749	0.74
ann 3	0.650	0.87
WEKA		
ann 4	0.768	0.72
ann 5	0.780	0.69
ann 6	0.647	0.90
Linearna regresija	0.669	0.92

- AC/SMA 8 PmB (iz časovnega obdobja 1998 - 2005)

Pri zmesi AC/SMA 8 PmB nismo našli osamelcev, zato nismo izključili nobenega vhodno - izhodnega para podatkov. Analizirali smo 357 parov podatkov, od tega smo jih 307 uporabili za učenje in 50 za testiranje umetnih nevronske mreže.

Preglednica 25: Uporabljene umetne nevronske mreže.

Table 25: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	7 - 15 - 10 - 1	0.5	5000
ann 2	7 - 5 - 10 - 5 - 1	0.5	10000
ann 3	7 - 10 - 15 - 20 - 1	0.5	8000
ann 4	7 - 7 - 5 - 1	0.1	5000
ann 5	7 - 5 - 10 - 5 - 1	0.1	10000
ann 6	7 - 10 - 15 - 20 - 1	0.2	5000

Preglednica 26: r^2 in RMSE za različne nevronske mreže in linearno regresijo.

Table 26: r^2 and RMSE for different neural networks and linear regression.

	r^2	RMSE
NTR2003		
ann 1	0.240	0.81
ann 2	0.317	0.74
ann 3	0.492	0.67
WEKA		
ann 4	0.314	0.83
ann 5	0.434	0.72
ann 6	0.173	1.70
Linearna regresija	0.562	0.60

- modeliranje na vseh sedmih zmesih skupaj

Od 1814 vhodno - izhodnih parov podatkov jih je 1634 uporabljenih za učenje in 180 za testiranje umetnih nevronske mreže.


Preglednica 27: Uporabljene umetne nevronske mreže.

Table 27: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	7 - 10 - 10 - 1	0.5	10000
ann 2	7 - 10 - 5 - 10 - 1	0.5	10000
ann 3	7 - 15 - 10 - 15 - 1	0.5	10000
ann 4	7 - 5 - 7 - 1	0.1	8000
ann 5	7 - 5 - 10 - 5 - 1	0.1	10000
ann 6	7 - 10 - 15 - 20 - 1	0.2	5000

Preglednica 28: r^2 in RMSE za različne nevronske mreže in linearno regresijo.Table 28: r^2 and RMSE for different neural networks and linear regression.

	r^2	RMSE
NTR2003		
ann 1	0.778	0.43
ann 2	0.770	0.44
ann 3	0.759	0.45
WEKA		
ann 4	0.749	0.48
ann 5	0.793	0.42
ann 6	0.803	0.41
Linearna regresija	0.717	0.48



Slika 16: Dejanske vrednosti in z nevronske mrežo ann 1 izračunane vrednosti deleža votlin v zmesi kamnitega materiala.

Figure 16: Actual and with neural network ann 1 calculated values for voids content in aggregate.

Linearni model je od modela, ki ga dobimo z umetnimi nevronskimi mrežami, boljši oz. enak v primeru asfaltnih zmesi AC 22, AC/SMA 8 PmB, AC 32, AC 16 in AC 11. Pri asfaltnih zmesih AC/SMA 11 PmB in AC 8 je linearni model za spoznanje slabši od nekaterih modelov z nevronskimi mrežami, pri analizi vseh zmesi skupaj pa je opaziti, da so vsi modeli z nevronskimi mrežami boljši od linearnega modela. Pri posameznih zmesih so bile torej skrivne povezave med podatki zgolj slučajne, umetne nevronske mreže pa so jih modelirale kot nekaj pomembnega. To je bil vzrok za poslabšanje modela. Pri modeliranju vseh zmesi skupaj pa so nevronske mreže odkrile prave skrivne povezave med podatki. V tem primeru je nelinearnost posledica nazivne zrnivosti. Zato so bili v tem primeru modeli z umetnimi nevronskimi mrežami boljši od linearnega.

3.3 Sklep

Primerjava razlik korelacijskih koeficientov med naključno razdeljenimi asfaltnimi analizami v dve skupini, je pokazala, da nobena meritev ne odstopa veliko od ostalih meritev. To pomeni, da tam, kjer so se pojavila odstopanja, so ta dovolj majhna in so posledica slučaja. Primerjava razlik korelacijskih koeficientov med dvema skupinama asfaltnih analiz, ki so časovno razdeljene na dve obdobji (prvo obdobje med leti 1998 in 2005 in drugo obdobje med leti 2006 in 2009), pa je pokazala, da so odstopanja med meritvami večja. To pomeni, da nastale razlike niso posledica zgolj slučaja, ampak spremembe standardov ali drugih dejavnikov, ki so vplivali na meritve.

Pri modeliranju deleža votlin v asfaltni zmesi je bolje, da pri vhodnih podatkih ne upoštevamo podatkov o bitumnu, saj imajo prevelik raztros in so manj zanesljivi. Poleg tega ni nujno, da se delež votlin v asfaltni zmesi modelira z nevronskimi mrežami, saj je preprostejši linearni model pokazal podobne ali celo boljše rezultate.

Pri modeliranju deleža votlin v zmesi kamnitega materiala smo ugotovili, da je v primeru, ko imamo podatke o različnih asfaltnih zmesih, model z umetnimi nevronskimi mrežami uspešnejši v primerjavi z modeli pri posameznih zmesih in celo v primerjavi z linearnim modelom.

4 RAZVOJ GROBEGA MODELA OBNAŠANJA ASFALTNIH ZMESI PRI VIŠJI TEMPERATURI

Asfaltne zmesi, ki se vgrajujejo v voziščne konstrukcije, morajo biti odporne proti nastanku trajnih deformacij in razpok, ki so posledica temperaturnih sprememb in utrujanja materiala. Poškodbe voziščnih konstrukcij, ki jih povzročajo različni vplivi, nimajo enakega vpliva na vse voziščne plasti in se lahko pojavljajo v različnih oblikah.

Med dinamične preiskave asfaltnih zmesi uvrščamo triosni preizkus, s katerim ugotavljamo odpornost asfaltne zmesi proti trajnemu preoblikovanju. Omenjena lastnost spada med osnovne tehnične lastnosti, ki napovedujejo obnašanje asfaltne zmesi (ang. performance-based). Test je med drugim namenjen razvrščanju asfaltnih zmesi in ugotavljanju njihove sprejemljivosti za uporabo na asfaltnih voziščih in je še posebej uporaben na obrabnih in veznih voziščnih plasteh, kjer je potrebna visoka odpornost proti nastanku trajnih deformacij. Z njim lahko v procesu načrtovanja asfaltne zmesi določimo optimalni delež bitumna v odvisnosti od največje odpornosti na trajne deformacije. Mnogo raziskovalcev se je ukvarjalo z razvojem triosnega testa in ugotavljalo njegove optimalne robne pogoje, ki bi čimbolje simulirali dejansko stanje na cestišču (Foo, 1994, Garba, 2002, Calderon Ulloa, 2009, Zang, Brown, Kandhal, West, 2005).

V Nemčiji so ob koncu prejšnjega tisočletja pričeli z uporabo novih tipov asfaltnih zmesi (SMA), kar je potegnilo za sabo tudi nove načine preizkušanja materiala, kamor spada tudi triosni preizkus. Ker običajne testne metode, ki se izvajajo za ugotavljanje odpornosti proti nastanku kolesnic, ne ločijo med konvencionalnimi in novejšimi asfaltnimi zmesmi, se sedaj na Nizozemskem uporablja triosni test (Huurman M., 2000, Erkens, 2002). Brown, Kandhal, Zhang (2001) in Tušar (2007) so opisali določanje lastnosti, temelječih na obnašanju in lastnosti, povezanih z obnašanjem, kar predstavlja nov pristop k preizkušanju asfaltnih zmesi. Med drugim so opisali tudi triosni test, ki spada med preizkuse temelječe na obnašanju. Huurman (2000) v svojem delu opisuje metodo za napovedovanje trajnih deformacij asfalta oz. kolesnic. V tej metodi so kot relevantni parametri obnašanja materiala uporabljeni podatki, ki so pridobljeni s triosnim testom. Pellinen, Song in Xiao (2004) so uporabili rezultate strižnega triosnega testa pri raziskovanju vpliva količine zračnih votlin na trdnostne parametre asfaltnih mešanic SMA in AC. Za pridobitev materialnih parametrov, ki so jih potrebovali pri numeričnem modeliranju, so izvedli dinamični strižni triosni test. Model so verificirali s podatki, pridobljenimi s preskusom tvorbe kolesnic. Analiza podatkov, dobljenih s pomočjo eksperimenta, je pokazala, da imata obe zmesi največjo kohezijo ter strižno trdnost, ko v zmesi ni zračnih por, ter da je asfaltna zmes SMA manj občutljiva na spreminjanje deleža zračnih votlin v zmesi. Glavni zaključek dela je, da pri asfaltnih zmesih z velikim deležem zračnih votlin (12 - 13 %) ne pride do zaklinjenja agregatnih zrn in s tem do preprečevanja strižnih deformacij. Prav tako sta se Zhi in Wing Gun (2009) ukvarjala z ugotavljanjem odpornosti proti nastanku trajnih deformacij asfaltnih zmesi, ki vsebujejo različne deleže zračnih votlin. Ugotovila sta, da je odpornost proti nastanku kolesnic največja pri vsebnosti zračnih votlin 4.5 % do 8 % pri obrabnih plasteh. Molenaar J.M.M. in Molenaar A.A.A. (2000) sta ugotavljala občutljivost na trajne deformacije asfalta s triosnim testom lezenja. Lezenje sta merila pod vplivom različnih oblik dinamične obtežbe in za različne velikosti preizkušancev. Pokazala sta, da je naklon krivulje lezenja odvisen od geometrije in se zato ne more pripisati lastnosti materiala. Možen vzrok temu je uporaba premajhnih preizkušancev v kombinaciji s trenjem med preizkušancem in ploščo, preko katere se prenaša obtežba. Prikazala sta tudi odvisnost krivulje lezenja od oblike obtežne krivulje. Halit, Atakan, Süreyya in Fazil (2008) so v svojem delu primerjali obnašanje treh asfaltnih zmesi, ki so sestavljene iz treh različnih polimernih bitumnov. Ugotovili so, da je vpliv polimernih bitumnov na večjo odpornost proti trajnim deformacijam v triosnem testu največji pri temperaturi 25 °C. Prav tako so dokazali, da je z vidika ocenjevanja primernosti testov za ugotavljanje trajnih deformacij vpliv sestave zmesi kamnitih zrn na trajno deformacijo večji od načina zgoščevanja asfaltne zmesi.

Obstaja kar nekaj študij glede odpornosti na trajne deformacije asfalta, ki temeljijo predvsem na oceni vplivov posameznih lastnosti sestavnih materialov asfaltnih zmesi (npr. vrsta bitumna in sejalne krivulje). Zaključki so različni in v nekaterih primerih tudi nasprotujoči. To pripisujemo predvsem temu, da obstajajo različni testi in različne ocene rezultatov trajnih deformacij, kar pomeni, da je zelo težko primerjati različne študije med sabo in izluščiti pomembne zaključke. Na trajno deformacijo asfalta vplivata konsolidacija in strig. V različnih virih je dokazano, da se asfalt pri nizkih temperaturah in pri večjih frekvencah obtežbe obnaša viskoelastično, pri višjih temperaturah in manjših frekvencah obremenjevanja, kjer je nastanek trajnih deformacij oz. kolesnic zelo pomemben, pa je njegovo obnašanje bolj kompleksno (visko - elasto - plastično) (Garba, 2002, Collop, Khanzada, 2001). Garba (2002) je v svoji doktorski disertaciji ugotavljal, kako bi se odpornost na trajne deformacije lahko vključila v samo načrtovanje asfaltnih zmesi. Definiral je indeks odpornosti na trajne deformacije, ki je občutljiv na volumenske spremembe sestave asfaltnih zmesi in predstavlja preprost način za oceno odpornosti proti nastanku kolesnic. Ugotovil je, da v primeru litih asfaltov oz. asfaltov, ki vsebujejo 3 % ali manj zračnih votlin, pride do velikega radialnega deformiranja in zato ima v takih primerih radialna oz. bočna deformacija zelo velik vpliv na kumulativno trajno deformacijo (kolesnico), v ostalih primerih, pri običajnih asfaltnih zmesih, kjer je delež votlin večji, pa je trajna kumulativna deformacija v večji meri odvisna od zgoščanja in ne toliko od strižne deformacije. Blab (2013) je v svojem delu ugotovil, da na občutljivost na trajne deformacije vpliva delež bitumna in pa vrsta uporabljenega agregata. Preizkušal je vezno asfaltno zmes AC 22 PmB25/45-65 z različnimi deleži bitumna in tremi različnimi vrstami kamnitega materiala. Ugotovil je, da je optimalni masni delež bitumna od 0.3 do 0.1 % manjši od deleža bitumna, ki ga določimo po tradicionalnem Marshallovem postopku. Tudi na Slovaškem so se začeli ukvarjati z lastnostmi asfaltnih zmesi, ki temeljijo na obnašanju. Remišova (2012) je analizirala občutljivost asfaltnih zmesi AC 11 in AC 11 PmB na trajne deformacije z vidika vsebnosti bitumna in debeline bitumenskega filma. Ugotovila je, da ima zmes, ki vsebuje polimerni bitumen, manjše deformacije v triosnem preizkusu.

Za določitev odpornosti proti trajnemu preoblikovanju asfaltnih vzorcev pri povišanih temperaturah smo naredili triosne teste na asfaltnih zmesih, ki se uporabljajo v Sloveniji, in preizkusi nastanka kolesnic (WTT). Ugotoviti želimo, kako sta testa med sabo povezana, če analiziramo osnovne vrste asfaltnih zmesi. Zanima nas torej t.i. grobi model obnašanja asfaltnih zmesi pri povišanih temperaturah, ki vsebujejo najmanj in največ zračnih votlin. Kriterij, po katerem smo izbrali vrste asfaltnih zmesi, ki so vključene v model, so sejalne krivulje. Torej želimo zajeti zgornjo in spodnjo mejno sejalno krivuljo. Beseda "grobi" se nanaša na obravnavo štirih osnovnih tipov asfaltnih zmesi, ki se običajno uporabljajo v Sloveniji: bitumenski beton (AC - Asphalt concrete), drobir z bitumenskim mastiksom (SMA - Stone mastic asphalt), liti asfalt (MA - Mastic asphalt) in drenažni asfalt (PA - Porous asphalt). MA in PA glede na sejalno krivuljo predstavljata spodnjo in zgornjo mejo, znotraj katerih se nahajajo ostale zmesi. To sta asfaltni zmesi, ki imata najmanjši in največji delež zračnih votlin. Poudarek je torej na grobem modelu, saj se nismo spuščali v notranjost, temveč smo zajeli osnovne sejalne krivulje, tudi zgornjo in spodnjo mejo, ki se uporablja v asfalterstvu.

Ugotoviti želimo, če je mogoče primerjati rezultate triosnega testa in preizkusa odpornosti proti nastanku kolesnic za štiri osnovne vrste asfaltnih zmesi ter poiskati grobi matematični model, ki bi opisal njuno zvezo. Triosni test je v standardu SIST EN 12697 - 25 predviden za kvalitativno oceno trajnih deformacij na vozišču. Naš trud je bil torej usmerjen ravno v to, da smo skušali kljub temu, da tega ni v osnovnem namenu standarda, kvantitativno določiti globino kolesnice preko triosnega testa.

Čeprav se po standardu ne zahteva več, smo za zmesi, ki smo jih uporabili pri modeliranju, izvedli tudi preizkus po Marshallu, saj spada med mehanske preizkuse in se izvaja pri enaki temperaturi kot preizkus odpornosti proti nastanku kolesnic. Pričakovali smo rezultate, ki bi

pomagali pri iskanju ustreznega modela. Poleg omenjenih treh mehanskih testov smo pri modeliranju upoštevali še lastnosti bitumna in lastnosti asfaltnih zmesi. Na tem mestu se moramo zavedati, da govorimo o izdelavi grobega modela, saj so v modeliranje vključene osnovne vrste asfaltnih zmesi in imamo majhno število eksperimentalnih podatkov. Vzrok za omejeno število preskusov je cena eksperimentalnega dela in tudi zahtevnost priprave preskušancev.

4.1 Materiali

4.1.1 Bitumen


V nalogi smo za izdelavo asfaltnih zmesi uporabili bitumen B20/30 in s polimeri modificiran bitumen PmB10/40-65. Na izbor tršega bitumna je vplivala asfaltna zmes MA, ki ima najmanj zračnih votlin in največji delež bitumna. Z namenom primerjave triosnega preizkusa in preizkusa odpornosti proti nastanku kolesnic so vse štiri osnovne zmesi sestavljene iz enakega bitumna (PmB10/40-65 oz. B20/30). V spodnji preglednici so prikazane lastnosti in njihove vrednosti za oba tipa bitumna.

Preglednica 29: Lastnosti bitumnov PmB10/40-65 in B20/30.
Table 29: Properties of bitumen binder PmB10/40-65 and B20/30.

Lastnost	Metoda	Vrednost	
		PmB10/40-65	B20/30
PK [°C]	EN 1427	75.1	62.9
Penetracija pri 25 °C [mm/10]	EN 1426	16.7	24
Indeks penetracije (IP)	EN 12591, pt B4	1.2	0
Gostota pri 25 °C [g/cm ³]	EN ISO 3838	1.033	1.0221
Pretrgališče po Fraassu [°C]	EN 12593	-9.9	-4.7
Elastični povratek pri 25 °C [%]	EN 13398	72	-
Duktilnost [cm]			
pri 25 °C	DIN 52 013:2007	53	35
pri 10 °C		26.95	-
pri 5 °C		9.43	-
Sila pri raztezanju [N]			-
pri 25 °C	EN 13398	20.47	-
pri 10 °C		106.43	-
pri 5 °C		183.27	-
Energija pri raztezanju [J/cm ²]			
pri 25 °C	EN 13398	1.97	-
pri 10 °C		17.22	-
pri 5 °C		8.26	-
Dinamična viskoznost pri 60 °C [Pa s]	EN 12596	-	2323

4.1.2 Agregat

Vse asfaltne zmesi, uporabljene za izdelavo grobega modela, so bile narejene iz agregata karbonatnega porekla (kamnolom Laže) in s premerom zrna agregata, ki se preseje skozi kvadratno odprtino sita z največjo velikostjo stranice 11 mm. Na sliki 17 so prikazane sejalne krivulje za vse 4 osnovne tipe asfaltov, med katerimi MA11 in PA11 predstavljata minimum in maksimum glede na vsebnost zračnih votlin.



Slika 17: Sejalne krivulje.
Figure 17: Particle size distribution curve.

4.1.3 Asfaltne zmesi

Z namenom izdelave grobega modela smo se odločili obravnavati štiri osnovne tipe asfaltnih zmesi: AC, SMA, PA in MA. Vse zmesi so sestavljene iz karbonatnega agregata z največjim premerom zrna 11 mm in so enkrat mešane z bitumnom B20/30 in drugič s polimernim bitumnom PmB10/40-65. Torej obravnavamo 8 asfaltnih zmesi in jih označimo takole: AC B20/30, AC PmB10/40-65, SMA B20/30, SMA PmB10-65, PA B20/30, PA PmB10/40-65, MA B20/30 in MA PmB10/40-60.

V preglednici 30 so prikazane vrednosti za vsebnost bitumna in zračnih votlin v posamezni asfaltni zmesi. Razvidno je, da imajo zmesi, ki vsebujejo polimerni bitumen, več zračnih votlin kot zmesi z navadnim cestogradbenim bitumnom. To je v skladu z večjo odpornostjo proti zgoščevanju asfaltnih zmesi s polimernim bitumnom, ki ima višjo točko zmehčiča v primerjavi z navadnimi cestogradbenim bitumnom (preglednica 29). Vendar pa v splošnem velja, da tudi, če sta točki zmehčiča polimernega bitumna (z SBS modifikatorjem) in navadnega cestogradbenega enaki, je vedno težje kompaktirati asfaltne zmesi, ki vsebujejo PmB.

Preglednica 30: Vsebnost bitumna, polnila, votlin in zapolnjenost votlin z bitumnom za posamezno asfaltno zmes.

Table 30: Binder content, filler content, air void content and voids filled with bitumen for different asphalt mixtures.

	Vsebnost bitumna (m/m) [%]	Vsebnost polnila (m/m) [%]	Vsebnost votlin (V/V) [%]	Zapolnjenost votlin z bitumnom [%]
Asfaltna zmes	EN 12697 - 1	EN 12697 - 2	EN 12697 - 8	EN 12697 - 8
AC	5.2	7.7	2.5	83.4
AC PmB	5.2	7.7	3.6	77.4
SMA	6.5	8.0	2.3	86.6
SMA PmB	6.5	8.0	2.9	83.5
PA	5.0	3.6	15.8	39.3
PA PmB	5.0	3.6	19.8	32.8
MA	7.0	27.2	1.5	91.6
MA PmB	7.0	27.2	1.9	89.7

4.2 Eksperimenti

4.2.1 Triosni eksperiment

Trajna deformacija, ki nastane pri triosnem testu, je močno odvisna od obtežbe, še posebej velik vpliv nanjo ima bočni pritisk ter trajanje in oblika obtežbe (Asphalt research program, 1994). Zato je zelo pomembna ustrezna ocena vpliva bočnega pritiska na cestišču ter temperaturnih in ostalih zunanjih pogojev. Glede na raziskave se največkrat upošteva konstantni bočni pritisk v kombinaciji z navpično obtežbo, saj ni razlik v primeru uporabe cikličnega bočnega pritiska. V eksperimentih, ki so predstavljeni v nadaljevanju, smo upoštevali bočne pritiske in temperaturo, kot jih narekujejo standardi SIST EN 12697 - 25 in SIST EN 13108.

