

Unaprijeđeni postupci za raspoznavanje razina boli na temelju slika lica

Zorić, Bruno

Doctoral thesis / Disertacija

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:158468>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-07-09**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



SVEUČILIŠTE J. J. STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH
TEHNOLOGIJA

Bruno Zorić

Unaprijeđeni postupci za raspoznavanje razina boli na
temelju slika lica

Doktorska disertacija



Osijek, 2017.

Sadržaj

Popis tablica	i
Popis slika	iii
Popis algoritama	vii
Popis oznaka	vii
1 Uvod	1
1.1 Ciljevi disertacije	3
1.2 Sadržaj disertacije	3
2 Računalno raspoznavanje boli	6
2.1 Raspoznavanje uzoraka	7
2.1.1 Klasifikacijski problemi u medicini	8
2.2 Važnost boli - osjet, izražavanje i opažanje	9
2.2.1 Osjet boli	10
2.2.2 Izražavanje boli	11
2.2.3 Povezanost raspoznavanja emocija i razina boli	12
2.3 Računalno raspoznavanje razina boli	13
2.3.1 Ljestvice određivanja boli	13
2.3.2 Dostupni podaci s prikazom bolnih stanja	17
2.3.3 Vrednovanje raspoznavanja razina boli	19
2.3.4 Mjere kvalitete raspoznavanja	21
3 Izdvajanje opisnih značajki boli iz slika lica	24
3.1 Problem izdvajanja opisnih značajki	25
3.2 Postojeći postupci izdvajanja značajki za predstavljanje bolnih stanja	26
3.3 Postupak izdvajanja značajki zasnovan na shearlet transformaciji	29

3.3.1	Shearlet transformacija	30
3.3.2	Lokalni binarni uzorci	32
3.3.3	Informativne regije slike lica s gledišta bolnih stanja	34
3.3.4	Izdvajanje opisnih značajki predloženim postupkom	36
3.4	Ekperimentalna analiza i rezultati	38
3.4.1	Priprema podataka	38
3.4.2	Postavke eksperimenta	40
3.4.3	Ponašanje predloženog postupka prilikom učenja na svim dostupnim podacima	41
3.4.4	Ponašanje predloženog postupka pri učenju na dijelu podataka	45
3.4.5	Razmatranje rezultata usporedno po klasifikatorima	51
3.5	Osvrt na predloženi postupak	52
4	Smanjenje dimenzionalnosti problema odabirom značajki omotačem	55
4.1	Smanjenje dimenzionalnosti odabirom značajki	56
4.2	Postupci zasnovani na omotačima	58
4.2.1	Prirodom inspirirani algoritmi kao omotači	59
4.3	Metoda odabira značajki praćenjem doprinosa opisnih značajki boli	61
4.3.1	Tijek pretrage omotačem	61
4.3.2	Praćenje doprinosa značajki	63
4.3.3	Kreiranje rješenja na osnovu arhive znanja	64
4.4	Ekperimentalna analiza i rezultati	65
4.4.1	Postavke eksperimenta	65
4.4.2	Detalji ugradnje	67
4.4.3	Ponašanje ftFS