Dinamična naprava s triosno celico, ki jo imamo na voljo, se uporablja za namene produktnih standardov. To pomeni, da je zaradi lažje izvedbe testa triosna celica manjša in omogoča uporabo valjastih vzorcev, ki so pripravljene z udarnim zgoščevalnikom, in je njihovo razmerje med višino in premerom $h/d=0.6$. Zaradi robnega efekta naj bi bilo razmerje $h/d=2$, vendar so tudi Foo (1994) ter Mallick, Ahlrich in Brown (1995) v svojem delu ugotovili, da robni efekt nima bistveno večjega vpliva na trajne deformacije, če se zaradi lažje izvedbe testa uporablja vzorce, ki imajo razmerje $h/d=0.6$. Glede na standard SIST EN 12697 - 25, metoda B, po katerem smo preiskavo izvajali, se za merilo trajne deformacije uporablja enoosna kumulativna deformacija ϵ_n ali pa stopnja lezenja f_c , ki po mnenju več raziskovalcev nista dobra parametra, ker sta izračunana na osnovi enoosne navpične deformacije in nista občutljiva na spremembe v volumski sestavi asfaltnih zmesi, ki so narejene iz enakih materialov in različnih deležev votlin in bitumna (Garba, 2002). Vendar se za komercialne namene in za običajne zmesi kumulativno trajno deformacijo določa le v navpični smeri, saj smo že prej omenili, da ima pri običajnih zmesih večji vpliv na kumulativno trajno deformacijo zgoščevanje in ne strižno deformiranje. V Nemčiji za ugotavljanje odpornosti proti trajnim deformacijam za asfaltno zmesi SMA in AC, ki se običajno največ vgrajujejo v obrabne plasti, uporabljajo enoosni ciklični tlačni preizkus, ki je enostavnejša oblika triosnega testa, saj se postavi bočni pritisk na 0. Ravno tako ga izvajajo po standardu EN 12697 - 25, le da ločijo

med enoosnim cikličnim tlačnim testom z bočnim pritiskom in brez bočnega pritiska. Omenjene zmesi preizkušajo brez bočnega pritiska in upoštevajo manjše navpične obtežbe, ki so prilagojene testnim pogojem. Na ta način se izognejo večjim radialnim deformacijam in si s tem zagotovijo, da preiskujejo lastnost, ki je povezana z obnašanjem materiala in se ne ukvarjajo s stabilnostnim problemom samega vzorca (Roos, Karcher, 2009).


Potek preizkusa:

Asfaltni preizkušanelec vstavimo v triosno celico med dve kovinski plošči premera $d = 100$ mm, da ga lahko čim bolj natančno centralno namestimo. Statični bočni in osni ciklični pritisk, ki sta potrebna za test, proizvaja servo hidravlični sistem aparature. Celico postavimo na spodnjo nosilno ploščo, na kateri je pritrjeno tudi držalo za senzorja, s katerima merimo navpični pomik tlačne plošče. Na obodu triosne celice je pritrjena zračna membrana, ki se ob dovajanju zraka napihne. Shematski prikaz triosnega preizkusa in haversinusoidne obtežbe sta prikazana na slikah 18 in 19. Pred pričetkom testa se vzorec za 2 minuti predobremeni s statično obtežbo, ki je enaka: $0.02 (2\sigma_v + \sigma_c)$. Sledi obremenitev s konstantnim pritiskom $\sigma_c = 0.15$ MPa, v navpični smeri pa z dinamično haversinusoidno osno obtežbo σ_a . Teža zgornje plošče se upošteva kot konstantna predobtežba 19 N v navpični smeri in se ustrezno odšteje od σ_c . Konstantni pritisk σ_c okrog vzorca povzroči zrak, ki se dovede v zračnico. V odvisnosti od števila ciklov obremenjevanja se meri sprememba višine vzorca oz. se izrisuje deformacijska krivulja. Dolžina cikla je 1 s, od tega traja 0.6 s faza obtežbe in 0.4 s faza mirovanja na nivoju konstantnega pritiska σ_c . Rezultantna osna obremenitev vzorca σ_A je:

$$\sigma_c + \sigma_a(t) = \sigma_c + \sigma_v(1 + \sin(2\pi f t)), \quad (52)$$


kjer je:

- σ_c ... konstantni pritisk,
- $\sigma_a(t)$... ciklična osna obremenitev v odvisnosti od časa,
- σ_v ... amplituda haversinusoidne obtežbe ($\sigma_v = 0.30$ MPa),
- f ... frekvenca ($f = 2.5$ Hz),
- t ... čas.




Slika 18: Shematski prikaz haversinusoidne ciklične obtežbe vzorca.

Figure 18: Schematic representation of haversinusoidal cyclic load of the specimen.



Slika 19: Shematski prikaz triosnega preizkusa (SIST EN 12697 - 25).
Figure 19 Schematic representation of the triaxial test (SIST EN 12697 - 25).


Cilindrični preizkušanci ($d = 100$ mm, $h = 60$ mm) so bili pripravljene v laboratoriju z udarnim kompaktorjem (SIST EN 12697 - 30) in so prikazani na sliki 20a. Razmerje višina/premer vzorcev je v našem primeru 0.6 (odvisno od zrnivosti zmesi; standard SIST EN 12697 - 25, metoda B), testna temperatura je 50 °C (standard prEN 13108 - 20) za vse štiri tipe zmesi. Konstantna temperatura je zagotovljena z uporabo temperaturne komore, kamor se postavi triosna celica (slika 20b, 20c).



Slika 20: a) Pripravljena vzorca za triosni preizkus, b) triosna celica ter c) temperaturna komora in računalnik, preko katerega se vodi preizkus.

Figure 20: a) Specimens for the triaxial test, b) triaxial cell and c) temperature chamber and computer.

Odpornost proti nastanku trajnih deformacij se določi na podlagi krivulje tečenja (deformacijska krivulja), ki je prikazana na sliki 21. Abscisna os predstavlja število ciklov obremenjevanja, na ordinatni osi pa so prikazane kumulativne deformacije ϵ_n , ki se za vsak obtežbeni cikel izračunajo po enačbi (53). V začetnem območju naklon krivulje pada z naraščanjem števila ciklov, v območju 2 je naklon krivulje približno konstanten in vsebuje prevojno točko (A), v zadnjem delu (3) pa naklon krivulje narašča z večanjem števila ciklov.



Slika 21: Primer krivulje tečenja.
Figure 21: An example of flow curve.

Modeli za določevanje odpornosti na trajne deformacije običajno upoštevajo odnos med navpično kumulativno deformacijo in številom ciklov, v katerih nastane kumulativna deformacija:

$$\varepsilon_n = 100(h_0 - h_n) / h_0, \quad (53)$$

kjer je:

ε_n ... kumulativna osna deformacija,
 h_0 ... višina vzorca po predobtežbi,
 h_n ... višina vzorca po n ciklih.

Glede na standard SIST EN 12697 - 25 se določi parametre deformacijske krivulje na naslednja dva načina:

a) Določitev stopnje lezenja f_c :

Če obstaja linearno območje 2, se deformacijsko krivuljo aproksimira z linearno funkcijo:

$$\varepsilon_n = A_1 + B_1 n_1, \quad (54)$$

kjer B_1 predstavlja naklon linearnega dela krivulje in se izračuna po metodi najmanjših kvadratov za linearno območje na deformacijski krivulji. Nato določimo stopnjo lezenja f_c :

$$f_c = B_1 10^4, \quad (55)$$

ki je izražena v [$\mu\text{m}/\text{m}/\text{cikel}$].

Opisan način je enostaven, vendar slabo opiše deformacijsko krivuljo. Naklon f_c je namreč v veliki meri odvisen od izbora intervala, kjer aproksimiramo krivuljo z linearno funkcijo, saj v splošnem ne obstaja območje na deformacijski krivulji z resnično konstantnim naklonom.

b) Določitev parametrov B in $\varepsilon_{1000, \text{calc.}}$:

Določi se najmanjše kvadrate odstopanja eksponentne aproksimacije (kvazi) linearne območja na deformacijski krivulji:

$$\varepsilon_n = A n^B, \quad (56)$$


kjer je ϵ_n kumulativna osna deformacija, ki nastane zaradi navpične dinamične obtežbe, B pa je parameter, določen po metodi najmanjših kvadratov. Sledi izračun trajne deformacije po 1000 ciklih obremenjevanje $\epsilon_{1000,calc.}$:

$$\epsilon_{1000,calc.} = A 1000^B. \quad (57)$$

4.2.1.1 Rezultati

Triosni test smo izvedli za štiri osnovne tipe asfaltnih zmesi in dva tipa bitumna (B20/30 in PmB10/40-65) z namenom izdelave grobega modela obnašanja asfaltne zmesi pri ciklični obremenitvi, ki imajo najmanjši in največji delež zračnih votlin (od t.i. najbolj zaprtih do najbolj odprtih asfaltnih zmesi). Na tem mestu je potrebno omeniti, da je bil triosni preizkus na slovenskih asfaltnih mešanica narejen prvič.

Slika 22 prikazuje deformacijske krivulje v odvisnosti od števila obtežnih ciklov. Opazi se, kar je tudi pričakovano, da je asfaltna zmes MA daleč stran od ostalih zmesi in da se asfaltne zmesi, ki vsebujejo polimerni bitumen, bolje obnašajo pri ciklični obtežbi kot zmesi z navadnim bitumnom.



Slika 22: Deformacijske krivulje za različne asfaltne zmesi, dobljene s triosnim preizkusom.
Figure 22: Deformation curves of triaxial test for different types of asphalt.

4.2.1.2 Ponovljivost rezultatov triosnega preizkusa

Ponovljivost določitve vrednosti trajne deformacije ϵ s triosnim testom je bila določena z večkratnim zaporednim merjenjem trajne deformacije ϵ pri različnem številu ciklov in za tri različne vrste asfaltnih zmesi pri enakih pogojih. Za analizo vpliva je bila uporabljena enofaktorska analiza variance ANOVA (poglavje 2.2.1). V nadaljevanju je podana ničelna hipoteza H_0 in pripadajoča alternativna hipoteza H_A :

H_0 : vrsta asfaltne zmesi nima vpliva na vrednosti ε ,

H_A : vrsta asfaltne zmesi ima vpliv na vrednosti ε .

Vrednosti ε so določene za tri različne vrste asfaltnih zmesi pri štirih različnih številih ciklov obremenjevanja.

V preglednici 31 so prikazane vrednosti ε za različne vrste asfaltnih zmesi pri različnem številu ciklov n in za tri ponovitve ter vrednosti za F in F_{krit} .

Preglednica 31: Vrednosti trajne deformacije ε za različne vrste asfaltnih zmesi pri različnem številu ciklov n in vrednosti za F in F_{krit} .

Table 31: Values of permanent deformation ε at different cycles n for different types of asphalt mixtures and values for F and F_{krit} .

Asfaltna zmes	$n = 1000$ ε [%]			$n = 2500$ ε [%]			$n = 5000$ ε [%]			$n = 10000$ ε [%]		
	1	2	3	1	2	3	1	2	3	1	2	3
AC 16 PmB 45/80-65	0.36	0.33	0.33	0.39	0.37	0.35	0.40	0.40	0.38	0.42	0.42	0.40
SMA 11 PmB 10/40-65	0.27	0.27	0.27	0.29	0.29	0.29	0.31	0.31	0.31	0.34	0.32	0.33
AC 11 B20/30	0.43	0.48	0.46	0.48	0.55	0.51	0.51	0.57	0.54	0.54	0.61	0.58
F	72.20			78.12			95.87			101.57		
F_{krit}	5.14			5.14			5.14			5.14		

Rezultati enofaktorske ANOVE so prikazani v preglednici 32. Oznaka F predstavlja vrednost statistike F v primeru analize vpliva vrste asfaltne zmesi na vrednosti ε . Analogno predstavlja F_{krit} kritično vrednost F glede na tveganje α , za katerega smo izbrali vrednost $\alpha = 0.05$. SS , df , MS in P predstavljajo vsoto kvadratov, prostostne stopnje, povprečne kvadrate in vrednost P . Če $F > F_{krit}$, je ničelna hipoteza H_0 zavrnjena. To pomeni, da ima vrsta asfaltne zmesi statistično značilen vpliv na vrednosti ε . Posledično so razlike med vrednostmi ε , ki nastanejo zaradi treh ponovitev vsake vrste asfaltne zmesi pri enakem številu ciklov obtežbe, manjše od razlik med temi vrednostmi, ki so posledica različnih vrst asfaltnih zmesi.

V vseh primerih so vrednosti testne statistike F večje od pripadajoče kritične vrednosti F_{krit} , ki je določena pri $\alpha = 0.05$. Od tod sledi, da so vse vrednosti ε odvisne od vrste asfaltne zmesi.

Preglednica 32: Rezultat enofaktorske analize variance za $n = 10000$.

Table 32: The result of single factor analysis of variance at $n = 10000$.

Izvor variabilnosti	SS	df	MS	F	P - vrednost	F_{krit}
Med asf. zmesmi	0.0959	2	0.048	101.57	2.36E - 05	5.143
Znotraj asf. zmesi	0.00283	6	0.000472			
Skupaj	0.0988	8				

4.2.2 Preizkus nastajanja kolesnic (WTT - Wheel tracking test)


Določanje globine kolesnic v asfaltni plasti je preiskava določanja odpornosti proti trajnim deformacijam pri povišani temperaturi. Preizkus nastajanja kolesnice je bil izveden v skladu s standardom SIST EN 12697 - 22 (mala naprava na zraku - postopek B). Za vse asfaltne zmesi so bili vzorci pripravljeni v laboratoriju. Zaradi testiranja zmesi z maksimalno velikostjo zrna 11 mm je debelina vzorcev 40 mm. Vzorce vpneemo v kalupe tako, da je njihova zgornja površina v istem nivoju kot površina kalupa. Test je izveden pri konstantni temperaturi 60 °C.

Ta temperatura je zahtevana v slovenskih nacionalnih specifikacijah. Kalup z vzorcem vstavimo v napravo, kot je prikazano na sliki 23. Obtežbo predstavlja kolo z gumo, ki je zunanje premera med 200 mm - 205 mm, pravokotnega prereza debeline 50 mm in je postavljeno na sredino vzorca ter pravokotno na njegovo površino. Vzorec ciklično obremenimo z 20000 prehodi kolesa (oz. 10000 cikli). Na sredini merimo globino kolesnice *RD* in stopnjo naraščanja kolesnice *wts*:

$$wts = \frac{(d_{10000} - d_{5000})}{5}, \quad (58)$$

kjer je:


d_{10000} ... globina kolesnice po 10000 ciklih in
 d_{5000} ... globina kolesnice po 5000 ciklih.



Slika 23: Naprava za ugotavljanje globine kolesnice.
 Figure 23: Wheel tracking test device.

4.2.2.1 Rezultati

Slika 24 prikazuje krivulje trajnih deformacij vzorcev asfaltnih zmesi v odvisnosti od števila ciklov obremenjevanja. Podobno kot pri triosnem testu je tudi tukaj pričakovano trajna deformacija za asfaltno zmes MA daleč stran od ostalih. Zelo podobni deformacijski krivulji pa imata zmesi AC PmB10/40-65 in SMA PmB10/40-65.




Slika 24: Deformacijske krivulje za različne asfaltne zmesi, dobljene s preizkusom ugotavljanja globine kolesnice (WTT).

Figure 24: Deformation curves of wheel tracking test for different types of asphalt.

4.2.3 Preizkus po Marshallu


S preizkusom po Marshallu se v asfaltni dejavnosti določijo t.i. stabilnost, tečenje in Marshallov kvocient za asfaltne vzorce. Preizkus se izvaja v skladu s standardom SIST EN 12697 - 34. Glede na to, da se test izvaja pri enaki temperaturi kot WTT, smo pričakovali rezultate, ki bi jih lahko vključili v modeliranje. V preteklosti se je test izvajal v sklopu kontrole kakovosti predvsem za AC zmesi, po novih evropskih standardih za specifikacijo asfaltnih zmesi (EN 13108) pa se izvaja le še za asfaltne zmesi, ki se vgrajujejo na letališčih. To je tudi razlog, da preiskava ni več rutinska in zato nimamo rezultatov meritev za vse asfaltne zmesi, ki smo jih uporabili za validacijo modelov in za njihovo razširitev.

Valjasti vzorci so pripravljani v skladu s standardom SIST EN 12697 - 30 (Marshallov postopek, kjer se preizkušance izpostavi 100 udarcem nabijala). Po predhodnem temperiranju v vodi se vzorce obremenjuje v stiskalnici s konstantno hitrostjo stiskanja 50 mm/min do porušitve (slika 25). Stabilnost S je na področju asfaltnega definiran kot maksimalna sila, ki jo še lahko prenese vzorec. Tečenje F je definirano kot razdalja med točkama A in S', kjer točka A označuje sečišče tangente na deformacijsko krivuljo in abscisno osjo, točka S' pa predstavlja deformacijo vzorca, ki ustreza maksimalni sili S . Marshallov kvocient je razmerje med stabilnostjo S in tečenjem F (slika 26a).



Slika 25: Naprava za izvajanje preizkusa po Marshallu.
Figure 25: Marshall test device.

Na tem mestu je potrebno poudariti, da je za vzorce asfaltne zmesi SMA težko določiti največjo silo S . To najbolj vpliva na natančnost določitve tečenja F . Na sliki 26 se vidi, da je najbolj ponovljiv najstrmejši del krivulje (sila - pomik). Zato za modeliranje uporabimo namesto tečenja F t.i. tangencialno tečenje F_t , ki se določi iz naklona krivulje in je bolj zanesljiv parameter. Posledično smo namesto Marshallovega kvocienta (S/F) uporabili kvocient S/F_t .



Slika 26: a) Prikaz definicije stabilnosti, tečenja in Marshallovega kvocienta, b) Tipičen rezultat Marshallovega testa za SMA asfaltno zmes.

Figure 26: a) Definition of stability, flow and Marshall quotient, b) A typical result of Marshall test for asphalt mixtures SMA.

Rezultati preizkusa po Marshallu so prikazani v preglednici 33.


4.2.4 Primerjava treh mehanskih testov asfaltnih zmesi

Zaradi velikih trajnih deformacij zmesi MA, ki vsebuje cestogradbeni bitumen, sta se triosni preizkus in preizkus nastajanja kolesnic ustavila pred koncem testa, zato te zmesi ne vključimo v modeliranje. Iz slik 27 in 28 je razvidno, da rezultata za asfaltno zmes MA, ki vsebuje polimerni bitumen, bistveno odstopata od vrednosti obeh testov za preostale zmesi. Preglednica 33 prikazuje rezultate mehanskih testov asfaltnih plasti.

Preglednica 33: Rezultati mehanskih preiskav asfaltnih zmesi.
Table 33: Results of mechanical tests of asphalt mixtures.


	S	F_t	S/F_t	Trajna defor. (ϵ_{10000})	Maks. defor.	Proporc. glob. koles.	wt_s
	[kN]	[mm]	[kN/mm]	[%]	[mm]	[%]	[mm/1000]
Metoda EN 12697	34	34	34	25	25	22	22
AC	17.6	2.5	7	0.577	0.367	5.44	0.059
AC PmB	20.4	2	10.2	0.505	0.322	2.87	0.026
SMA	11.3	1.4	8	0.442	0.285	4.73	0.046
SMA PmB	13.7	1.8	7.9	0.329	0.210	2.87	0.028
PA	8.4	1.1	7.9	0.799	0.487	4.11	0.046
PA PmB	8.9	1.5	5.9	0.569	0.352	3.16	0.031
MA PmB	20.9	4.9	4.3	2.657	1.646	35.5	0.785
MA	21.4	3.4	6.3	4.292 (1000 ciklov)	2.637 (1000 ciklov)	39.6 (2500 ciklov)	-

Rezultate triosnega preizkusa in WTT testa smo grafično predstavili na slikah 27 in 28. Iz slike 28 je razvidno, da so asfaltne zmesi, ki vsebujejo polimerni bitumen bolj odporne proti nastanku kolesnic od zmesi, ki vsebujejo cestogradbeni bitumen. Presenetljivo sta obe asfaltni zmesi SMA (s polimernim bitumnom PmB10/40-65 in cestogradbenim bitumnom B20/30) bolj odporni proti trajni deformaciji v triosnem testu od ostalih asfaltnih zmesi (slika 27). Iz preglednice 33 vidimo, da vrednosti tangencialnega tečenja F_t za zmesi, ki vsebujejo PmB niso vedno nižje od vrednosti pri asfaltni zmesih, ki vsebujejo cestogradbeni bitumen B. Iz tega lahko zaključimo, da ne obstaja vedno preprosta povezava med uporabo polimernega bitumna in cestogradbenega bitumna.



Slika 27: Trajna deformacija (ϵ_{10000}), dobljena iz triosnega preizkusa, za sedem asfaltnih zmesi.

Figure 27: Permanent deformation (ϵ_{10000}) of triaxial test for seven asphalt mixtures.




Slika 28: Proporcionalna globina kolesnice za sedem asfaltnih zmesi.

Figure 28: Proportional rut depth for seven asphalt mixtures.

4.3 Modeliranje


V modeliranje smo vključili sedem asfaltnih zmesi: AC 11 B20/30, AC 11 PmB10/40-65, SMA 11 B20/30, SMA 11 PmB10/40-65, PA 11 B20/30, PA 11 PmB10/40-65 in MA 11 PmB10/40-65. Zmesi MA 11 B20/30 nismo vključili v modele, ker po pričakovanjih ne izkazuje odpornosti proti trajnim deformacijam, saj je pri obeh mehanskih testih (WTT in triosni test) zelo hitro prišlo do prevelikih deformacij in s tem do ustavitve preizkusa. Najprej smo skušali ugotoviti neposredno povezanost med preizkusom ugotavljanja odpornosti proti nastanju kolesnic in triosnim testom. Preverili smo preprosto linearno povezavo med trajnima

deformacijama (ϵ_{10000}), dobljenima iz obeh testov. Izračunan determinacijski koeficient med testoma je bil izredno visok. Nadaljnja analiza je pokazala, da je taka korelacija posledica velike oddaljenosti zmesi MA PmB od ostalih zmesi. To je pričakovan rezultat, saj zmes MA v asfalterstvu predstavlja zelo zaprto zmes (predstavlja t.i. ekstrem) in se po svojih lastnostih in uporabi močno razlikuje od ostalih zmesi (slika 33). Iz slike 29b je razvidno, da za uporabljeni merilni napravi za izvedbo triosnega testa in WTT ter za dane oblike in velikosti vzorcev ni neposredne linearne povezave, ampak je potrebno upoštevati druge lastnosti asfaltnih zmesi in bitumna. Ker predvidevamo, da v določenih primerih obstaja linearna povezava med triosnim testom in WTT, smo izključili še zmesi PA in PA PmB, saj iz slike 29b razberemo, da sta ti dve zmesi naslednji, ki poslabšujeta korelacijo med testoma. Tudi to je v skladu s pričakovanji, saj je porozni asfalt PA druga ekstremna zmes glede na sejalno krivuljo (slika 17). Če torej upoštevamo samo zmesi AC, AC PmB, SMA in SMA PmB, smo ugotovili, da je glede na naše število podatkov in uporabljeni aparaturi za izvedbo obeh testov neposredna linearna povezava med testoma $r^2 = 0.375$ (slika 30).



Slika 29: Linearna povezava proporcionalne globine kolesnice in trajne deformacije, dobljene s triosnim testom: a) model z zmesjo MA PmB; b) model brez zmesi MA PmB.


Figure 29: Linear correlation between proportional rut depth and permanent deformation of triaxial test: a) model with mixture MA PmB; b) model without mixture MA PmB.



Slika 30: Linearna povezava proporcionalne globine kolesnice in trajne deformacije, dobljene s triosnim testom brez zmesi PA, PA PmB, MA in MA PmB.

Figure 30: Linear correlation between proportional rut depth and permanent deformation of triaxial test without mixtures PA, PA PmB, MA and MA PmB.

Na tem mestu je potrebno omeniti, da v literaturi nismo našli primerjave med triosnim testom in WTT, ki bi bila opravljena z enakimi napravami, pri enakih pogojih in za enake testne materiale, kot smo jih uporabili mi. Zato neposredne primerjave med dobljenimi rezultati našega dela in dela ostalih avtorjev nimamo. Za primer lahko navedemo korelacijo med stopnjo lezenja f_c pri triosnem testu in hitrostjo naraščanja deformacije wts pri preizkusu nastajanja kolesnic, ki so jo v svojem delu določili Gardete in sodelavci (2005). Testa so izvedli pri temperaturi 45 °C za tri asfaltne zmesi, ki so sestavljene iz apnenčastega agregata in vsebujejo različne količine bitumenskega veziva (3.7 %, 4.2 % in 4.7 %). Pri primerjavi vrednosti za korelacijo med stopnjo lezenja f_c pri triosnem testu in hitrostjo naraščanja deformacije (wts) v WTT smo dobili enako vrednost in sicer 0.7 (slika 31), pri čemer smo pri linearnem modelu upoštevali 4 asfaltne zmesi (AC, AC PmB, SMA in SMA PmB).



Slika 31: Korelacija med stopnjo lezenja f_c pri triosnem testu in hitrostjo naraščanja deformacije (wts) v WTT.

Figure 31: Correlation between creep rate f_c of triaxial test and wheel - tracking slope (wts).


PCA metodo smo uporabili za ugotavljanje korelacij med izmerjenimi lastnostmi (preglednica 34), posredno pa tudi za ugotavljanje podobnosti med asfaltnimi zmesmi in za zmanjšanje števila parametrov pri modeliranju.

Preglednica 34: Vrednosti lastnosti asfaltnih zmesi, ki so uporabljene pri računu z metodo glavnih komponent.

Table 34: The values of the properties of asphalt mixtures which were used in principal component analysis.

Lastnost	Asfaltna zmes						
	AC	AC PmB	SMA	SMA PmB	PA	PA PmB	MA PmB
Proporc. glob. koles. [%]	5.44	2.87	4.73	2.87	4.11	3.16	35.51
Trajna defor. (ϵ_{10000}) [%]	0.58	0.50	0.44	0.33	0.80	0.57	2.66
Delež bitumna [%]	5.2	5.2	6.5	6.5	5.0	5.0	7.0
Sito 0.063 [%]	7.7	7.7	8.0	8.0	3.6	3.6	27.2
Sito 0.09 [%]	8.5	8.5	8.8	8.8	3.9	3.9	29.6
Sito 0.25 [%]	12.9	12.9	10.6	10.6	5.0	5.0	34.3
Sito 0.71 [%]	21.8	21.8	13.4	13.4	6.7	6.7	40.3
Sito 2 [%]	41.5	41.5	19.8	19.8	10.7	10.7	53.5
Sito 4 [%]	58.9	58.9	31.2	31.2	15.9	15.9	67.0
Sito 8 [%]	78.8	78.8	54.7	54.7	25.5	25.5	82.7
Sito 11.2 [%]	95.3	95.3	95.1	95.1	90.9	90.9	96.2
Prostor. gost. [kg/m^3]	2428	2404	2372	2361	2088	1992	2382
Največja gost. [kg/m^3]	2491	2495	2429	2433	2480	2483	2428
Vseb. zrač. votl. [%]	2.5	3.6	2.3	2.9	15.8	19.8	1.9
Stop. zapol. votl. [%]	83.4	77.4	86.6	83.5	39.3	32.8	89.7
Votl. v kam. mat. [%]	14.8	15.8	17.4	17.8	26.0	29.4	18.0
S [kN]	17.6	20.4	11.3	13.7	8.4	8.9	20.9
F [mm]	5.7	6.5	2.9	9.6	3.0	2.9	8.5
S/F [kN/mm]	3.1	3.3	3.9	1.5	2.9	3.1	2.5
F_t [mm]	2.5	2.0	1.4	1.8	1.1	1.5	4.9
S/ F_t [kN/mm]	7.0	10.2	8.0	7.8	7.9	5.9	4.3
PK [°C]	62.9	75.1	62.9	75.1	62.9	75.1	75.1
Pen. [mm/10]	24	16.7	24	16.7	24	16.7	16.7
Duktilnost [cm]	35	23.8	35	23.8	35	23.8	23.8


Na sliki 33 vidimo, katere asfaltne zmesi so si med sabo podobne. Glede na sejalne krivulje sta si med sabo bolj podobni asfaltni zmesi AC in MA ter SMA in PA (slika 32). Zmesi SMA in AC pa imata med sabo dve ključni podobnosti, in sicer vsebnost votlin in delež bitumna. In ravno ta dva parametra očitno bolj vplivata na lastnosti kot pa sejalne krivulje, saj se zmesi AC in SMA nahajta precej blizu na sliki 33. In od tu lahko v splošnem sklepamo, da lastnosti bitumna prevladujejo nad lastnostmi agregata. Na sliki 32 sta grafično prikazana struktura in princip obnašanja osnovnih asfaltnih zmesi. Liti asfalt ima zelo velik delež bitumna in zato je bitumen tisti, ki prenaša obtežbo. Asfaltna zmes AC deluje po principu betona, saj je gosta zmes zrn kamnitega materiala ovita s tankim bitumenskim ovojem in zato pri prenosu obtežbe sodelujeta tako kamniti material kot bitumen. Pri zmesih SMA in PA pa se obtežba prvotno prenaša s kamnitimi zrni, saj se le-ta pod obtežbo močno stisnejo in zaklinijo.



Slika 32: Grafični prikaz osnovne strukture in principa obnašanja asfaltnih zmesi (Partl, Chailleux, 2013).

Figure 32: Graphical representation of the basic structure and behaviour of the asphalt mixtures (Partl, Chailleux, 2013).


Modele smo pripravili brez MA PmB, saj je za model zanimivo le tisto območje, kjer se nahaja največ točk na sliki 29a.



Slika 33: Prikaz vrste asfaltnih zmesi po metodi glavnih komponent (PCA) (diagram asfaltnih zmesi).


Figure 33: Principal component analysis (PCA) for different types of asphalt mixtures (score plot).

Na sliki 34 so prikazane lastnosti asfaltnih zmesi glede na prvi dve glavni osi Φ_1 in Φ_2 metode glavnih komponent, ki opišeta približno 80 % celotne variance podatkov. Slika 35 pa prikazuje lastnosti asfaltnih zmesi glede na glavni osi Φ_1 in Φ_3 . Vidimo, da so na obeh slikah lastnosti porazdeljene bolj po prvi glavni osi Φ_1 , kar pomeni, da glavna os Φ_3 ne vpliva bistveno na varianco lastnosti in lahko za pripravo grobih modelov izberemo vhodne parametre glede na sliko 34.



Slika 34: Prikaz lastnosti asfaltnih zmesi po metodi glavnih komponent (PCA) v koordinatnem sistemu Φ_1 in Φ_2 (diagram lastnosti).

Figure 34: Principal component analysis (PCA) in the coordinate system Φ_1 and Φ_2 for properties of asphalt mixtures (loading plot).



Slika 35: Prikaz lastnosti asfaltnih zmesi po metodi glavnih komponent (PCA) v koordinatnem sistemu Φ_1 in Φ_3 (diagram lastnosti).

Figure 35: Principal component analysis (PCA) in the coordinate system Φ_1 and Φ_3 for properties of asphalt mixtures (loading plot).

Za pripravo čimboljših modelov smo v modeliranje vključili še podatke o sestavi asfaltnih zmesi in mehanske podatke iz Marshallovega preizkusa. Omenjene podatke smo izbrali glede na rezultate metode glavnih komponent (slika 34). Tiste točke, ki na sliki 34 ležijo blizu, imajo podoben vpliv na rezultat, zato smo izbrali le eno izmed njih. Za primere, ko manjka kateri od rezultatov meritev ali da nismo prepričani v njegovo natančnost (npr. meritev stabilnosti ni več rutinska preiskava in zato se poslabša ponovljivost izvajanja preiskave), smo pripravili več različnih modelov, ki vsebujejo različne parametre (preglednica 36).

Za izbor ustreznega modela in kasneje za njegovo validacijo imamo štiri kriterije:

- metoda glavnih komponent (PCA);
- število vhodnih parametrov;
- metoda leave-one-out (LOO), ki predstavlja notranjo validacijo modela;
- zunanja validacija modela oz. interpolacija (preizkus modela na asfaltni zmesi, ki ni bila vključena v model, vendar je sestavljena iz enakih materialov kot asfaltne zmesi, ki so vključene v model).

Prvi kriterij (metodo PCA) smo že komentirali, drugi kriterij pa se nanaša na število vhodnih podatkov pri modeliranju. Pomembno je, da imamo manj vhodnih parametrov od števila zmesi, ki jih vključimo v modeliranje, saj s tem preprečimo predoločen sistem enačb. Tretji in četrti kriterij sta opisana v nadaljevanju.

Preglednica 35: Pomen oznak, ki so uporabljene v modelih.

Table 35: Symbols used in models.

Oznaka	Lastnost
y	proporcionalna globina kolesnice iz WTT
x_2	trajna deformacija iz triosnega testa
x_3	PK bitumna
x_4	delež bitumna
x_5	presejek skozi sito velikosti 0.063 mm (filer)
x_6	presejek skozi sito velikosti 2 mm (točka peska)
x_7	vsebnost zračnih votlin
x_8	S/F_t
x_9	največja gostota asfaltne zmesi

Glede na pomen oznak v zgornji preglednici, so v preglednici 36 izpisani modeli, njihovi determinacijski koeficienti in napake.

Preglednica 36: Modeli, r^2 in RMSE.

Table 36: Models, r^2 and RMSE.


Model	r^2_{modela}	RMSE _{modela}
1. $y = a_1 x_2 + b$	0.096	0.93
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.978	0.15
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.895	0.32
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.893	0.32
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.945	0.23
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.940	0.24
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.995	0.07
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.957	0.20

Iz preglednice 36 je razvidno, da imajo modeli visoke korelacijske koeficiente, razen prvega modela, ki opisuje neposredno povezavo med WTT in triosnim testom. Pričakovali smo večjo korelacijo med testoma. Vzroki za manjšo korelacijo od pričakovane so lahko različne priprave preskušancev, različne izvedbe obremenitve ter za 10 °C različna temperatura preskusa. Model smo poskusili izboljšati z dodatnimi parametri, ki smo jih izbrali glede na metodo PCA in so upoštevani v ostalih modelih.

4.3.1 Validacija modela

4.3.1.1 Material v validacijskih zmesih

Za validacijo modela smo uporabili t.i. manj hrupni asfaltni zmesi SMA, in sicer SMA 11 B20/30 LN in SMA 11 PmB10/40-65 LN. Za omenjeni asfalt je značilno, da glede na sejalno krivuljo (slika 36) in samo sestavo (preglednica 37) leži med zmesema SMA in PA. Manj hrupni asfalt izkazuje dobro odpornost proti trajnemu preoblikovanju pri povišanih temperaturah, slabše pa se obnaša pri nizkih temperaturah, saj ima manj stične površine med agregatnimi zrnji in vezivom. Bitumen in kameni material, ki sestavljata validacijski zmesi, sta enaka kot pri zmesih, uporabljenih za izdelavo grobega modela.



Slika 36: Sejalna krivulja asfaltne zmesi SMA LN.

Figure 36: Particle size distribution curve for asphalt mixture SMA LN.

Preglednica 37: Vsebnost bitumna, polnila, votlin in zapolnjenost votlin z bitumnom za asfaltni zmesi SMA LN in SMA LN PmB.

Table 37: Binder content, filler content, air void content and voids filled with bitumen for asphalt mixtures SMA LN and SMA LN PmB.

	Vsebnost bitumna (m/m) [%]	Vsebnost polnila (m/m) [%]	Vsebnost zračnih votlin (V/V) [%]	Zapolnjenost votlin z bitumnom [%]
Asfaltna zmes	EN 12697 - 1	EN 12697 - 2	EN 12697 - 8	EN 12697 - 8
SMA	6.5	8.0	2.3	86.6
SMA PmB	6.5	8.0	2.9	83.5
SMA LN	6.0	6.4	6.4	68.0
SMA PmB LN	6.0	6.4	6.3	68.1
PA	5.0	3.6	15.8	39.3
PA PmB	5.0	3.6	19.8	32.8


4.3.1.2 Rezultati eksperimentov na validacijskih zmesih

Za validacijo grobega modela smo naredili enake eksperimente kot za samo izdelavo modela (poglavje 4.2). V preglednici 38 ter na slikah 37 in 38 so prikazani rezultati mehanskih preizkusov validacijskih zmesi SMA 11 B20/30 LN in SMA 11 PmB10/40-65 LN. Ker se manj hrupna asfaltna zmes SMA LN po sestavi nahaja nekje med zmesema SMA in PA, smo poleg rezultatov za validacijski zmesi prikazali še rezultate za SMA in PA, ki sta vključeni v modele. Iz slik 37 in 38 je razvidno, da sta asfaltni zmesi SMA LN in SMA PmB LN glede odpornosti proti nastanku trajnih deformacij zelo podobni asfaltni zmesi SMA oz. SMA PmB.

Preglednica 38: Rezultati mehanskih preiskav asfaltnih zmesi SMA LN.


Table 38: Results of mechanical tests of asphalt mixtures SMA LN.

	S	F_t	S/F_t	Trajna defor. (ε_{10000})	Maks. defor.	Proporc. glob. koles.	Stopnja tvorjenja kolesnice
	[kN]	[mm]	[kN/mm]	[%]	[mm]	[%]	[mm/1000]
Metoda EN 12697	34	34	34	25	25	22	22
SMA	11.3	1.4	8	0.442	0.285	4.73	0.046
SMA PmB	13.7	1.8	7.9	0.329	0.210	2.87	0.028
SMA LN	9.5	2.0	4.7	0.363	0.222	2.83	0.027
SMA PmB LN	-	-	-	0.275	0.172	2.37	0.021
PA	8.4	1.1	7.9	0.799	0.487	4.11	0.046
PA PmB	8.9	1.5	5.9	0.569	0.352	3.16	0.031



Slika 37: Deformacijski krivulji za validacijski asfaltni zmesi SMA 11 B20/30 LN in SMA 11 PmB10/40-65 LN, dobljeni s triosnim testom.

Figure 37: Deformation curves of triaxial test for asphalt mixtures SMA 11 B20/30 LN and SMA 11 PmB10/40-65 LN.




Slika 38: Deformacijski krivulji za validacijski asfaltni zmesi SMA 11 B20/30 LN in SMA 11 PmB10/40-65 LN, dobljeni s preizkusom ugotavljanja globine kolesnice (WTT).

Figure 38: Deformation curves of wheel tracking test (WTT) for validation asphalt mixtures SMA 11 B20/30 LN and SMA 11 PmB10/40-65 LN.

4.3.1.3 Rezultati validacije

Za preizkus delovanja modelov smo najprej naredili t.i. notranjo validacijo z validacijsko metodo izpusti enega (ang. leave-one-out validation) oz. krajše LOO metodo. Ta metoda se uporablja v primerih, ko nimamo na voljo velikih podatkovnih naborov. Za učenje modela uporabimo ves nabor podatkov, razen enega, ki ga porabimo za testiranje. Postopek se ponovi tolikokrat, da je vsak izhodno - vhodni par podatkov uporabljen enkrat tudi za testiranje.

Na sliki 39 smo preverili preprosto linearno povezavo med trajnima deformacijama (ϵ_{10000}), dobljenima iz WTT in triosnega testa, če k zmesem, ki smo jih uporabili za modeliranje, dodamo še obe validacijski asfaltni zmesi SMA 11 B20/30 LN in SMA 11 PmB10/40-65 LN. Vidimo, da se korelacija izboljšuje glede na sliko 29b, kjer so prikazane le asfaltne zmesi, ki so vključene v modeliranje. Vendar je tudi tu potrebno za grobo napoved globine kolesnice v modele dodati še druge podatke o asfaltni zmesi in bitumnu.



Slika 39: Linearna povezava proporcionalne globine kolesnice in trajne deformacije, dobljene s triosnim testom za asfaltni zmesi, ki so bile vključene v modeliranje, in dve validacijski asfaltni zmesi.

Figure 39: Linear correlation of proportional rut depth and permanent deformation of triaxial test for asphalt mixtures, included in modeling, and two validation asphalt mixtures.

V splošnem se moramo zavedati, da govorimo o grobih modelih, majhnemu številu vhodno izhodnih podatkov in s tem o grobem napovedovanju obnašanja asfaltnih zmesi. V preglednici 39 so prikazani koeficienti determinacije q_{LOO}^2 metode LOO, ki smo jo uporabili za t.i. notranjo kontrolo delovanja modelov. q_{LOO}^2 predstavlja determinacijski koeficient r^2 med izmerjenimi vrednostmi izhodnega podatka posameznih zmesi in z modelom izračunano vrednostjo za zmes, ki je bila iz modela izključena. Glede na vrednosti q_{LOO}^2 , je razvidno, da v pozitivnem smislu najbolj izstopa model 2, ki vsebuje tri vhodne parametre (trajna deformacija triosnega testa, PK bitumna in delež bitumna v asfaltni zmesi). Glede na rezultat metode glavnih komponent (slika 34), je tudi pričakovano, da lastnosti bitumna prevladujejo nad lastnostmi agregata. Poleg tega lahko potrdimo, kar sta ugotovila že Tušar in Kalmar (2010) v sklopu projekta BitVal (2010), da je globina kolesnice v veliki meri odvisna od PK bitumna. Drugi najboljši pa je model 6, ki je sestavljen iz štirih vhodnih parametrov (trajna deformacija triosnega testa, delež bitumna, presejek skozi sito 2 mm in kvocient S/F_1).

Preglednica 39: Rezultati notranje validacije z metodo LOO.
Table 39: The results of the internal validation method LOO.

Model	q_{LOO}^2
1. $y = a_1 x_2 + b$	0.08
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.84
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.34
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.37
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.56
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.67
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.35
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.03

Zunanjo validacijo smo naredili na asfaltnih zmesih SMA 11 B20/30 LN in SMA 11 PmB10/40-65 LN. Za oceno modelov smo uporabili kvadratni koren povprečja kvadratov napak (RMSE). Pri modelih 6 in 8, ki vsebujeta rezultate Marshallovega testa, smo naredili validacijo le na zmesi SMA 11 B20/30 LN, saj smo že prej opozorili, da ta preiskava ni več rutinska in so lahko nekateri rezultati vprašljivi. Iz preglednice 40 vidimo, da se modeli 2, 5, 7 in 8 na validacijskih zmesih nekoliko slabše obnašajo. Modela 2 in 6 pa izkazujeta precej dobre rezultate pri notranji validaciji (preglednica 39).

Preglednica 40: Rezultati zunanje validacije.
Table 40: The results of the external validation.


Model	RMSE _{modela}	RMSE _{validac. zmesi}
1. $y = a_1 x_2 + b$	0.93	0.87
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.15	2.61
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.32	1.51
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.32	1.28
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.23	2.28
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.24	0.31
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.07	3.29
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.20	2.18

Na tem mestu pogledimo, kateri od modelov se najboljše obnaša z vidika obeh validacij. Iz preglednice 39 in 40 je razvidno, da se najboljše obaša model 6, saj izpolnjuje tako kriterij notranje validacije kot kriterij zunanje validacije. V preglednici 41 so prikazane dejanske vrednosti globine kolesnice in z modelom 6 izračunane globine kolesnice, slika 40 pa grafično prikazuje dejanske in izračunane vrednosti kolesnice. Vidimo, da je model 6 uspešen pri kvalitativni napovedi obnašanja asfaltnih zmesi pri višjih temperaturah. To pomeni, da lahko z modelom 6 kvalitativno razvrstimo asfaltne zmesi glede na globino kolesnice.

Preglednica 41: Dejanske in z modelom 6 izračunane vrednosti proporcionalne globine kolesnice.

Table 41: Actual and with model 6 calculated values for proportional ruth depth.

Asfaltna zmes	Dejanska prop. glob. koles.	Izračunana prop. glob. koles.
AC	5.44	5.52
AC PmB	2.87	2.79
SMA	4.73	4.35
SMA PmB	2.87	3.24
PA	4.11	4.27
PA PmB	3.16	3.00



Slika 40: Grafični prikaz dejanske in z modelom 6 izračunane vrednosti proporcionalne globine kolesnice.

Figure 40: Graphical presentation of actual and with model 6 calculated values for proportional rut depth.

4.3.2 Razširitev modela

Opisane modele smo skušali razširiti še na druge asfaltni zmesi z drugačnimi vhodnimi materiali, sejalnimi krivuljami in sestavo. Uporabili smo 9 različnih asfaltnih zmesi nazivne zrnivosti 11 mm in 8 mm, ki smo jih imeli na voljo in za katere smo imeli podatke o bitumnu, sejalni analizi, analizi zmesi, preizkusu nastajanja kolesnice, Marshall testu in triosnem testu:

- AC 11 PmB45/80-65,
- SMA 8 PmB45/80-65,
- AC 11 PmB45/80-65,
- SMA 8 PmB45/80-65 LN,
- SMA 8 PmB45/80-65,
- SMA 8 PmB45/80-65,
- SMA 8 PmB45/80-65 žlindra,
- SMA 11 PmB45/80-65 žlindra,
- SMA 11 PmB45/80-65.

4.3.2.1 Material v zmesih za razširitev modelov


V preglednici 42 so podane vrednosti za lastnosti bitumnov, ki so sestavni del asfaltnih zmesi, uporabljenih za razširitev modelov.

Preglednica 42: Vrste bitumnov, uporabljenih v zmesih za razširitev modelov.

Table 42: Bitumen types used in mixtures for models extension.

Asfaltna zmes	PK	Pen.	Lastnost bitumna			Elastični povratek
			IP	Duktilnost	Pretrgališče po Fraassu	
1. PmB45/80-65	83	57	-	-	-	-
2. PmB45/80-65	88	57.9	5.7	86	– 16.6	97
3. PmB45/80-65	77.4	49.7	3.9	55	– 15.9	90
4. PmB45/80-65	80.3	60	-	-	– 22	98
5. PmB45/80-65	88.3	60.7	5.9	92.0	– 20	93.4
6. PmB45/80-65	82.9	61.8	-	-	– 26	92
7. PmB45/80-65	88	60	-	-	-	-
8. PmB45/80-65	88	60	-	-	-	-
9. PmB45/80-65	77	56	-	-	-	-

Na sliki 41 so prikazane sejalne krivulje za asfaltni zmesi, ki smo jih uporabili za razširitev grobega modela. Vse zmesi so narejene s polimernim bitumnom PmB 45/80-65 in imajo največji premer zrna agregata 11 mm oz. 8 mm. Nekoliko posebni sta asfaltni zmesi SMA 11 PmB45/80-65 žlindra in SMA 8 PmB45/80-65 žlindra, ki vsebujeta žlindro. Žlindre so skupno ime za anorganske ostanke pri visokotemperaturnih procesih. Žlindre se med seboj zelo razlikujejo, zato v cestogradnji govorimo o uporabi jeklarske žlindre, ki je stranski produkt pri proizvodnji jekla. Asfaltni zmesi, ki vsebujejo agregat iz žlindre, imajo večjo prostorninsko gostoto od asfaltnih zmesi brez vsebnosti žlindre, kar je lahko tudi razlog za nekoliko višjo porabo bitumna.



Slika 41: Sejalne krivulje asfaltnih zmesi za razširitev grobega modela.

Figure 41: Particle size distribution curve for model extension.

Preglednica 43: Vsebnost bitumna, polnila, votlin in zapolnjenost votlin z bitumnom za asfaltno zmes, ki so uporabljene za razširitev grobega modela.

Table 43: Binder content, filler content, air void content and voids filled with bitumen for asphalt mixtures used for model extension.

	Vsebnost bitumna (m/m) [%]	Vsebnost polnila (m/m) [%]	Vsebnost votlin (V/V) [%]	Zapolnjenost votlin z bitumnom [%]
Asfaltna zmes	EN 12697 - 1	EN 12697 - 2	EN 12697 - 8	EN 12697 - 8
AC 11 PmB45/80-65	4.6	7.9	5.4	68
SMA 8 PmB45/80-65	6.4	11.5	3.0	83.2
AC 11 PmB45/80-65	5.0	8.9	5.1	70.8
SMA 8 PmB45/80-65 LN	5.7	7.9	10.7	58.6
SMA 8 PmB45/80-65	6.5	9.6	4.2	77.9
SMA 8 PmB45/80-65	6.0	9.2	4.0	80.7
SMA 8 PmB45/80-65	5.2	7.7	9.2	60.3
žindra				
SMA 11 PmB45/80-65	5.0	7.6	8.0	63.1
žindra				
SMA 11 PmB45/80-65	6.2	10.2	3.8	79.6

4.3.2.2 Rezultati eksperimentov na zmesih za razširitev modelov

Za razširitev grobega modela so narejeni enaki eksperimenti kot za samo izdelavo modela. (poglavje 4.2). V preglednici 44 ter na slikah 42 in 43 so prikazani rezultati mehanskih preizkusov na desetih zmesih, ki smo jih uporabili za razširitev grobega modela.


Preglednica 44: Rezultati mehanskih preiskav asfaltnih zmesi za razširitev grobega modela.

Table 44: Results of mechanical tests of asphalt mixtures for model extension.

	S	F _t	S/F _t	Trajna defor. (ε ₁₀₀₀₀)	Maks. defor.	Proporc. glob. koles.	Stopnja tvorjenja kolesnice
	[kN]	[mm]	[kN/mm]	[%]	[mm]	[%]	[mm/1000]
Metoda EN 12697	34	34	34	25	25	22	22
AC 11 PmB45/80-65	-	-	-	0.362	0.235	2.357	0.026
SMA 8 PmB45/80-65	-	-	-	0.424	0.263	3.928	0.036
AC 11 PmB45/80-65	17.4	2.3	7.57	0.685	0.420	1.515	0.02
SMA 8 PmB45/80-65 LN	13	2.26	5.75	0.399	0.247	2.439	0.015
SMA 8 PmB45/80-65	15.5	2.83	5.48	0.693	0.439	1.582	0.019
SMA 8 PmB45/80-65	12.7	2.19	5.8	0.601	0.358	3.902	0.031
SMA 8 PmB45/80-65	12.1	2.77	4.37	0.649	0.429	2.280	0.018
žindra							
SMA 11 PmB45/80-65	13.2	2.66	4.96	0.549	0.357	2.195	0.018
žindra							
SMA 11 PmB45/80-65	9.7	3.29	2.95	1.084	0.69	3.103	0.018


Na sliki 42 so prikazane deformacijske krivulje, ki smo jih dobili s triosnim testom za 9 asfaltnih zmesi. Vidimo, da so krivulje med seboj zelo različne. Najboljše obnašanje pri

triosnem testu izkazujejo zmesi AC 11 PmB45/80-65 ter SMA 8 PmB45/80-65 LN in SMA 8 PmB45/80-65, najslabše pa se obnaša zmes SMA 11 PmB45/80-65. Hartinovs in sodelavci (2013) so ugotovili, da je odpornost na trajne deformacije v triosnem preizkusu največja, če asfaltna zmes vsebuje kombinacijo običajnega kamnitega materiala in žlindre. Prikazane rezultate je potrebno interpretirati tudi glede na lastnosti bitumnov, ki sestavljajo omenjene zmesi, in ne samo glede na vrsto asfaltni zmesi. To je ključno pri asfaltnih zmesih SMA, ki vsebujejo večji delež bitumna, da zapolni votline med strukturo kamnitega materiala in posledično je obnašanje takih asfaltnih zmesi močno odvisno od kakovosti uporabljenega bitumna.



Slika 42: Deformacijske krivulje, dobljene s triosnim preizkusom za asfaltni zmesi, ki smo jih uporabili pri razširitvi modelov.

Figure 42: Deformation curves of triaxial test for asphalt mixtures used for model extension.



Slika 43: Deformacijske krivulje, dobljene s preizkusom ugotavljanja globine kolesnice za asfaltni zmesi, ki smo jih uporabili pri razširitvi modelov.

Figure 43: Deformation curves of wheel tracking test for asphalt mixtures used for model extension.

Na sliki 43 so prikazani rezultati WTT na asfaltnih zmesih, ki smo jih imeli na voljo za razširitev grobih modelov.

4.3.2.3 Rezultati razširitve modelov

Pri modelih 6 in 8 smo za razširitev upoštevali le sedem asfaltnih zmesi, ki vsebujejo tudi podatke o kvocientu S/F_t (preglednica 44). Pri ostalih grobih modelih smo upoštevali vseh 9 asfaltnih zmesi. Iz spodnje preglednice vidimo, da so rezultati slabi.

Preglednica 45: Primerjava r^2 za modele in njihovo razširitev na druge zmesi.
Table 45: Comparison of r^2 for models and their extension to other mixtures.

Model	r^2_{model}	$r^2_{\text{razširitev}}$
1. $y = a_1 x_2 + b$	0.096	0.007
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.978	0.115
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.895	0.006
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.893	0.200
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.945	0.039
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.940	0.165
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.995	0.126
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.957	0.162

Preglednica 46: Rezultati razširitve grobih modelov.

Table 46: The results of the models extension.

Model	RMSE _{model}	RMSE _{razširitev}
1. $y = a_1 x_2 + b$	0.93	1.40
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.15	1.86
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.32	1.58
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.32	3.42
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.23	5.22
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.24	5.36
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.07	4.49
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.20	1.86

Rezultati v preglednicah kažejo na slabo možnost razširitve izbranih modelov na ostale asfaltne zmesi. Pri tem obstaja več možnosti, zakaj bi bili lahko modeli neprimerni:

1. modeli veljajo le za nazivno zrnastost 11 mm,
2. modeli ne veljajo za asfaltne zmesi, ki vsebujejo žlindro,
3. pri modeliranju med dejavnike nismo uspeli vključiti ene ali več bistvenih lastnosti, ki vplivajo na globino kolesnice (skrite vplivne spremenljivke).

V okviru točke 3 glede na izkušnje predvidevamo predvsem, da bi modeli v tem primeru veljali le za asfaltne zmesi, ki vsebujejo točno določeno vrsto kamnitega agregata in polnila. V tem primeru bi lahko zaključili, da je vpliv kamnitega agregata na globino kolesnice zelo velik in bi ga bilo treba kot dejavnik vpeljati v grobi model.

V skladu s prvo točko smo za test vzeli samo asfaltne zmesi z nazivno zrnastostjo 11. Pri modelih 6 in 8 smo za razširitev upoštevali le 3 zmesi, ki vsebujejo tudi podatke o kvocientu S/F_t (preglednica 44). Pri ostalih grobih modelih smo upoštevali vse 4 asfaltne zmesi.

Preglednica 47: Primerjava r^2 za modele in njihovo razširitev na asfaltne zmesi z nazivno zrnastostjo 11 mm.Table 47: Comparison of r^2 for models and their extension to asphalt mixtures with nominal particle size 11 mm.

Model	r^2_{model}	$r^2_{\text{raz., 11 mm}}$
1. $y = a_1 x_2 + b$	0.096	0.819
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.978	0.544
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.895	0.225
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.893	0.798
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.945	0.459
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.940	0.994
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.995	0.667
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.957	0.973

Preglednica 48: Rezultati razširitve grobih modelov.

Table 48: The results of the models extension.

Model	RMSE _{model}	RMSE _{raz., 11 mm}
1. $y = a_1 x_2 + b$	0.93	1.64
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.15	2.90
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.32	0.88
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.32	1.11
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.23	4.21
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.24	6.72
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.07	4.11
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.20	2.58

Preglednica 49: Primerjava r^2 razširitve modelov na asfaltne zmesi z nazivno zrnastostjo 11 mm in 8 mm.

Table 49: Comparison of r^2 for models extension to asphalt mixtures with nominal particle size 11 mm and 8 mm.

Model	$r^2_{raz., 11 mm}$	$r^2_{raz., 8 mm}$
1. $y = a_1 x_2 + b$	0.819	0.062
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.544	0.003
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.225	0.007
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.798	0.202
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.459	0.030
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.994	0.033
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.667	0.005
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.973	0.261

Glede na korelacijske koeficiente, podane v preglednici 47, so modeli zadovoljivi, še posebej modela 6 in 8. Po tem kriteriju je izrazito slab le model 3. Glede na vrednosti RMSE_{razširitev} v preglednici 48 pa lahko sklepamo, da je prišlo pri preizkusih do linearnega zamika rezultatov. Preglednica 49 jasno prikazuje, da modeli ne delujejo za nazivno zrnastost 8 mm in od tu lahko zaključimo, da modeli veljajo le za nazivno zrnastost 11 mm in da obstaja skrita sistemska spremenljivka, ki povzroči pri razširitvi modela linearni zamik rezultatov. Ta skrita sistemska spremenljivka pa očitno ni vpliv kamnatega agregata.

Iz zadnjih dveh tabel vidimo, da modeli kvalitativno veljajo za eno nazivno zrnastost kamnatega materiala, saj nobenega od modelov ne moremo posplošiti na asfaltne zmesi drugačnih nazivnih zrnastosti. Predvidevamo, da povezave med modeli za asfaltne zmesi različnih nazivnih zrnastosti obstajajo, vendar so nelinearne. Za potrditev te teze bi bilo potrebno za vsako zrnastostno sestavo sistematsko in kontrolirano pripraviti zmesi in izvajati preizkuse, kakor smo to storili z nazivno zrnastostjo 11 mm. S tem bi se izognili morebitnim napakam pri pripravi zmesi in izvedbi testov, ki so glede na izkušnje iz različnih laboratorijev še posebej izraziti pri določitvi PK bitumna in kvocientu S/F_t . Poleg tega pa na trajne deformacije močno vplivajo dodatki, ki so bili predvidoma dodani vsem zmesem SMA, uporabljenim za razširitev modelov. Naše asfaltne zmesi, uporabljene za modeliranje, vsebujejo karbonatni agregat, ki ima boljšo adhezijo z bitumnom in posledično ni velike potrebe po uporabi dodatkov. Glavni vzrok za tako izbiro agregata je bil torej, da pri asfaltni zmesi SMA nismo uporabili celuloznih vlaken, ki se običajno dodajajo zaradi večje količine veziva. Ti dodatki se v asfaltni plasti obnašajo kot neke vrste armatura in imajo velik vpliv na kolesnice.

Za izboljšanje modelov, ki bi se lahko ekstrapolirali na asfaltne zmesi, ki vsebujejo še druge vrste agregata, bi bilo potrebno upoštevati še lastnosti kamnatega materiala, ki pa jih je težko

kvantitativno ovrednotiti. Upoštevati bi bilo potrebno vsaj nekatere, ki so opisane v standardu SIST 1038 - 1: kakovost finih delcev, oblika grobih zrn, delež drobljenih zrn v zmesi grobih zrn, odpornost grobih zrn proti drobljenju, odpornost proti obrabi, vpijanje vode v groba zrna, obvitost grobih zrn z bitumenskim vezivom, vsebnost votlin v suho zgoščenem polnilu in delta preskus prstan kroglica.

4.3.3 Modeli z upoštevanjem zmesi MA PmB in njihova validacija

Modele, ki so opisani v prejšnjem poglavju, smo preizkusili še z vključitvijo zmesi MA PmB. Vidimo, da so korelacije med dejanskimi vrednostmi proporcionalne globine kolesnice in z modeli izračunane globine kolesnice zelo dobri. Na eni strani vemo, da je zmes MA PmB po sami strukturi in obnašanju zelo drugačna od ostalih zmesi in se na sliki 29a nahaja precej stran ter zato tudi vpliva na boljši determinacijski koeficient. Na drugi strani pa se ukvarjamo z grobimi modeli in je dobro imeti tudi takšne, ki opisujejo tako zaprto asfaltno zmes, kot je liti asfalt, in katerih sejalna krivulja se nahaja na skrajnem zgornjem robu območja sejalnih krivulj v asfalterstvu. Pri modelih 6 in 8, ki vsebujeta rezultate Marshallovega testa, smo naredili validacijo le na zmesi SMA 11 B20/30 LN, saj smo že prej opozorili, da ta preiskava ni več rutinska in so lahko nekateri rezultati vprašljivi. V preglednici 50 so prikazani determinacijski koeficienti r^2 modelov, ki vključujejo tudi zmes MA PmB, njihovo odstopanje $RMSE_{model}$ in odstopanje teh modelov na validacijskih zmesih $RMSE_{validacija}$. Ti modeli, ne glede na visoko korelacijo, niso dobri, kar izkazuje visok $RMSE_{model}$. Ne delujejo dobro pa zaradi vključitve asfaltna zmesi MA PmB, ki je, kot smo že omenili, daleč stran od ostalih (slika 29a).

Preglednica 50: Modeli, r^2 , RMSE in rezultati zunanje validacije.
Table 50: Models, r^2 , RMSE and results of the external validation.

Model	r^2_{model}	$RMSE_{model}$	$RMSE_{validac. zmesi}$
1. $y = a_1 x_2 + b$	0.971	1.89	1.98
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.991	1.04	1.05
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.977	1.69	2.38
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.999	0.35	1.25
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.985	1.37	1.69
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.999	0.23	0.27
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.996	0.69	1.25
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.998	0.51	0.63

Pri modelih 6 in 8 smo za razširitev upoštevali le 3 zmesi, ki vsebujejo tudi podatke o kvocientu S/F_t (preglednica 44). Pri ostalih grobih modelih smo upoštevali vse 4 asfaltna zmesi.

Preglednica 51: Primerjava r^2 razširitve modelov na asfaltne zmesi z nazivno zrnastostjo 11 mm in 8 mm.

Table 51: Comparison of r^2 for models extension to asphalt mixtures with nominal particle size 11 mm and 8 mm.

Model	$r^2_{\text{raz., 11 mm}}$	$r^2_{\text{raz., 8 mm}}$
1. $y = a_1 x_2 + b$	0.819	0.062
2. $y = a_1 x_2 + a_2 x_3 + a_3 x_4 + b$	0.069	0.011
3. $y = a_1 x_2 + a_2 x_3 + a_3 x_6 + b$	0.169	0.012
4. $y = a_1 x_5 + a_2 x_7 + a_3 x_3 + b$	0.685	0.019
5. $y = a_1 x_2 + a_2 x_9 + a_3 x_3 + b$	0.206	0.122
6. $y = a_1 x_2 + a_2 x_4 + a_3 x_6 + a_4 x_8 + b$	0.008	0.387
7. $y = a_1 x_2 + a_2 x_4 + a_3 x_3 + a_4 x_6 + b$	0.035	0.403
8. $y = a_1 x_2 + a_2 x_3 + a_3 x_8 + a_4 x_7 + b$	0.086	0.139

V primeru, ko v modeliranje vključimo liti asfalt s polimernim bitumnom MA PmB (preglednica 51), modeli v splošnem ne veljajo niti za asfaltne zmesi nazivne zrnastosti 11 mm niti za nazivno zrnastost 8 mm. Izjema sta le modela 1 in 4, ki za asfaltne zmesi nazivne zrnastosti 11 zadovoljivo delujeta. To je pričakovano, saj se asfaltna zmes MA PmB precej drugače obnaša od ostalih zmesi in se zato nahaja daleč stran na sliki 29a.

4.4 Sklep

Opisani modeli pokažejo obnašanje osnovnih tipov asfaltnih zmesi (AC, SMA, PA, MA). S cikličnim tlačnim triosnim testom pridobimo podatke o odpornosti posamezne asfaltne zmesi proti trajnim deformacijam, kar je eden od pomembnejših dejavnikov pri načrtovanju in uporabi asfaltnih zmesi v praksi. Z namenom primerjave rezultatov smo na istih zmesih poleg triosnega testa izvedli tudi test odpornosti proti nastanku kolesnic (WTT). Sprva smo pričakovali preprosto linearno povezavo, vendar se je izkazalo, da dobimo boljšo povezavo med testoma, če v linearni model vključimo še podatek o bitumnu in sestavi asfaltne zmesi. Glede na dejstvo, da izbrani statistični modeli vključujejo tudi asfaltne zmesi z najmanjšim in največjim deležem votlin, jih lahko uporabimo za grobo napoved tvorjenja kolesnic.

Glede na PCA metodo smo pri modeliranju uporabili različne vhodne parametre, ki so predstavljali lastnosti asfaltnih zmesi. Za primere, ko nam manjka kakšen od podatkov, ali če v natančnost dobljenega podatka nismo prepričani, smo pripravili 8 različnih modelov, ki vsebujejo različne vhodne parametre.

Izkazalo se je, da kriterija notranje in zunanje validacije najbolj izpolnjuje model 6, ki ga sestavljajo vrednost trajne deformacije iz triosnega testa, delež bitumna, točka peska (presejek skozi sito velikosti 2 mm) ter kvocient S/F_t . Determinacijski koeficient je visok in zato lahko sklepamo, da lahko s tem modelom kvalitativno napovemo kolesnice. Torej lahko različne asfaltne zmesi razvrstimo glede na obnašanje pri povišani temperaturi, ne moremo pa kvantitativno napovedati globine kolesnic.

V okviru naloge smo ugotovili, da razširitev modela na zmesi drugih nazivnih zrnastosti ni možna, saj modeli pri razširitvi na zmesi z zrnastostjo 8 mm ne delujejo. Ugotovili smo, da obstaja skrita sistemska spremenljivka, ki povzroči pri razširitvi modela linearni zamik rezultatov. Najverjetnejši vzrok linearnega zamika pri razširitvi modela na zmesi drugih nazivnih zrnastosti je, da so zmesi in njihove lastnosti (razen triosni ciklični test in test ugotavljanja odpornosti proti nastanku kolesnic) pridobljene iz različnih laboratorijev, medtem ko so zmesi, ki smo jih uporabili za modeliranje, pripravljene in preizkušene sistematsko pod kontroliranimi pogoji v enem laboratoriju.

Asfaltna zmes MA PmB je po pričakovanjih zelo drugačna od ostalih, zato je nismo vključili v modeliranje, ampak smo samo preverili, kako vpliva na delovanje dobljenih modelov (poglavje 4.3.3). Izkazalo se je, da asfaltna zmes MA PmB v splošnem poslabša modele, ki zato ne delujejo niti za asfaltne zmesi nazivne zrnivosti 11 mm.

5 UPORABA UMETNIH NEVRONSKIH MREŽ ZA OCENO TRAJNE DEFORMACIJE ASFALTNE ZMESI

Eden od načinov modeliranja različnih parametrov oz. lastnosti so tudi umetne nevronske mreže (Bredenhann, van de Ven, 2004, Goktepe, Agar, Hilmi Lav, 2006, Trtnik, Kavčič, Turk, 2008). Na področju umetne inteligence je najbolj razširjena metoda, ki se uporablja tudi za reševanje inženirskih problemov. Uporabljajo se predvsem kot modeli za napovedovanje, saj ne potrebujejo predhodnega znanja in imajo visoko natančnost. Na področju cestogradnje sta jih Saltan in Terzi (2008) uporabila za oceno deformiranja vozišča. Sukru in Oruc (2008) sta z uporabo umetnih nevronskih mrež modelirala povezavo med časom strjevanja, količino dodanega cementa, vsebnostjo odpadnega asfalta in modulom elastičnosti bitumenske emulzije. Nevronske mreže so se uporabljale pri napovedovanju tlačne trdnosti betona (Kewalramani, Gupta, 2006, Raghu Prasad, Eskandari, Venkatarama Reddy, 2009), pri napovedovanju stabilnosti pri gradnji tunelov (Leu, Chen, Chang, 2001), pri napovedovanju časa za izvedbo zemeljskih del in njihovih stroškov (Hala, Schabowicz, 2010), pri načrtovanju sistema dostave predhodno pripravljene betonske mešanice (Graham, Forbes, Smith, 2006), pri proizvodnji svežega betona z dodatkom gume (Topcu, Saridemir, 2006), pri modeliranju korozijskega toka armiranega betona (Topcu, Boga, Hocaoglu, 2009), pri študiji projektnega plana in njegove uspešnosti (Wang, Gibson, 2010), pri modeliranju procesa izgradnje konstrukcij (Flood, Christophilos, 1996), pri oceni sile trenja med kolesom in cesto (Matuško, Petrović, Perić, 2008), pri modeliranju spodnjih nosilnih nevezanih plasti voziščne konstrukcije (Saltan, Sezgin, 2007), pri modeliranju trajne deformacije s polipropilenom modificirane asfaltne zmesi (Tapkin, Cevik, Usar, 2009), pri oceni trdnosti lesenih elementov (Zavrtanik, 2008) ter še na mnogih inženirskih področjih.

Za določitev trajne deformacije cilindričnih vzorcev asfaltne zmesi smo izbrali večnivojske usmerjene umetne nevronske mreže z učnim algoritmom vzratnega širjenja napake. Na učenje umetne nevronske mreže vpliva vrsta parametrov, kot so maksimalno število iteracij, velikost učnega koraka, geometrija mreže, največja dovoljena velikost napake in tudi sami podatki, na katerih se mreža uči. Glede geometrije umetne nevronske mreže ni mogoče točno definirati, katera ustreza konkretnim podatkom. Pri obeh primerih smo se odločili za obravnavo mrež z dvema ali tremi skritimi nivoji. Uporabili smo fortranski program NTR2003 in knjižnico nevronskih mrež v programu WEKA. Oba programa in parametri, ki vplivajo na učenje umetnih nevronskih mrež, so opisani v poglavjih 3.2.1, 3.2.3 in 3.2.4. Opozorimo, da uporabljeni algoritmi niso povsem primerljivi, saj nastanejo razlike med programoma predvsem zaradi izhodne funkcije in zaradi postopkov v fazi učenja.


5.1 Podatki

Z umetnimi nevronskimi mrežami smo obravnavali rezultate triosnih testov. Modelirali smo dva parametra, ki opisujeta trajno deformiranje vzorcev asfaltne zmesi z največjim premerom zrna agregata 11 mm.

V obeh primerih najprej identificiramo parametre, ki pomembno vplivajo na določeno lastnost (izhodni podatek). Nato za tak parameter (vhodni podatek) ugotavljamo, katere vrednosti so osamelci. Natančen postopek določevanja osamelcev je opisan v nadaljevanju:

1. Vse vhodne podatke naključno premešamo.
2. Postavimo ničelno hipotezo H_0 : posamezna lastnost oz. vhodni podatek in izhodni podatek (t.j. deformacija po 1000 ciklih obremenjevanja ϵ_{1000} ter stopnja lezenja f_c) nista linearno povezana.
3. Določimo koeficiente linearne regresije.
4. Določimo tveganje ob zavrnitvi ničelne domneve P .

5. Pri tistem koeficientu, kjer je dejansko tveganje $P < \alpha = 0.01$, je vrednost koeficienta statistično značilno različna od 0 in lahko ničelno hipotezo H_0 zavrnemo.
6. V takih primerih preverimo posamezne vrednosti parametra (lastnosti), saj je utemeljen sum, da se med temi podatki nahaja osamelec.
7. Na osnovi podatkov ocenimo parametre normalne porazdelitve in podatke standardiziramo. Nato ugotovimo, ali posamezne vrednosti odstopajo od predpostavke o normalni porazdelitvi. Če zelo odstopajo od te predpostavke oz. če je verjetnost, da se taka vrednost zgodi zelo majhna, potem podatek označimo za osamelec. Verjetnost, pri kateri podatek označimo za osamelec, je $p = 1/\text{število podatkov}/10$ (slika 44)



Slika 44: Določitev osamelca med podatki.

Figure 44: Determination of the outlier.

V laboratoriju smo testirali 260 valjastih vzorcev v dinamični napravi s triosno celico. Z umetnimi nevronske mreže smo modelirali dva parametra, ki opisujeta deformiranje vzorca v triosni celici. Glede na standard SIST EN 12697 - 25 je potrebno pri rezultatih triosnega testa navesti povprečje dveh cilindričnih vzorcev. Najprej smo želeli ugotoviti, kateri vhodni podatki so primerni za modeliranje deformacijskih parametrov z večnivojskimi umetnimi nevronske mreže z učenjem s povratnim širjenjem napake. Obravnavali smo dva različna primera, ki se med seboj razlikujeta glede vhodnih podatkov, ki so bili uporabljeni pri modeliranju. Prvi primer ne vključuje podatkov o vsebnosti zračnih votlin, stopnji zapolnjenosti votlin ter podatkov o deležu votlin v kamniti zmesi. V obeh primerih upoštevamo povprečne vrednosti vhodnih in izhodnih podatkov.

- V prvem primeru kot vhodni podatki nastopajo: delež bitumna, sito 0.063, sito 0.25, sito 0.71, sito 2, sito 4, sito 8, prostorninska gostota asfaltna zmesi, največja gostota asfaltna zmesi, višina vzorca, premer vzorca in gostota vzorca, kot izhodna podatka pa nastopata: deformacija po 1000 ciklih obremenjevanja ϵ_{1000} ter stopnja lezenja f_c . Od 130 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 125. Od tega smo 100 parov uporabili za učenje umetne nevronske mreže in 25 za testiranje.
- V drugem primeru so vhodni podatki: delež bitumna, sito 0.063, sito 0.25, sito 0.71, sito 2, sito 4, sito 8, prostorninska gostota asfaltna zmesi, največja gostota asfaltna zmesi, vsebnost zračnih votlin, stopnja zapolnjenosti votlin, votline v kamniti zmesi, višina vzorca, premer vzorca in gostota vzorca, kot izhodna podatka pa nastopata: deformacija

po 1000 ciklih obremenjevanja ϵ_{1000} ter stopnja lezenja f_c . Od 128 vhodno - izhodnih parov podatkov jih je po izključitvi osamelcev ostalo 122. Od tega smo 100 parov uporabili za učenje umetne nevronske mreže in 22 za testiranje.

5.2 Rezultati

Za modeliranje deleža zračnih votlin v asfaltni zmesi smo uporabili različne večnivojske usmerjene nevronske mreže. V preglednicah 52 in 54 so prikazane tri za program NTR2003 in tri za programsko orodje WEKA.

Primer 1:

Najprej prikazujemo rezultate za manj vhodnih parametrov, kjer niso vključeni podatki o votlinah v asfaltni zmesi.

Preglednica 52: Uporabljene umetne nevronske mreže.


Table 52: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	12 - 15 - 10 - 3	0.5	5000
ann 2	12 - 5 - 7 - 3	0.5	5000
ann 3	12 - 5 - 10 - 5 - 3	0.5	10000
ann 4	12 - 15 - 10 - 1	0.2	8000
ann 5	12 - 5 - 10 - 5 - 1	0.1	8000
ann 6	12 - 10 - 15 - 20 - 1	0.1	10000

Preglednica 53: r^2 in RMSE za različne nevronske mreže in linearno regresijo.

Table 53: r^2 and RMSE for different neural networks and linear regression.

	$r^2_{\epsilon_{1000}}$	RMSE ϵ_{1000}	$r^2_{f_c}$	RMSE f_c
NTR2003				
ann 1	0.614	0.66	0.590	0.55
ann 2	0.467	0.86	0.485	0.72
ann 3	0.297	0.86	0.254	0.73
WEKA				
ann 4	0.434	1.22	0.501	0.83
ann 5	0.550	1.20	0.731	0.46
ann 6	0.648	0.88	0.454	0.89
Linearna regresija	0.377	0.85	0.242	0.96



Slika 45: Dejanske vrednosti in z nevronske mreže ann 1 izračunane vrednosti za ϵ_{1000} .

Figure 45: Actual and with neural network ann 1 calculated values for ϵ_{1000} .

Iz preglednic 52 in 53 je razvidno, da so povezave med vhodnimi in izhodnimi podatki nelinearne, saj so modeli z nevronskimi mrežami boljši od linearnega modela. Odkrile so nekatere splošne povezave med podatki, vendar kljub temu obstajajo še nekateri napojasneni deli, ki so vezani na neko drugo lastnost, ki je nismo merili, ali pa na neko lastnost, ki je ne poznamo.

Primer 2:

V drugem primeru med vhodne podatke vključimo tudi podatke o zračnih votlinah.


Preglednica 54: Uporabljene umetne nevronske mreže.

Table 54: Used artificial neural networks.

	Geometrija mreže	Učni korak	Maksimalno število iteracij
ann 1	15 - 15 - 10 - 3	0.5	5000
ann 2	15 - 10 - 10 - 3	0.2	8000
ann 3	15 - 10 - 15 - 20 - 3	0.5	8000
ann 4	15 - 5 - 7 - 1	0.3	8000
ann 5	15 - 10 - 15 - 20 - 1	0.1	5000
ann 6	15 - 5 - 10 - 5 - 1	0.1	10000

Preglednica 55: r^2 in RMSE za različne nevronske mreže in linearno regresijo.
Table 55: r^2 and RMSE for different neural networks and linear regression.

	$r^2_{\varepsilon_{1000}}$	RMSE ε_{1000}	r^2_{fc}	RMSE _{fc}
NTR2003				
ann 1	0.193	0.90	0.224	1.47
ann 2	0.329	0.83	0.074	1.57
ann 3	0.155	0.93	0.129	1.54
WEKA				
ann 4	0.543	0.81	0.481	1.38
ann 5	0.385	0.87	0.407	1.39
ann 6	0.353	0.86	0.515	1.39
Linearna regresija	0.715	0.59	0.465	0.58



Slika 46: Dejanske vrednosti in z linearnim modelom izračunane vrednosti za ε_{1000} .
Figure 46: Actual and with linear model calculated values for ε_{1000} .

Iz preglednic 54 in 55 je razvidno, da je linearni model za modeliranje ε_{1000} boljši od nevronskega modela.

Opazimo, da je po vključitvi dodatnih vhodnih podatkov, nevronskega modela slabši od linearnega. Predpostavljamo, da ti dodatni podatki predstavljajo motnjo oz., da niso dobro povezani z izhodnim podatkom.

5.3 Sklep

Želeli smo omogočiti hitrejše in cenejše ocenjevanje parametrov trajne deformacije za izbrano zmes. Z umetnimi nevronske mreže smo skušali modelirati parametre trajne deformacije asfaltnih zmesi pri višji temperaturi, ki jih dobimo s triosnim preizkusom. Na podlagi standardnih preiskav (sejalna analiza, ugotavljanje deleža bitumna, določanje

prostorninske in največje gostote asfaltne zmesi, deleža zračnih votlin v asfaltni zmesi, stopnje zapolnjenosti votlin in deleža votlin v zmesi kamnitega materiala) in geometrije preizkušancev smo želeli čim hitreje oceniti trajno deformacijo po 1000 ciklih obremenjevanja in stopnjo lezenja f_c .

Na osnovi opravljenih analiz, lahko zaključimo, da je za modeliranje ϵ_{1000} bolj ustrezen linearni model z upoštevanjem več faktorjev iz drugega primera, kjer v modelu upoštevamo tudi vpliv vsebnosti zračnih votlin, stopnje zapolnjenosti votlin in vpliv votlin v kamniti zmesi. Za modeliranje stopnje lezenja pa je bolj ustrezen nevronskega model iz prvega primera, kjer med vhodnimi podatki ne upoštevamo prej omenjenih vplivov.

Če umetne nevronske mreže ne odkrijejo nekih splošnih povezav med podatki, so slabše od linearnega modela. Pri modeliranju z umetnimi nevronskimi mrežami je pomembna tudi delitev podatkov na učne in testne. V primeru majhnega raztrosa učnih podatkov in večjega raztrosa testnih podatkov je logična posledica, da nevronskega model slabše deluje. Tudi v primeru, ko nekateri podatki nastopajo le med testnimi, je naravno, da se takih vrednosti nevronske mreže ne morejo naučiti in zato takih podatkov ne znajo modelirati. Problem se lahko reši z uporabo metod, kot je na primer leave-many-out metoda ali pa Kennardstoneov algoritem.

6 UPORABA ULTRAZVOČNE METODE NA BITUMENSKEM VEZIVU

Bitumen se v prvi vrsti uporablja na voziščnih konstrukcijah kot vezni material med agregatnimi zrni v različnih asfaltnih zmesih. V vsakdanji praksi se v sklopu kontrole kakovosti meri veliko lastnosti bitumenskega veziva (EN 1426:2007, DIN 52013:2007, EN 1426:2007, EN 12593:2007, EN 12596:2007, SIST EN 13398:2010, SIST EN ISO 3838:2004). Za proizvajalce asfaltnih zmesi je zelo pomembna lastnost bitumna zveza med temperaturo in viskoznostjo. V primeru cestogradbenih bitumnov je njuna odvisnost linearna na logaritemski merilni skali, t.i. Heukelom diagram (Mouton, 2003). Temperatura mešanja asfaltnih zmesi se določi na podlagi t.i. ekviviskozne temperature bitumna. V preteklosti so se za merjenje viskoznosti najpogosteje uporabljali kapilarni viskozimetri, v današnjem času pa se običajno uporabljajo rotacijski viskozimetri (reometri). S takimi viskozimetri je težko meriti učinek kontinuiranih kemičnih in fizikalnih procesov, kot sta staranje ali pomlajevalni efekt na viskoznost bitumna.

V zadnjih letih sta razvoj računalniške tehnologije in avtomatizacija meritev omogočila razvoj različnih novih metod za spremljanje procesa strjevanja različnih materialov. Nekatere izmed njih delujejo na principu valovanja različnih ultrazvočnih valov, ki potujejo skozi material in so se izkazale za zanesljive pri določevanju različnih lastnosti materialov.

Že leta 1965 je Richard (1965) objavil patent z oznako US 3194057 A in določil linearno zvezo med ultrazvočno absorpcijo in kinematično viskoznostjo tekočin. S patentom številka US 5365778, ki je bil objavljen leta 1994 (The University of Chicago, 1994), je bila razvita bolj napredna metoda za merjenje viskoznosti tekočin z ultrazvočnim viskozimetrom, kjer se generirajo tako prečni kot longitudinalni ultrazvočni valovi. Viskoznost tekočine je določena na podlagi določitve odboja strižnih ultrazvočnih valov. V današnjem času na trgu obstaja več vrst komercialnih ultrazvočnih viskozimetrov s piezoelektričnim resonatorjem za določanje viskoznosti bitumna.

Lionetto in sodelavci (2008) so na področju polimerov z ultrazvočno metodo spremljali procese spreminjanja različnih lastnosti, ki nastanejo v povezavi s kristalizacijo in drugimi kemičnimi in fizikalnimi fenomeni. Ramanathan s sodelavci (1991) je UZ uporabil za ugotavljanje adhezije med bitumnom in agregatom za različne vrste asfaltov. Veliko se UZ uporablja na področju naftne industrije za spreminjanje oz. izboljšavo lastnosti bitumna. Z njim se lahko prekinе nekatere šibke molekularne vezi ali pa postavi organizirano prostorsko orientacijo nekaterih molekul bitumna. Še več pa se ultrazvok uporablja za analizo hidratacijskega procesa cementnih materialov (Chung, 2010, Sun, Voigt, Shah, 2006, Trtnik, Gams, 2014, Trtnik, Valič, Turk, 2013, Reinhardt, Grosse, 2004, Ozturk, Krogel, Grubl, Popovics, 2006, Chotard et al., 2001). Med drugimi je Valič (2000) razvil ultrazvočni (UZ) aparat, ki temelji na metodi odboja strižnih ultrazvočnih valov (USWR), in dokazal uporabnost omenjene nedestruktivne metode za spremljanje procesa strjevanja različnih cementnih past, kot so Portland cement, Vezur cement, aluminij cement, beli cement, epoksi in podobno (Valič, Stepišnik, 1998).

Večina empiričnih metod, ki se uporabljajo za opis obnašanja bitumna, vsebuje zelo omejeno količino informacij o procesu mehčanja bitumna, saj se nekatere izmed njih izvajajo le pri eni sami določeni temperaturi (Dolinšek et al., 2000). Zato so za spremljanje procesa strjevanja (mehčanja) bitumna potrebne avtomatizirane in kontinuirane merilne tehnike, ki bi proces spremljale v širokem temperaturnem intervalu. Dolinšek et al. (2000) so predstavili novo merilno metodo za natančnejše spremljanje procesa mehčanja bitumna, ki temelji na nuklearni magnetno resonančni (NMR) spektroskopiji. Odkrili so, da se proces mehčanja lahko natančno spremlja na osnovi določitve NMR mehčalnih krivulj v odvisnosti od temperature.

V doktorski disertaciji predstavimo uporabo alternativne nedestruktivne metode odboja strižnih ultrazvočnih valov za spremljanje temperaturno odvisnega procesa strjevanja bitumna. Na osnovi omenjene metode deluje merilni inštrument USWR-4, ki ga je razvil Valič (2000) in je bil do sedaj zelo učinkovito uporabljen za spremljanje hidratacijskih procesov in strukturnih formacij cementnih past (Valič, Stepišnik, 1998, Trtnik, Valič, Turk, 2013). V nadaljevanju predstavimo pomembno razširitev omenjene USWR metode na področje spremljanja strjevalnega procesa različnih vrst bitumenskega veziva v širokem temperaturnem intervalu, kar omogočajo visoko temperaturno odporne kvarčne sonde.

6.1 Material

6.1.1 Bitumen

Pomembne fizikalne lastnosti bitumna, kot so na primer penetracija, viskoznost, točka zmehčanja in druge, so močno povezane s temperaturno odvisnim procesom mehčanja bitumna. Zato trenutno obstaja več konvencionalnih empiričnih metod za kvantitativno določevanje mehčanja bitumna, npr. točka zmehčanja po metodi "prstan in kroglica", penetracija in viskoznost (Dolinšek et al., 2000). Bitumni so razdeljeni v razrede glede na penetracijo in točko zmehčanja. Poleg cestogradbenih bitumnov se v cestogradnji veliko uporabljajo tudi s polimeri modificirani bitumni. Ti bitumni so modificirani z namenom izboljšave njihovih lastnosti (povišanje točke zmehčanja, zmanjšanje pretrgališča po Fraassu, povečanje odpornosti na trajne deformacije in podobno). Pri raziskavi smo uporabili tri vrste cestogradbenega bitumna (B) in dve vrsti s polimerom modificiranega bitumna (PmB). Njihove lastnosti so podane v preglednici 56.

Preglednica 56: Vrste bitumnov in njihove lastnosti.
Table 56: Characteristics and labeling of bitumen used in the study.

Lastnost	B 20/30	B 100/150	B 160/220	PmB 10/40-65	PmB 45/80-65
PK [°C]	62.9	42	38.1	75.1	82.8
Penetracija pri 25 °C [mm/10]	24	170.3	187	16.7	44.7
Indeks penetracije	0	0.1	1.2	1.2	4.4
Gostota pri 25 °C [g/cm ³]	1.0221	1.0284	0.9926	1.033	1.0076
Pretrgališče po Fraassu [°C]	-4.7	-19	-	-9.9	-19.8
Elastični povratek pri 25 °C [%]	-	-	-	72	97
Duktilnost pri 25 °C [cm]	35	-	>100	26.95	59.6
Dinamična visk. pri 60 °C [Pa s]	2323	28.7	-	-	-

6.2 Metoda odboja strižnih ultrazvočnih valov

6.2.1 Splošno o metodi

Metodo odboja strižnih ultrazvočnih valov je v svoji doktorski disertaciji podrobno predstavil Trtnik (2009). Ko ultrazvočno valovanje zadene ob stično površino dveh materialov, se del tega odbije, preostali del pa potuje naprej skozi naslednji material. Za omenjeno metodo je pomemben koeficient odboja (slika 47), ki je označen z r in velja:

$$r = \frac{p_r}{p_e}, \quad (59)$$

kjer je:

p_r ... zvočni tlak (amplituda) odbojnega signala in
 p_e ... zvočni tlak (amplituda) oddajnega signala.

Koeficient odboja strižnega valovanja r na stiku dveh materialov je z akustičnima impedancama obeh materialov Z_1 in Z_2 povezan z naslednjo enačbo:

$$r = \frac{Z_2 - Z_1}{Z_2 + Z_1}. \quad (60)$$

Akustično impedanco Z izračunamo kot produkt gostote materiala ρ in hitrosti valovanja v skozi material:

$$Z = \rho v. \quad (61)$$

V spodnji preglednici so prikazane vrednosti akustične impedance in hitrosti prehoda strižnih in vzdolžnih valov skozi nekatere materiale.

Preglednica 57: Vrednosti hitrosti prehoda vzdolžnih in strižnih ultrazvočnih valov skozi različne materiale ter akustične impedance (Frederick, 1965).

Table 57: Values of speed of longitudinal and speed of shear ultrasonic waves for different materials and values of acoustic impedance (Frederick, 1965).

Material	v_p [m/s]	v_s [m/s]	Z [kg/m ² s]
Aluminij	6400	3130	$17.3 \cdot 10^6$
Jeklo	6100	3240	$46.3 \cdot 10^6$
Kremen	5570	352	$14.5 \cdot 10^6$
Voda	1450	-	$1.48 \cdot 10^6$
Led	3980	1990	$3.6 \cdot 10^6$
Zrak (10 °C)	325.2	-	0.000436
Zrak (-10 °C)	337.3	-	0.000420

V splošnem lahko za viskoelastični material akustično impedanco Z , strižni modul G in viskoznost η razstavimo na elastični in viskozni del, kar v matematičnem zapisu naredimo s kompleksnimi števili:

$$Z = R + iX, \quad G^* = G' + iG'', \quad \eta^* = \eta' + i\eta'', \quad (62)$$

kjer je R realni del akustične impedance, X je imaginarni del akustične impedance, modul G' se nanaša na elastično obnašanje materiala, G'' na viskozno obnašanje materiala, η' predstavlja viskozno obnašanje materiala, η'' pa elastično obnašanje.

Hitrost prečnega akustičnega valovanja v materialu je odvisna od gostote materiala ρ , elastičnega modula E , strižnega modula G in Poissonovega koeficienta materiala η :

$$v_s = \sqrt{\frac{G'}{\rho}} = \sqrt{\frac{E}{2\rho(1+\eta'')}} , \quad G' = \frac{E}{2(1+\eta'')}. \quad (63)$$

Po upoštevanju zveze

$$G' = \rho v_s^2, \quad (64)$$

ki sledi iz enačb (63) ter po preoblikovanju enačbe (61) in prve od enačb (62), lahko zapišemo enačbe za kompleksni strižni modul ter njegovi realni in kompleksni komponenti:

$$G^* = \frac{Z^2}{\rho} = \frac{(R + iX)^2}{\rho}, \quad G' = \frac{R^2 - X^2}{\rho}, \quad G'' = \frac{2RX}{\rho}. \quad (65)$$

Valič (2000) je podal naslednje zveze:

$$G^* = \omega \eta^*, \quad G' = \omega \eta'', \quad G'' = \omega \eta', \quad (66)$$

kjer je ω kotna hitrost valovanja. Realno in imaginarno komponento viskoznosti lahko zapišemo z naslednjima zvezama:

$$\eta' = \frac{2RX}{\rho\omega}, \quad \eta'' = \frac{R^2 - X^2}{\rho\omega}. \quad (67)$$

Če upoštevamo zgornji enačbi, lahko akustično impedanco viskoelastičnega materiala zapišemo kot:


$$Z = \sqrt{\rho G' + i\rho\omega\eta'}. \quad (68)$$

Za viskoelastični material tudi strižni odbojni koeficient zapišemo s kompleksnimi komponentami:

$$r^* = r_0 \exp(i\varphi) = r_0(\cos \varphi + i \sin \varphi), \quad (69)$$

kjer je r_0 velikost refleksijskega koeficienta in predstavlja razmerje med amplitudo odbojnega signala p_r in amplitudo oddajnega signala p_e (slika 47), φ pa je fazna razlika med vpadnim θ_e in odbojnim θ_r valom:

$$\varphi = \theta_e - \theta_r. \quad (70)$$



Slika 47: Shema vpadnega in odbojnega vala na stiku pomožni material - cementna pasta (Voigt, 2004).

Figure 47: Scheme of incident and reflected wave at buffer - cement paste interface (Voigt, 2004).

Akustično impedanco materiala lahko določimo z merjenjem strižnega odbojnega koeficienta na stiku z materialom, za katerega poznamo vrednost impedance. Velikokrat se fazno spremembo φ izrazi s fazno spremembo odbojnih valov θ , ki jo zapišemo v odvisnosti od faze odbojnega vala, ki nastane na stiku pomožnega in testnega materiala in v odvisnosti od faze odbojnega vala, ki nastane na stiku pomožnega materiala in zraka:

$$\theta = \theta_r^{mat} - \theta_r^{zrak}, \quad (71)$$

kjer je:

θ_r^{mat} ... fazni kot odbojnega vala na stiku pomožnega in testnega materiala,

θ_r^{zrak} ... fazni kot odbojnega vala na stiku pomožnega materiala in zraka.

Velja:

$$\theta_r^{mat} = \theta_e + \varphi, \quad \theta_r^{zrak} = \theta_e + \pi, \quad \varphi = \theta + \pi. \quad (72)$$

Kompleksni odbojni strižni koeficient zapišemo:

$$r^* = r_0 \exp i(\pi + \theta) = -r_0(\cos \theta + i \sin \theta), \quad (73)$$

akustično impedanco pa v skladu z enačbo (60):

$$Z_{mat} = Z_{pom} \frac{1 + r^*}{1 - r^*}, \quad (74)$$

kjer je:

Z_{mat} ... akustična impedanca testnega materiala,
 Z_{pom} ... impedanca pomožnega materiala.

Če upoštevamo (73) v (74), dobimo:

$$Z_{mat} = Z_{pom} \frac{1 - r_0(\cos \theta + i \sin \theta)}{1 + r_0(\cos \theta + i \sin \theta)}. \quad (75)$$

Sedaj lahko zapišemo enačbi za realno in imaginarno komponento kompleksne akustične impedance Z_{mat} . Upoštevamo prvo izmed enačb (62) in dobimo:

$$R = Z_{pom} \frac{1 - r_0^2}{1 + r_0^2 + 2r_0 \cos \theta}, \quad X = Z_{pom} \frac{2r_0 \sin \theta^2}{1 + r_0^2 + 2r_0 \cos \theta}. \quad (76)$$

6.2.2 Merilni inštrument USWR

Merilni inštrument USWR-4, ki je prikazan na sliki 49, je razvil Valič s sodelavci (1998, 2000). Osnovni model inštrumenta je bil razvit z namenom spremljanja procesa strjevanja različnih cementnih materialov. Merilni sistem je sestavljen iz štirih merilnih sond iz kremena, oddajnika in sprejemnika, generatorja pulza, merilca impedance, sprejemnika in PC računalnika. Sonde so pravokotnega prereza, dimenzij 16x13 mm in dolžine 62 mm. Zgornji del sonde je okroglega prereza s premerom 1 cm, na spodnjem delu pa je pritrjena merilna glava z aluminijastim cilindričnim ohišjem premera 3 cm in dolžine 4 cm (slika 50b). Merilna glava vsebuje t.i. PZE generator strižnega ultrazvočnega valovanja in deluje hkrati kot oddajnik in sprejemnik. Zgornji konec sonde potisnemo v kalup, kjer se nahaja vzorec bitumna. Aparat USWR-4 deluje na osnovi merjenja velikosti prvega s_1 in drugega s_2 povratnega odmeva strižnega ultrazvočnega valovanja (slika 48). Generator pulza oddaja kratek in šibak pulz (4 μ s in 2 W) s frekvenco 17 MHz. Zatem se tvori strižno ultrazvočno valovanje z amplitudo A_i , ki potuje do vrha merilne sonde oz. do stika sonde s testnim materialom s hitrostjo strižnega valovanja v_{s1} . Na stiku med ultrazvočno sondo in testnim materialom se del valovanja odbije nazaj do merilne glave in nastane prvi povratni odmev s_1 . Ta potuje nazaj do stične površine med sondo in materialom in ponovno se del tega signala odbije in potuje nazaj do merilne glave, kjer se ustvari povratni odmev s_2 itd. S tem dobimo celotno zaporedje odmevov, ki si sledijo v časovnem intervalu dolžine $2L/v_{s1}$. Glede na to inštrument neposredno iz amplitud prvega in drugega odmeva izračuna odbojni strižni koeficient r . Velja:

$$\frac{s_2}{s_1} = \frac{A_i r^2 r_0}{A_i r} = r r_0, \quad (77)$$


kjer je konstanta r_0 vrednost odbojnega koeficienta na stiku med kvarčno sondo in PZE kristalom. Ker je znano, da strižno valovanje skozi zrak ne poteka, je $r_{zrak} = 1$ in velja:

$$\left(\frac{s_2}{s_1}\right)_{zrak} = r_{zrak} r_0 = r_0. \quad (78)$$

Od tod lahko izpeljemo:

$$r = \left(\frac{S_2}{S_1} \right) / \left(\frac{S_2}{S_1} \right)_{\text{zrak}} . \quad (79)$$

Izraz $(S_2/S_1)_{\text{zrak}}$ v nekem smislu predstavlja koeficient normiranja in je karakteristika posamezne merilne sonde.



Slika 48: Shema delovanja USWR inštrumenta.
Figure 48: Block scheme of USWR instrument.

Aparat je povezan z računalnikom, kjer posebna programska oprema omogoča avtomatsko shranjevanje podatkov v vnaprej določenih časovnih intervalih (slika 49) in istočasno izrisovanje krivulje $r(t)$.




Slika 49: Ultrazvočni aparat za spremljanje procesa strjevanja bitumna USWR-4.
Figure 49: Ultrasonic apparatus for monitoring hardening process of bitumen USWR-4.

Z ohlajevanjem se bitumen strjuje, s čimer se vrednost njegove akustične impedance povečuje. To pomeni, da se vrednost odbojnega koeficienta $r(T)$ s padanjem temperature zmanjšuje. Za predstavitev vrednosti strižnega koeficienta r se običajno uporablja naraščajoča krivulja, zato smo za opisovanje procesa strjevanja bitumna uporabili spremembo odbojnega koeficienta Δr (Valič, 2000), ki se zapiše z enačbo:

$$\Delta r(T) = 1 - r(T). \quad (80)$$

6.3 Priprava vzorcev in procedura eksperimenta

Kalupe z volumnom 150 cm^3 ($a = 5 \text{ cm}$, $b = 5 \text{ cm}$, $h = 6 \text{ cm}$) smo pripravili iz ekstrudiranega polistirena. Za preprečevanje taljenja kalupov na začetku preizkusa smo jih prekrili z visoko temperaturno odporno tunelsko folijo (slika 50a). Bitumen smo segreli na temperaturo okoli $160 \text{ }^\circ\text{C}$, da se je utekočnil, in ga vlili v kalup. Takoj zatem smo bitumenski vzorec položili v temperaturno komoro, kjer je bil izpostavljen temperaturi zraka okoli $-20 \text{ }^\circ\text{C}$ (slika 50c). Vanj smo do globine 5 mm potisnili merilni senzor (slika 50b), da smo zagotovili ustrezen stik med sondo in bitumnom. Do enake globine smo v vzorec potisnili tudi termočlen za spremljanje spreminjanja temperature. Po postavitvi merilnega senzorja in termočlena se je pričelo kontinuirano merjenje strižnega odbojnega koeficienta $r(t)$ in temperature T ter s tem spremljanje procesa strjevanja bitumenskega vzorca. Rezultati merjenja so se beležili v 10s časovnih intervalih.



Slika 50: a) Kalup iz ekstrudiranega polistirena.

Figure 50: a) Extruded polystyrene mould.



b) Merilni senzor.

b) Measuring sensor.



c) Temperaturna komora.


c) Temperature chamber.

6.4 Rezultati

Istočasno smo kontinuirano merili temperaturo v vzorcu in strižni odbojni koeficient r na stiku med kvarčno merilno sondo in bitumnom.

6.4.1 Hlajenje bitumenskih vzorcev

Zaradi majhnih vzorcev bitumna in nizke temperature prostora, kjer se je izvajal eksperiment, je proces ohlajanja vzorcev potekal zelo intenzivno. Slika 51 prikazuje $T - t$ diagrame za tri vrste cestogradbenega bitumna in dve vrsti s polimeri modificiranega bitumna (preglednica 56). Po 1.5 - 2 urah je temperatura za vse vrste bitumnov dosegla končno vrednost, približno -20°C . Iz slike 51 je razvidno, da je padec temperature podoben za vse vrste bitumna, kar označuje zelo podoben proces ohlajevanja bitumenskih vzorcev. To je pomemben pokazatelj, da se doseže eden od ciljev študije USWR metode na bitumenskih vzorcih (t.j. analiza zmožnosti uporabe USWR metode za spremljanje procesa strjevanja različnih vrst bitumnov).




Slika 51: $T - t$ diagram za: a) cestogradbeni bitumen, b) s polimeri modificiran bitumen.

Figure 51: $T - t$ diagram for: a) paving grade bitumen, b) polymer modified bitumen.

Temperatura ima velik vpliv na pomembne fizikalne lastnosti bitumna, kot sta penetracija in viskoznost. Posledično so se med procesom strjevanja bitumenskih vzorcev konstantno spreminjale lastnosti ultrazvočnega širjenja valov. To vodi v spremembe strižnega odbojnega koeficienta Δr , ki je določen iz amplitud zaporednih odbojnih valov na stiku bitumen/sonda. Ker je Δr neposredno povezan z impedanco materiala Z in strižnim modulom G (enačba (60 in 63)), padec temperature povzroča povečanje togosti materiala.


Slika 52 prikazuje tipičen razvoj spremembe strižnega odbojnega koeficienta Δr s temperaturo T med procesom strjevanja bitumna pri enakem času (glede na sliki 51 in 53). Razvidno je naraščanje Δr v odvisnosti od padanja temperature, kar je povezano z dobro znanim procesom povečevanja togosti materiala pri zniževanju temperature. Posledično lahko zaključimo, da je Δr občutljiv na spremembe v bitumnu, ki se pojavijo med procesom strjevanja in lahko zato predstavlja primeren in napreden parameter za spremljanje strjevalnega procesa bitumna v širokem temperaturnem intervalu. Poleg tega lahko opazimo linearen odnos med Δr in T , kar kaže na linearno naraščanje akustične impedance bitumna s padanjem temperature znotraj opazovanega temperaturnega intervala (enačba (60)).



Slika 52: Tipičen razvoj koeficienta Δr s temperaturo.

Figure 52: Typical development of the Δr coefficient with temperature.


Na sliki 53 je predstavljen razvoj Δr v odvisnosti od časa t med procesom strjevanja bitumna za tri cestogradbene in dva polimerna bitumna. Opazimo, da so pri cestogradbenih in ravno tako pri polimernih bitumnih vrednosti Δr med celotnim strjevalnim procesom višje pri trših vrstah in obratno. To je v nasprotju z razvojem temperature s časom, kjer je opaziti zelo podoben padec temperature za vse vrste bitumna (slika 51).



Slika 53: $\Delta r - t$ diagram za: a) cestogradbeni bitumen, b) s polimeri modificiran bitumen.
Figure 53: $\Delta r - t$ diagram for: a) paving grade bitumen, b) polymer modified bitumen.

6.4.2 Vpliv vrste bitumna na razmerje $\Delta r - T$

Na sliki 54 je prikazan vpliv vrste bitumna na razvoj $\Delta r(T)$ za cestogradbeni bitumen in s polimeri modificiran bitumen. Diagrami za vse vrste bitumnov so dobljeni iz slik 51 in 53 z nanašanjem vrednosti za Δr in T pri enakem času. Rezultati kažejo, da v vseh primerih vrednosti Δr naraščajo s padanjem temperature v bitumenskih vzorcih. To je neposredno povezano z višjim strižnim modulom bitumna pri nižjih temperaturah. Poleg tega so opazne linearne zveze med Δr in T za vse vrste bitumnov, ki niso enake in se spreminjajo glede na vrsto bitumna. Pri trših bitumnih se razvijejo višje vrednosti Δr s padanjem temperature, kar je v skladu z vrednostmi penetracije za različne vrste bitumnov (glej preglednico 56). To je pomemben rezultat, ki dokazuje uporabnost predstavljene ultrazvočne metode pri analizi vpliva vrste oz. sestave bitumna na temperaturno odvisen proces strjevanja bitumna.



Slika 54: $\Delta r - T$ diagram za: a) cestogradbene bitumne, b) s polimeri modificiran bitumen.
Figure 54: $\Delta r - T$ diagram for: a) paving grade bitumen, b) polymer modified bitumen.

6.4.3 Ponovljivost in zanesljivost USWR metode na bitumenskih vzorcih

Ponovljivost določitve vrednosti $r(T)$ z USWR metodo je bila določena z večkratnim zaporednim merjenjem odbojnega koeficienta $r(T)$ pri enaki vrsti bitumna in pri enakih pogojih. Za analizo vpliva je bila uporabljena dvofaktorska ANOVA (poglavje 2.2.2). V

nadaljevanju so podane tri ničelne hipoteze H_{0i} in pripadajoče alternativne hipoteze H_{Ai} ($i = T, B$ and TB):

H_{0T} : T /vrsta bitumna/interakcija med T in vrsto bitumna nima vpliva na vrednosti Δr ,

H_{AT} : T /vrsta bitumna/interakcija med T in vrsto bitumna ima vpliv na vrednosti Δr .

Vrednosti Δr so določene za tri različne vrste bitumna pri štirih različnih temperaturah, ki so označene s T_1 , T_2 , T_3 , in T_4 in smo jih izbrali tako, da zajamejo čim širši temperaturni interval.

V preglednici 58 so prikazane vrednosti za Δr_{ijk} ($i = 1, 2, 3, 4$; $j = 1, 2, 3$) za vrsto bitumna j in temperaturo T_i .

Preglednica 58: Vrednosti Δr_{ijk} glede na temperature bitumna in vrste bitumna.

Table 58: Values of Δr_{ijk} with respect to different bitumen temperatures and bitumen types.

T [°C]	Ponovitev	Vrsta bitumna		
		B20/30	B100/150	B160/200
$T_1 = -10$	1	0.29	0.27	0.24
	2	0.30	0.27	0.22
	3	0.31	0.27	0.27
$T_2 = 25$	1	0.24	0.21	0.21
	2	0.26	0.19	0.18
	3	0.27	0.2	0.18
$T_3 = 45$	1	0.21	0.15	0.16
	2	0.21	0.16	0.14
	3	0.19	0.15	0.13
$T_4 = 90$	1	0.18	0.04	0.04
	2	0.13	0.03	0.06
	3	0.12	0.07	0.04

Rezultati dvofaktorske ANOVE so prikazani v preglednici 59. Oznake F_T , F_B , in F_{TB} predstavljajo vrednosti statistike F v primeru, ko so analizirani vplivi T , vrste bitumna in interakcije T /vrsta bitumna na vrednosti Δr . Analogno predstavljajo $F_{krit,T}$, $F_{krit,B}$ in $F_{krit,TB}$ kritične vrednosti F glede na α , za katerega smo izbrali vrednost $\alpha=0.05$. SS , df , MS in P predstavljajo vsoto kvadratov, prostostne stopnje, povprečne kvadrate in dejansko tveganje. Če $F > F_{krit}$, je ničelna hipoteza H_{0i} ($i = T, B$ in TB) zavržena. To pomeni, da imajo T , vrsta bitumna ter interakcija med T in vrsto bitumna statistično značilen vpliv na vrednosti Δr . Posledično so razlike med vrednostmi Δr , ki nastanejo zaradi treh ponovitev vsake vrste bitumna manjše od razlik med vrednostmi, ki so posledica različne T , vrste bitumna in interakcije T /vrsta bitumna.

V vseh primerih so vrednosti testne statistike F večje od pripadajoče kritične vrednosti F_{krit} , ki je določena pri $\alpha=0.05$. Od tod sledi, da so vse vrednosti Δr odvisne od T , vrste bitumna ter interakcije T /vrsta bitumna.

Preglednica 59: Preglednica ANOVA.
Table 59: ANOVA table.

Izvor variabilnosti	SS	df	MS	F	P - vrednost	F_{krit}
<i>T</i>	0.181	3	0.060	255.65	2.4E – 18	3.01
vrsta bitumna	0.034	2	0.017	71.67	7.6E – 11	3.40
interakcija <i>T</i> in vrste bitumna	0.004	6	0.001	2.54	0.04744	2.51
ponovitve	0.006	24	0.0002			
skupaj	0.22	35				

6.5 Sklep

Rezultati eksperimentov so pokazali, da se pri vseh petih vrstah bitumenskega veziva vrednost strižnega odbojnega koeficienta večja z nižanjem temperature, kar je neposredno povezano z večjo togostjo oziroma višjim strižnim modulom bitumna pri nižjih temperaturah. Razlike v razvoju strižnega odbojnega koeficienta s temperaturo za različne tipe bitumnov kažejo na občutljivost strižnega odbojnega koeficienta na sestavo bitumna in s tem primernost ultrazvočne metode za ugotavljanje lastnosti različnih tipov bitumnov. Ker je strižni odbojni koeficient neposredno povezan s strižnim modulom in akustično impedanco materiala, omogoča enostavno določitev omenjenih karakteristik pri poljubni temperaturi materiala. Poleg tega je bila dokazana ponovljivost USWR metode in s tem tudi njena uporabnost za spremljanje procesa strjevanja bitumna.

7 ZAKLJUČKI

V splošnem je naloga sestavljena iz štirih glavnih delov, ki so navidezno precej različni. Toda po drugi strani imajo vsi deli skupni imenovalac. Zadnje poglavje se nanaša na bitumen, ki je ena od glavnih komponent asfaltne zmesi in ima pomembno vlogo pri obnašanju asfaltnih zmesi pri višjih temperaturah, s čimer se ukvarjamo v četrtem in petem poglavju. Poleg tega pa na obnašanje asfalta vplivajo še druge lastnosti, ki so zbrane v bazi podatkov in jih analiziramo v tretjem poglavju. V nadaljevanju so tudi zaključki predstavljeni po poglavjih, ki se nanašajo na posamezni del doktorske disertacije.

Tretje poglavje se nanaša na izdelavo baze podatkov, ki predstavljajo rezultate različnih preiskav asfaltnih zmesi v obdobju več kot deset let. Poleg tega smo določene parametre statistično analizirali in pripravili modele z umetnimi nevronskimi mrežami.

- Bazo podatkov smo pripravili z namenom, da se bo v prihodnosti širila in dala možnost različnim analizam podatkov, ki so potrebne za raziskovalne in praktične namene.
- Razlike korelacij pri časovnem deljenju podatkov v dve skupini so statistično značilno različne s tveganjem manjšim od 5 %. To pomeni, da je prišlo do sprememb v povezavah med parametri med časovnim obdobjema. Dejansko je v tem času prišlo do sprememb standardov iz starih JUS na nove evropske standarde SIST EN.
- Razlike korelacij pri naključnem deljenju podatkov v dve skupini niso statistično značilno različne in so posledica naključja. Torej nobeden od podatkov ne odstopa preveč od preostalih.
- Statistična metoda (poglavje 3.1) je dovolj preprosta, da bi se lahko pogosto uporabljala v praksi, saj uporablja le osnovne statistične izračune, ki jih omogočajo vsi računalniški programi, namenjeni urejanju, zbiranju in analiziranju podatkov.
- Čeprav je znano, da viskoznost bitumna vpliva na delež votlin v asfaltni zmesi, je bilo pri modeliranju votlin v asfaltni zmesi ugotovljeno, da podatki o bitumnu pokvarijo model, saj izkazujejo prevelik raztros, jih je težje pridobiti in so lahko večkrat vprašljivi.
- Za ugotavljanje povezanosti deleža votlin v asfaltni zmesi z ostalimi lastnostmi se lahko uporabi preproste linearne modele, saj so se izkazali za enako dobre ali celo boljše od modeliranja z nevronskimi mrežami.
- Pri modeliranju deleža votlin v zmesi kamnitega materiala se je v splošnem izkazalo, da so linearni modeli pri obravnavi podatkov posamezne asfaltne zmesi boljše od modelov z nevronskimi mrežami. Pri analizi več zmesi skupaj pa se je izkazalo, da pride do večjih nelinearnosti in so zato nevronske mreže boljše od linearnega modela. Eden od možnih vzrokov nelinearnosti se skriva v različnih sejalnih krivuljah.

V četrtem poglavju smo želeli ugotoviti, kako sta triosni dinamični test in preizkus nastanka kolesnic (WTT) povezana, če analiziramo osnovne vrste asfaltnih zmesi. Predstavili smo razvoj t.i. grobega modela, s katerim smo skušali opisati obnašanje štirih osnovnih tipov asfalta pri višji temperaturi. Model obravnava asfaltne zmesi, ki glede na sejalno krivuljo vsebujejo najmanj in največ zračnih votlin. Na podlagi rezultatov grobega modela smo prišli do naslednjih zaključkov:

- Izkaže se, da dobimo boljšo povezavo med triosnim testom in preizkusom odpornosti proti nastanku kolesnic, če v linearni model vključimo še podatke o bitumnu in sestavi asfaltne zmesi.

- Kriteriju notranje in zunanje validacije najbolj ustreza model 6, ki kot vhodne parametre obravnava vrednost trajne deformacije iz triosnega testa ϵ_{10000} , delež bitumna, presejek skozi sito 2 mm ter razmerje S/F_t . Visok determinacijski koeficient med dejansko in z modelom 6 izračunano globino kolesnice je pokazatelj, da lahko s tem modelom kvalitativno napovemo kolesnice. To pomeni, da lahko asfaltne zmesi razdelimo glede na obnašanje pri višji temperaturi, ne moremo pa kvantitativno napovedati globine kolesnice.
- Model 6 je primeren za hitro rangiranje različnih asfaltnih zmesi nazivne zrnivosti 11 mm pri povišani temperaturi.
- Razširitev grobega modela na asfaltne zmesi različnih nazivnih zrnivosti ni mogoča, saj modeli pri razširitvi na zmesi z zrnavostjo 8 mm ne delujejo. Vzrok za to je obstoj skrite sistemske spremenljivke, ki pri razširitvi modela povzroči linearni zamik. Najverjetneje je skrita sistemska spremenljivka to, da so zmesi pripravljene in analizirane (razen triosni test in preizkus nastajanja kolesnic) v različnih laboratorijih, medtem ko so zmesi, ki smo jih uporabili za modeliranje, pripravljene in preizkušene sistematično pod kontroliranimi pogoji v enem laboratoriju. Poleg tega na trajne deformacije močno vplivajo dodatki.
- Za izboljšanje modelov, da bi se lahko ekstrapolirali na asfaltne zmesi, ki vsebujejo še druge vrste agregata, bi bilo potrebno upoštevati še lastnosti kamnitega materiala, ki pa jih je težko kvantitativno ovrednotiti (kakovost finih delcev, oblika grobih zrn, delež drobljenih zrn v zmesi grobih zrn, odpornost grobih zrn proti drobljenju, odpornost proti obrabi itd.).

V petem poglavju smo modelirali parametre trajnega deformiranja asfaltne zmesi pri višji temperaturi z umetnimi nevronskimi mrežami in linearnim modelom. Na podlagi rezultatov pridemo do naslednjih zaključkov:

- Z umetnimi nevronskimi mrežami in linearnim modelom smo omogočili hitrejše in cenejše ocenjevanje parametrov trajnega deformiranja asfaltnih zmesi, ki imajo pomembno vlogo pri napovedovanju obnašanja posamezne vrste asfalta na vozišču.
- Umetne nevronske mreže so v primeru, ko ne odkrijejo nekih splošnih povezav med podatki, slabše od linearnega modela. To pa je odvisno od narave problema.
- Za modeliranje ϵ_{1000} je bolj ustrezen linearni model, ki upošteva tudi vpliv vsebnosti zračnih votlin, stopnje zapolnjenosti votlin in votlin v kamniti zmesi.
- Za modeliranje stopnje lezenja f_c je bolj ustrezen nevronski model, ki ne upošteva vpliva vsebnosti zračnih votlin, stopnje zapolnjenosti votlin in votlin v kamniti zmesi.

V šestem poglavju smo predstavili uporabo metode odboja strižnih ultrazvočnih valov za kontinuirano spremljanje procesa strjevanja cestogradbenih in polimernih bitumnov. Iz rezultatov lahko izluščimo naslednje glavne zaključke:

- Uporaba visoko temperaturno odpornih merilnih senzorjev USWR-4 inštrumenta omogoča kontinuirano spremljanje procesa strjevanja bitumna v širokem temperaturnem intervalu.
- Zaradi večanja togosti materiala se sprememba strižnega odbojnega koeficienta Δr večja s padanjem temperature materiala tako za cestogradbene bitumene kot za polimerne bitumne. To pomeni, da razvoj Δr s temperaturo jasno odraža proces strjevanja bitumna. Med celotnim procesom so zveze $\Delta r - T$ linearne za vse vrste bitumnov.

- Razlike v razvoju $\Delta r - T$ krivulj za različne vrste bitumnov kažejo na to, da lahko USWR metoda predstavlja napredno nedestruktivno tehniko za spremljanje procesa strjevanja različnih vrst bitumenskega veziva.
- Statistična analiza je potrdila ponovljivost USWR metode in s tem tudi njeno uporabnost za spremljanje procesa strjevanja bitumna.
- Zaradi njene praktičnosti, lahke izvedbe in zmožnosti uporabe v laboratoriju ali in-situ lahko predstavljena tehnika postane alternativa nekaterim ostalim standardiziranim metodam za določevanje lastnosti materialov.

V splošnem bi lahko zaključili, da vsi pridobljeni rezultati kažejo na zahtevnost in kompleksnost obnašanja asfalta in posredno bitumna, kot njegove pomembne sestavine in na veliko parametrov, ki so med seboj zapleteno povezani, kljub veliki bazi. S tem se odpirajo nova poglavja in vprašanja za nadaljnje delo.

8 POVZETEK

Doktorska disertacija je sestavljena iz štirih vsebinskih delov. V prvem delu vzpostavimo bazo podatkov iz obstoječih meritev različnih asfaltnih zmesi na inštitutu za gradbene materiale IGMAT d.d. (Interna baza meritev, Igmatt, 1998 – 2009) v desetletnem časovnem obdobju. Za zbrane podatke nas zanima, ali so vplivi faktorjev in njihovih interakcij statistično značilni. Zanimajo nas predvsem korelacije med obstoječimi mehanskimi eksperimenti in ostalimi lastnostmi asfaltnih zmesi, t.j. med stabilnostjo in ostalimi lastnostmi ter med tečenjem in ostalimi lastnostmi. Statistično primerjamo povprečne vrednosti, variance in korelacije med merjenimi količinami. Najprej podatke razdelimo glede na dve časovni obdobji v katerih so meritve izvedene. S tem ugotavljamo, ali je prišlo do razlik pri izvajanju meritev ter ali je prišlo do razlik med povezavami posameznih meritev v časovnih obdobjih. Z naključnim deljenjem podatkov v dve skupini ugotovimo, če je kateri od podatkov močno oddaljen od ostalih in ga na ta način tudi izločimo. Z večkratnim, zaporednim in naključnim deljenjem podatkov v dve skupini pa določimo meje za razlike korelacijskih koeficientov posameznih lastnosti s stabilnostjo in tečenjem. Razvoj take metode nam omogoča ugotavljanje vpliva sprememb na rezultate meritev, ki jih ne moremo pripisati naključju, ampak nekim drugim dejavnikom (sprememba standardov, sprememba naprav za izvajanje meritev, osebe, ki izvajajo meritve in podobno). Poleg razvoja opisane statistične metode modeliramo delež votlin v asfaltni zmesi AC 22 ter delež votlin v zmesi kamnitega materiala za več različnih asfaltnih zmesi še z umetnimi nevronskimi mrežami in linearnim modelom. Ugotavljamo, katere podatke vključimo med vhodne parametre modela in predstavimo dva različna programa za modeliranje z nevronskimi mrežami.

V drugem delu se ukvarjamo z iskanjem povezave med triosnim testom in preskusom tvorbe kolesnic v asfaltni plasti za štiri osnovne vrste asfaltov nazivne zrnivosti 11 mm, ki se uporabljajo v Sloveniji. Poleg tega vse štiri osnovne asfaltne zmesi pripravimo s cestogradbenim in s polimeri modificiranim bitumnom. Na ta način dobimo t.i. grobi model, katerega osnovni namen je opis obnašanja osnovnih tipov asfaltov. Model obravnava asfaltne zmesi, ki glede na sejalno krivuljo vsebujejo najmanj in največ zračnih votlin. Izkaže se, da je potrebno v modeliranje vključiti še podatek o bitumnu in sestavi asfaltne zmesi. Za primere, ko manjka kateri od rezultatov meritev ali nismo prepričani v njegovo natančnost, pripravimo več različnih modelov, ki vsebujejo različne vhodne parametre. Modele validiramo na asfaltnih zmesih SMA 11 B20/30 LN in SMA 11 PmB10/40-65 LN ter jih skušamo razširiti še na druge asfaltne zmesi z drugačnimi vhodnimi materiali, sejalnimi krivuljami in sestavo. Ugotovimo, da je izbrani model primeren za hitro rangiranje različnih asfaltnih zmesi nazivne zrnivosti 11 mm pri povišani temperaturi.

V tretjem delu doktorske disertacije je prikazano modeliranje parametrov trajnega deformiranja asfaltnih zmesi. Deformacijske parametre dobimo s cikličnimi, triosnimi testi na asfaltnih zmesih z nazivno zrnivostjo 11 mm. Na podlagi standardnih preiskav (sejalna analiza, ugotavljanje deleža bitumna, določanje prostorninske in največje gostote asfaltne zmesi, deleža zračnih votlin v asfaltni zmesi, stopnje zapolnjenosti votlin in deleža votlin v zmesi kamnitega materiala) in geometrije preizkušancev želimo čim hitreje oceniti trajno deformacijo po 1000 ciklih obremenjevanja in stopnjo lezenja f_c . Ugotavljamo, katere podatke vključimo med vhodne parametre modela in predstavimo dva različna programa za modeliranje z nevronskimi mrežami.

V zadnjem delu je prikazana možnost uporabe nedestruktivne metode odboja strižnih ultrazvočnih valov, ki na področju bitumnov še ni bila uporabljena. Metoda sloni na uporabi merilnega inštrumenta USWR-4 Hardening metra, ki deluje na principu konstantnega merjenja strižnega odbojnega koeficienta na stiku med testnim materialom in kvarčno sondo. Štiri merilne sonde omogočajo izvajanje meritev na štirih vzorcih hkrati, kar je pomembno predvsem pri izvajanju meritev neposredno na terenu. Uporablja se ustrezna programska oprema za spremljanje razvoja strižnega odbojnega koeficienta in temperature v odvisnosti

od časa neposredno na računalniškem zaslonu ter shranjevanje podatkov za kasnejšo obdelavo rezultatov. V okviru raziskave so bili testirani trije cestogradbeni bitumni in dva s polimeri modificirana bitumna. Eksperimentalni rezultati kažejo na občutljivost strižnega odbojnega koeficienta na sestavo bitumna in s tem primernost ultrazvočne metode za ugotavljanje lastnosti različnih tipov bitumnov.

9 SUMMARY

This doctoral thesis consists of four different parts. In the first part the database for various pavement mixtures, which were tested at the building materials institute Igmat Ljubljana (Interna baza meritev, Igmat, 1998 – 2009) from 1998 to 2009, was established. We are interested in whether the effects of factors and their interactions are statistically significant, mainly in correlation between the existing mechanical experiments and other properties of asphalt mixtures. The statistic analysis compares mean values, variances and correlations between measured quantities. Firstly, we have divided all measurements into two time periods to determine whether there are differences between measurements and differences between the connections of individual measurements. Secondly, the data were randomly divided into two groups to determine if any value of measurements is outlier. In order to obtain limits for differences of correlation coefficients for stability and flow, we have repeatedly and randomly divided data into two groups. With the method described we established the effect of changes on measurements, which cannot be attributed solely to coincidence but some other external factors, such as modification of standards, replacement of equipment or changes in staff. In addition, the modeling of air voids content of asphalt mixture AC 22 and air voids content in aggregate mixture for different asphalt mixtures with artificial neural networks and linear regression is represented. We deal with the selection of data for input parameters and represent two different programs for modeling with artificial networks.

In the second part we have compared the results of triaxial test and wheel tracking test for four basic types of asphalt mixtures, regularly used in Slovenia. All tested asphalt mixtures have maximal grain size 11 mm and were prepared with road bitumen and with polymers modified bitumen. We get robust model, whose primary purpose is to describe the behavior of the basic types of asphalt. The model considers asphalt mixtures which have minimum and maximum air voids content according to the sieve curves. It turns out that it is necessary to include the properties of bitumen and asphalt mixtures composition. Different models, which contain various input parameters, are prepared for the case of missing any of the measurements or in case of its inaccuracy. Models are validated on asphalt mixtures SMA 11 B20/30 LN and SMA 11 PmB10/40-65 LN. We have tried to extense them to other asphalt mixtures with different input materials, sieve curves and composition. The main conclusion is that the selected model is suitable for fast classification of different asphalt mixtures with nominal grain size of 11 mm at high temperatures.

In the third part of the doctoral thesis the modeling of parameters of permanent deformation of asphalt mixtures is represented. The deformation parameters are obtained by cyclic triaxial test on asphalt mixtures with a nominal grain size of 11 mm.

On the basis of standard tests (sieve analysis, determination of bitumen content, determination of bulk density and maximum density of asphalt mixtures, air voids content in asphalt mixtures, voids filled with binder and air voids content in aggregate mixture) and geometry of specimens we tried to evaluate permanent deformation after 1000 cycles of loading and creep rate f_c . We were dealing with the selection of data for input parameters and representing two different programs for modeling with artificial networks.

The last part presents the use of non - destructive ultrasonic shear wave reflection (USWR) method in the field of bituminous materials. The technique relies on the use of a measuring instrument called USWR-4 Hardening meter. It works on the principle of continuous measurement of change of a shear wave reflection coefficient at the contact between the test material and quartz probe. Four probes enable measurements on four samples simultaneously, which is especially important when performing measurements directly in - situ. An appropriate software to monitor the development of shear wave reflection coefficient

and temperature as a function of time directly on the computer screen and data storage for later processing of the results was developed. Three different types of paving grade and two polymer modified bitumens were tested. Experimental results show the sensitivity of the shear wave reflection coefficient to the composition of bitumens and hence the suitability of the method for determination of characteristics of the various types of bitumens.

VIRI

Analysis of available data for validation of bitumen tests - BiTVal. Report on phase 1. 201 str.

Anderson, T. W. 2003. An introduction to multivariate statistical analysis. Third edition. Wiley series in probability and statistics: 752 str.

Asphalt research program. Permanent deformation response of asphalt aggregate mixes. The strategic highway research program, SHRP - A - 415. 1994. Institute of transportation studies, University of California.

Blab, R. 2013. Performance - based asphalt mix and pavement design. Romanian journal of transport infrastructure, 2: 21 - 38.

Bredenhann, S. J., van de Ven, M. F. C. 2004. Application of artificial neural networks in the back - calculation of flexible pavement layer moduli from deflection measurements. Enthen consultants South Africa, TU Delft Netherlands.

Brown, E.R., Kandhal, P.S., Zhang, J. 2001. Performance testing for hot mix asphalt. NCAT Report 01 - 05, Auburn, Auburn University.

Calderon Ulloa, A. 2009. Characteristics of dynamic triaxial testing of asphalt mixtures. MSc Thesis. Reno, University of Nevada.

Chang, C. - H., Pal, N. 2008. Testing on the common mean of several normal distributions. Computational statistics & data analysis, 53: 321 - 333.

Chotard, T., Gimet - Brert, N., Smith, A., Fargeto, D., Bonnet, J.P., Gault, C. 2001. Application of ultrasonic testing to describe the hydration of calcium aluminate cement at the early age. Cement and concrete research, 31(3): 405 - 412.

Chou, J. - S., Yang, I - T., Chong, W.K. 2009. Probabilistic simulation for developing likelihood distribution of engineering project costs. Automation in construction, 18: 570 - 577.

Chung, C.W. 2010. Ultrasonic wave reflection measurements on stiffening and setting of cement paste. PhD Thesis. USA, IL, Urbana, Urbana - Champaign, University of Illinois.

Collop, A.C., Khanzada, S. 2001. Permanent deformation in idealized bituminous composites. School of civil engineering, University of Nottingham, UK. Proceedings of the institution of mechanical engineers, part L: Journal of materials design and applications, London, SAGE.

Dolinšek, J., Jeglič, P., Apih, T., Lahajnar, G., Naglič, O., Sever, A. 2000. Temperature - dependent bitumen softening studied by NMR. Journal of physics D: Applied physics, 33: 1615 - 1624.

Erkens, S.M.J.G. 2002. Asphalt concrete response. PhD Thesis. Delft, Delft university of technology.

Flood, I., Christophilos, P. 1996. Modeling construction processes using artificial neural networks. Automation in construction, 4: 307 - 320.

Foo, K.Y. 1994. Predicting rutting in hot mix asphalt. PhD Thesis. Auburn, Auburn University.

Frank, E., Holmes, G., Mayo, M., Pfahringer, B., Smith, T., Witten, I. 2012. Data Mining with Open Machine Learning Software: aplikacija Weka 3. <http://www.cs.waikato.ac.nz/ml/weka/> (Pridobljeno junij 2014).

Franz, G., von der Heyde, M., Bulthoff, H.H. 2005. An empirical approach to the experience of architectural space in virtual reality - exploring relations between features and affective appraisals of rectangular indoor spaces. *Automation in construction*, 14: 165 - 172.

Frederick, J.R. 1965. Ultrasonic Engineering, Inc. USA, John Wiley and Sons.

Garba, R. 2002. Permanent deformation properties of asphalt concrete mixtures. PhD Thesis. Trondheim, Norwegian university of science and technology.

Gardete, D., Picado - Santos, L., Pais, J. 2005. Permanent deformation characterization of bituminous mixtures: laboratorial tests. http://repositorium.sdum.uminho.pt/bitstream/1822/4940/1/Gardete_CI_2005.pdf. (Pridobljeno 5.5.2014).

Gestrata. 2010. Asphalt Handbuch. Seventh edition, Wien.

Goktepe Burak, A., Agar, E., Hilmi Lav, A. 2006. Advances in backcalculating the mechanical properties of flexible pavements. *Advances in engineering software*, 37: 421 - 431.

Graham, L. D., Forbes, D. R., Smith, S. D. 2006. Modeling the ready mixed concrete delivery system with neural networks. *Automation in construction*, 15: 656 - 663.

Halit, Ö., Atakan A., Süreyya, T., Fazil, C. 2008. Laboratory performance of the elastomer – modified asphalt mixtures. *Building and environment*, 43: 1270 - 1277.

Haritonovs, V., Zumanis, M., Brencis, G., Smirnovs, J. 2013. Asphalt concrete performance with conventional and waste aggregates. *International journal of pavement research and technology*, 6(5): 505 - 510.

Haykin S. 1994. *Neural Networks: A Comprehensive Foundation*. New York, Macmillan College publishing Company, Inc.: 216 f.

Hays, W. 1991. *Statistics*. Fifth edition. Harcour Brace College Publishers, University of Texas at Austin: 1112 str.

Hola, B., Schabowicz, K. 2010. Estimation of earthworks execution time costs by means of artificial neural networks. *Automation in construction*, 19: 570 - 579.

Huurman, M. 2000. Cyclic triaxial tests on asphalt concrete relating to rutting. 2th Eurasphalt & Eurobitume, Barcelona, pp. 351 - 363.

Interna baza meritev lastnosti posameznih asfaltnih mešanic za različne naročnike v obdobju 1998 - 2009. Igmat d.d.

Kartam, N., Flood, I., Garrett, J. H. 1997. *Artificial neural networks for civil engineers: fundamentals and applications*. New York, American society of civil engineers: 216 f.

Kewalramani, W. A., Gupta, R. 2006. Concrete compressive strength prediction using ultrasonic pulse velocity through artificial neural networks. *Automation in construction*, 15: 374 - 379.

Leu, S. S., Chen, C. N., Chang, S. L. 2001. Data mining for tunnel stability: neural network approach. *Automation in construction*, 10: 429 - 441.

Lionetto, F., Maffezzoli, A. 2008. Polymer characterization by ultrasonic wave propagation. *Advances in polymer technology*, 27(2): 63 - 73.

Luminari, M., Fidato, A. 1998. A state of the art report of the mix design. In Franken, L. (ed), *Bituminous binders and mixes*. Report of RILEM technical Committee 152 - PBM.

Mallick, R.B., Ahlrich, R., Brown, E.R. 1995. Potential of dynamic creep to predict rutting. *ASTM SPT 1256*.

Matuško, J., Petrović, I., Perić, N. 2008. Neural network based tire/road friction road estimation. *Engineering application of artificial intelligence*, 21: 442 - 456.

Miao, W., Chiou, P. 2008. Confidence intervals for the difference between two means. *Computational statistics & data analysis*, 52: 2238 - 2248.

Molenaar, J.M.M., Molenaar, A.A.A. 2000. Susceptibility to permanent strain of asphalt in the dynamic triaxial compression creep test. *2th Eurasphalt & Eurobitume*, Barcelona, pp. 490 - 499.

Mouton, Y. 2003. Organic materials in civil engineering.
http://books.google.si/books?id=5_Jkf1VSY7AC&printsec=frontcover&hl=sl#v=onepage&q&f=false. (Pridobljeno 22.10.2013).

Ozgan, E. 2009. Fuzzy logic and statistical - based modelling of the Marshall stability of asphalt concrete under varying temperatures and exposure times. *Advances in engineering software*, 40: 527 - 534.

Ozturk, T., Krogel, O., Grubl, P., Popovics, J.S. 2006. Improved ultrasonic wave reflection technique to monitor the setting of cement - based materials. *NDT e int*, 39(4): 258 - 263.

Partl, M., N., Chailleux, E. 2013. Advances in interlaboratory testing and evaluation of bituminous materials. A - state - of - the - art report of RILEM technical Committee 206 - ATB.

Pellinen, T.K., Song, J., Xiao, S. 2004. Characterization of hot mix asphalt with varying air voids content using triaxial shear strength test. *8th Conference on asphalt pavements for Southern Africa*, South Africa.

Raghu Prasad, B. K., Eskandari, H., Venkatarama Reddy, B. V. 2009. Prediction of compressive strength of SCC and HPC with high volume fly ash using ANN. *Construction and building materials*, 23: 117 - 128.

Ramanathan, K., Stallings, R.L., Newsome, J.R. 1991. An ultrasonic technique for the measurement of adhesion of asphalt to aggregate. *Journal of adhesion science and technology*, 5(3): 181 - 190.

Reinhardt, H.W., Grosse, C.U. 2004. Continuous monitoring of setting and hardening of mortar and concrete. *Construction and building materials*, 18: 145 - 154.

Remišova, E. 2012. Resistance to permanent deformation in binder content and film thickness viewpoint. *Roczniki inżynierii budowlanej – zeszyt*: 6 str.

Richard, J.D. 1965. Ultrasonic viscosimeter US 3194057 A.

<http://www.google.com/patents/US3194057>. (Pridobljeno 3.10.2013).

Roos, R., Karcher, C. 2009. Asphalt with high resistant to permanent deformation and its testing in the laboratory. Bulgaria, International conference UACEG: Science and practice, University of architecture, civil engineering and geodesy: 11str.

Rumelhart, D. E., McClelland, J. L., the PDP Research Group. 1986. Parallel Distributed Processing, Volume 1: Foundations. Cambridge, The MIT Press: 501 f.

Saltan, M., Sezgin, H. 2007. Hybrid neural network and finite element modeling of sub - base layer material properties in flexible pavements. Materials and design, 28: 1725 - 1730.

Saltan, M., Terzi, S. 2008. Modeling deflection basin using artificial neural networks with cross - validation technique in backcalculating flexible pavement layer moduli. Advances in engineering software, 39: 588 - 592.

Sukru, T.O., Oruc, S. 2008. Neural network model for resilient modulus of emulsified asphalt mixtures. Construction and building materials, 22: 1436 - 1445.

Sun, Z., Voigt, T., Shah, S.P. 2006. Rheometric and ultrasonic investigations of viscoelastic properties of fresh Portland cement pastes. Cement and concrete research. 36(2): 278 - 287.

Tapkin, S., Cevik, A., Usar, U. 2009. Accumulated strain prediction of polypropylene modified marshall specimens in repeated creep test using artificial neural networks. Expert systems with applications, 36: 11186 - 11197.

The University of Chicago. 1994. Method for measuring liquid viscosity and ultrasonic viscometer.

<http://www.google.com/patents/US5365778>. (Pridobljeno 3.10.2013).

Topcu, I. B., Boga, A. R., Hocaoglu, F. O. 2009. Modeling corrosion currents of reinforced concrete using ANN. Automation in construction, 18: 145 - 152.

Topcu, I. B., Saridemir, B. 2006. Prediction of rubberized concrete properties using artificial neural network and fuzzy logic. Construction and building materials, 22: 532 - 540.

Topping, B. H. V., Bahreininejad, A. 1997. Neural computing for structural mechanics. Edinburg, Saxe - Coburg publications: 176 f.

Touran, A., Wiser, E.P. 1992. Monte Carlo technique with correlated random variables. Journal of construction engineering and management, 118: 258 - 272.

Trtnik, G. 2009. Uporaba ultrazvočne metode za analizo vezanja in strjevanja betona. Doktorska disertacija. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Konstrukcijska smer. 152 str.

Trtnik, G., Kavčič, F., Turk, G. 2008. The use of artificial neural networks in adiabatic curves modeling. Automation in construction, 18: 10 - 15.

Trtnik, G., Gams, M. 2014. Recent advances of ultrasonic testing of cement based materials at early ages. Ultrasonics, 54(1): 66 - 75.

Trtnik, G., Valič, M.I., Turk, G. 2013. Measurement of setting process of cement pastes using non - destructive ultrasonic shear wave reflection technique. NDT e int, 56: 65 - 75.

Turk, G. 2012. Verjetnostni račun in statistika. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo: 264 str.

Tušar, M. 2007. Strokovni prispevki. Novosti pri laboratorijskih preiskavah. ZAS: Od skupščine do skupščine 11, ZAS: 23 - 26.

Tušar, M., Kalman, B. 2010. Raziskava obnašanja cestogradbenih in s polimeri modificiranih bitumnov. Izsek iz projekta SPENS. Portorož, Slovenski kongres o cestah in prometu: 1286 - 1293.

Tušar, M., Novič, M. 2009. Data exploration on standard asphalt mix analyses. Journal of chemometrics, 23: 283 - 293.

Valič, M.I. 2000. Hydration of cementitious materials by pulse echo USWR. Method, apparatus and application examples. Cement and concrete research, 30(10): 1633 - 1640.

Valič, M.I., Stepišnik, J. 1998. A study of cement pastes by reflection of ultrasonic shear waves. Part I: Apparatus, experimental method and application examples. KZT, 32(6): 551 - 560.

Valič, M.I., Stepišnik, J. 1998. An ultrasonic shear wave apparatus and its applications in materials research. 34th International Conference on microelectronics, devices and materials, Rogaška Slatina, Slovenia.

Valič, M.I., Vuk, T. 2000. A study of the influence of additives and admixtures on the hydration of cement with pulsed USWR method. KZLTET, 34(5): 249 - 255.

Voigt, T. 2004. The application of an ultrasonic shear wave reflection method for nondestructive testing of cement - based materials at early ages. PhD Thesis. Leipzig, Universität Leipzig.

Wall, D.M. 1996. Distributions and correlations in Monte Carlo simulation. Construction management and economics, 15: 241 - 258.

Wang, Y. R., Gibson Jr. 2010. A study of preproject planning and project success using ANNs and regression models. Automation in construction, 19: 341 - 346.

Zavrtanik, N., Ljubič, A., Kavčič, F., Turk, G. 2010. Kako poiskati razloge za spremenjene statistične lastnosti asfaltnih mešanic. Gradbeni vestnik, 59: 219 - 224.

Zavrtanik, N. 2008. Uporaba umetnih nevronske mreže za oceno trdnosti lesenih elementov. Diplomsko naloga. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Konstrukcijska smer. 81 str.

Zhang, J., Brown, E.R., Kandhal, P.S., West, A. 2005. An overview of fundamental and simulative performance tests for hot mix asphalt. Journal of ASTM international. 2(5).

Zhi, S., Wing Gun, W. 2009. Nonlinear properties analyses on rutting behaviour of bituminous materials with different air void contents. Construction and building material, 23: 3492 - 3498.

Žmavc, J. (urednik). 2011. Asfalt. ZAS, Ljubljana. 334 str.

STANDARDI

1. SIST EN 12697 - 25: 2005 Bitumenske zmesi - Preskusne metode za vroče asfaltne zmesi - 25. del: Ciklični tlačni preskus.
2. SIST EN 12697 - 22: 2004+A1: 2007 Bitumenske zmesi - Preskusne metode za vroče asfaltne zmesi - 22. del: Preskus nastajanja kolesnic.
3. SIST EN 12697 - 34: 2004+A1: 2007 Bitumenske zmesi - Preskusne metode za vroče asfaltne zmesi - 34. del: Preskus po Marshallu.
4. SIST EN 12697 - 1: 2012 Bitumenske zmesi - Preskusne metode za vroče asfaltne zmesi - 1. del: Topni delež veziva.
5. SIST EN 12697 - 2: 2002+A1: 2007 Bitumenske zmesi - Preskusne metode za vroče asfaltne zmesi - 2. del: Ugotavljanje zrnivosti.
6. SIST EN 12697 - 6: 2004+A1: 2007 Bitumenske zmesi - Preskusne metode za vroče asfaltne zmesi - 6. del: Ugotavljanje prostorninske gostote bitumenskih preskušancev.
7. SIST EN 12697 - 30: 2004+A1: 2007 Bitumenske zmesi - Preskusne metode za vroče asfaltne zmesi - 30. del: Priprava preskušancev z udarnim zgoščevalnikom.
8. SIST EN 12697 - 5: 2004+A1: 2007 Bitumenske zmesi - Preskusne metode za vroče asfaltne zmesi - 5. del: Ugotavljanje največje gostote.
9. SIST EN 1426:2007. Bitumen in bitumenska veziva - Določanje penetracije z iglo.
10. DIN 52013:2007. Bitumen and bituminous binders - Determination of ductility.
11. SIST EN 12591/A:2009. Bitumen in bitumenska veziva - Specifikacije za cestogradbene bitumne.
12. SIST EN 1427:2007. Bitumen in bitumenska veziva - Določanje zmehčišča - Metoda prstana in kroglice.
13. SIST EN 13398:2010. Bitumen in bitumenska veziva - Določevanje elastičnega povratka modificiranih bitumnov.
14. SIST EN 12593:2007. Bitumen in bitumenska veziva - Določanje pretrgališča po Fraassu.
15. SIST EN 12596:2007. Bitumen in bitumenska veziva - Določanje dinamične viskoznosti z metodo s kapilarnim vakuumom.
16. DIN 52013:2007. Bitumen und bitumenhaltige Bindemittel - Bestimmung der Duktilität .

SEZNAM PRILOG

PRILOGA A: KORELACIJSKI KOEFICIENTI ZA DVE ČASOVNI OBDOBJI IN ZA DVE SKUPINI, KJER SO MERITVE RAZDELJENE NAKLJUČNO ZA AC 11, AC 16 IN AC 32.

PRILOGA A:

A1: Korelacijski koeficienti za asfaltno zmes AC 11

Preglednica 1: Korelacijski koeficienti za dve obdobji in njihove razlike.
Table 1: The correlation coefficients for two periods and their differences.

	r_{xy}				razlike v r_{xy} med obdobjema	
	1998/2005		2006/2009		S	F
	S	F	S	F		
PK	-0.004	0.015	-0.149	0.417	0.144*	0.402*
Penetracija	-0.025	0.113	0.038	-0.335	0.063	0.448*
Viskoznost	0.028	-0.006	-0.140	0.407	0.168	0.413*
IP	-0.021	0.119	-0.186	0.262	0.165*	0.143*
Delež bitumna	-0.322	-0.271	0.089	-0.086	0.411*	0.185*
Sito 0.09 mm	-0.067	0.083	0.069	-0.011	0.137	0.094
Sito 0.25 mm	-0.120	0.002	0.257	-0.238	0.376*	0.240*
Sito 0.71 mm	-0.264	-0.237	0.351	-0.451	0.615*	0.214*
Sito 2.0 mm	-0.176	-0.208	0.278	-0.454	0.454*	0.246*
Sito 4.0 mm	-0.198	-0.333	0.249	-0.417	0.447*	0.084
Sito 8.0 mm	-0.196	-0.357	0.411	-0.438	0.607*	0.080
Sito 11.2 mm	-0.053	-0.189	0.388	-0.253	0.441*	0.064
Prostor. gost.	0.530	0.587	0.275	0.116	0.255*	0.471*
Največja gost.	0.565	0.588	0.092	0.282	0.473*	0.306*
Vsebnost zrač. votl.	0.226	0.159	-0.269	0.280	0.494*	0.122
Stopnja zapol. votl.	-0.203	-0.123	0.250	-0.226	0.453*	0.103
Votline v kam. mat.	0.226	0.202	-0.188	0.275	0.414*	0.073
Največja gost. kam. mat.	0.567	0.601	0.126	0.270	0.441*	0.331*

*Odstopanja so prevelika, da bi bila lahko naključna.

Preglednica 2: Korelacijski koeficienti za dve skupini, kjer so meritve naključno premešane in njihove razlike.

Table 2: The correlation coefficients for two groups where measurements are randomly divided and their differences.

	r_{xy}				Razlike v r_{xy} med 1. in 2. skupino podatkov	
	1. skupina podatkov		2. skupina podatkov		S	F
	S	F	S	F		
PK	-0.012	0.259	-0.021	0.285	0.009	0.026
Penetracija	-0.003	-0.090	-0.071	-0.147	0.067	0.057
Viskoznost	-0.002	0.089	-0.026	0.186	0.024	0.096
IP	-0.019	0.275	-0.083	0.269	0.064	0.006
Delež bitumna	-0.212	-0.150	-0.195	-0.032	0.017	0.118
Sito 0.09 mm	-0.030	0.113	-0.010	0.140	0.020	0.027
Sito 0.25 mm	-0.022	0.039	-0.046	0.072	0.025	0.033
Sito 0.71 mm	-0.106	-0.135	-0.127	-0.185	0.021	0.051
Sito 2.0 mm	-0.027	-0.129	-0.051	-0.228	0.023	0.099
Sito 4.0 mm	-0.067	-0.273	-0.032	-0.303	0.035	0.030
Sito 8.0 mm	-0.033	-0.306	-0.040	-0.322	0.008	0.017
Sito 11.2 mm	0.056	-0.118	0.086	-0.106	0.030	0.011
Prostor. gost.	0.477	0.402	0.431	0.497	0.047	0.096
Največja gost.	0.451	0.433	0.437	0.495	0.014	0.062
Vsebnost zrač. votl.	0.046	0.145	0.094	0.086	0.048	0.059
Stopnja zapol. votl.	-0.049	-0.116	-0.086	-0.027	0.037	0.089
Votline v kam. mat.	0.054	0.153	0.140	0.216	0.086	0.063
Največja gost. kam. mat.	0.457	0.429	0.451	0.521	0.006	0.092

A2: Korelacijski koeficienti za asfaltno zmes AC 16

Preglednica 3: Korelacijski koeficienti za dve obdobji in njihove razlike.
Table 3: The correlation coefficients for two periods and their differences.

	r_{xy}				Razlike v r_{xy} med obdobjema	
	1998/2005		2006/2009		S	F
	S	F	S	F		
PK	-0.019	0.029	-0.082	0.186	0.064	0.158
Penetracija	-0.256	-0.118	-0.076	-0.073	0.180*	0.045
Viskoznost	0.221	0.054	0.031	0.259	0.190*	0.205*
IP	-0.220	-0.050	-0.219	0.159	0.001	0.209*
Delež bitumna	0.049	0.319	-0.092	0.001	0.141	0.318*
Sito 0.09 mm	0.175	0.419	-0.123	0.202	0.298*	0.217*
Sito 0.25 mm	0.105	0.217	0.077	0.193	0.028	0.024
Sito 0.71 mm	-0.108	-0.080	0.166	-0.071	0.274*	0.009
Sito 2.0 mm	0.026	0.003	0.077	-0.148	0.051	0.151
Sito 4.0 mm	0.212	0.230	0.072	-0.034	0.140	0.263*
Sito 8.0 mm	0.289	0.391	-0.122	0.103	0.411*	0.288*
Sito 11.2 mm	0.191	0.316	-0.120	-0.118	0.311*	0.434*
Sito 16 mm	-0.078	-0.093	0.093	-0.303	0.171	0.210*
Prostor. gost.	0.213	0.464	0.097	0.494	0.116	0.030
Največja gost.	0.233	0.038	0.244	0.477	0.011	0.439*
Vsebnost zrač. votl.	-0.040	-0.382	0.089	-0.145	0.130	0.236*
Stopnja zapol. votl.	0.055	0.404	-0.095	0.153	0.150	0.251*
Votline v kam. mat.	0.069	-0.119	0.082	-0.156	0.013	0.036
Največja gost. kam. mat.	0.297	0.291	0.225	0.535	0.072	0.244*

*Odstopanja so prevelika, da bi bila lahko naključna.

Preglednica 4: Korelacijski koeficienti za dve skupini, kjer so meritve naključno premešane in njihove razlike.

Table 4: The correlation coefficients for two groups where measurements are randomly divided and their differences.

	r_{xy}				Razlike v r_{xy} med 1. in 2. skupino podatkov	
	1. skupina podatkov		2. skupina podatkov		S	F
	S	F	S	F		
PK	-0.076	0.147	-0.049	0.221	0.026	0.074
Penetracija	-0.243	-0.026	-0.197	-0.023	0.046	0.003
Viskoznost	0.206	0.003	0.198	0.004	0.008	0.001
IP	-0.273	0.142	-0.206	0.219	0.067	0.077
Delež bitumna	-0.011	0.293	0.013	0.287	0.025	0.006
Sito 0.09 mm	0.060	0.389	0.170	0.405	0.110	0.016
Sito 0.25 mm	0.049	0.281	0.138	0.209	0.089	0.072
Sito 0.71 mm	-0.089	0.034	-0.048	-0.079	0.041	0.113*
Sito 2.0 mm	0.017	0.043	0.011	-0.083	0.006	0.126
Sito 4.0 mm	0.162	0.208	0.161	0.150	0.001	0.058
Sito 8.0 mm	0.195	0.359	0.147	0.358	0.048	0.001
Sito 11.2 mm	0.082	0.276	0.143	0.255	0.062	0.021
Sito 16 mm	-0.053	-0.049	-0.087	-0.067	0.034	0.018
Prostor. gost.	0.161	0.472	0.172	0.442	0.011	0.030
Največja gost.	0.216	0.170	0.267	0.137	0.051	0.034
Vsebnost zrač. votl.	-0.003	-0.321	0.003	-0.305	0.006	0.015
Stopnja zapol. votl.	0.010	0.339	0.013	0.329	0.004	0.009
Votline v kam. mat.	0.058	-0.095	0.092	-0.100	0.034	0.005
Največja gost. kam. mat.	0.253	0.358	0.303	0.322	0.050	0.036

*Odstopanja so prevelika, da bi bila lahko naključna.

A3: Korelacijski koeficienti za asfaltno zmes AC 32

Preglednica 5: Korelacijski koeficienti za dve obdobji in njihove razlike.
Table 5: The correlation coefficients for two periods and their differences.

	r_{xy}				Razlike v r_{xy} med obdobjema	
	1998/2005		2006/2009		S	F
	S	F	S	F		
PK	-0.181	-0.216	-0.164	0.107	0.017	0.323*
Penetracija	0.178	0.235	-0.080	-0.145	0.258*	0.380*
Viskoznost	-0.092	-0.083	0.043	0.187	0.135	0.271*
IP	-0.112	-0.116	-0.228	0.040	0.117*	0.156*
Delež bitumna	-0.121	-0.101	-0.038	0.391	0.082	0.493*
Sito 0.09 mm	0.295	0.225	0.039	0.376	0.255*	0.151
Sito 0.25 mm	0.197	0.026	0.209	0.467	0.012	0.441*
Sito 0.71 mm	0.267	0.153	0.287	0.373	0.020	0.221*
Sito 2.0 mm	0.392	0.311	0.178	0.144	0.214*	0.167
Sito 4.0 mm	0.356	0.340	0.121	0.211	0.235*	0.130
Sito 8.0 mm	0.314	0.262	0.030	0.206	0.283*	0.056
Sito 11.2 mm	0.235	0.210	-0.002	0.077	0.237*	0.133
Sito 16 mm	0.109	0.017	-0.041	0.153	0.150	0.136
Sito 22.4 mm	-0.043	-0.145	-0.043	0.346	0.001	0.491*
Prostor. gost.	0.071	-0.002	0.184	0.505	0.113	0.507*
Največja gost.	-0.170	-0.239	0.180	0.440	0.350*	0.679*
Vsebnost zrač. votl.	-0.214	-0.204	-0.117	-0.493	0.098	0.288*
Stopnja zapol. votl.	0.115	0.099	0.068	0.521	0.047	0.421*
Votline v kam. mat.	-0.269	-0.252	-0.094	0.133	0.175	0.386*
Največja gost. kam. mat.	-0.220	-0.274	0.151	0.470	0.371*	0.744*

*Odstopanja so prevelika, da bi bila lahko naključna.

Preglednica 6: Korelacijski koeficienti za dve skupini, kjer so meritve naključno premešane in njihove razlike.

Table 6: The correlation coefficients for two groups where measurements are randomly divided and their differences.

	r_{xy}				Razlike v r_{xy} med 1. in 2. skupino podatkov	
	1. skupina podatkov		2. skupina podatkov			
	S	F	S	F	S	F
PK	-0.257	-0.013	-0.267	-0.024	0.010	0.011
Penetracija	0.027	0.096	-0.001	0.143	0.028	0.047
Viskoznost	0.044	0.002	0.113	-0.027	0.069	0.029
IP	-0.269	0.043	-0.279	0.055	0.010	0.013
Delež bitumna	-0.137	0.180	0.062	0.228	0.198*	0.048
Sito 0.09 mm	0.217	0.241	0.307	0.278	0.090	0.037
Sito 0.25 mm	0.265	0.240	0.362	0.252	0.097	0.012
Sito 0.71 mm	0.294	0.248	0.341	0.276	0.046	0.027
Sito 2.0 mm	0.265	0.197	0.309	0.292	0.044	0.095
Sito 4.0 mm	0.283	0.212	0.361	0.231	0.078	0.019
Sito 8.0 mm	0.210	0.173	0.324	0.187	0.114	0.014
Sito 11.2 mm	0.159	0.076	0.298	0.116	0.139	0.040
Sito 16 mm	0.136	0.024	0.225	-0.003	0.089	0.027
Sito 22.4 mm	-0.042	0.116	0.030	0.087	0.072	0.029
Prostor. gost.	0.254	0.312	0.237	0.182	0.017	0.129
Največja gost.	0.203	0.244	0.183	0.063	0.020	0.181
Vsebnost zrač. votl.	-0.218	-0.279	-0.227	-0.381	0.009	0.101
Stopnja zapol. votl.	0.108	0.298	0.215	0.383	0.107	0.084
Votline v kam. mat.	-0.270	-0.027	-0.075	-0.078	0.195*	0.051
Največja gost. kam. mat.	0.154	0.266	0.184	0.109	0.030	0.157

*Odstopanja so prevelika, da bi bila lahko naključna.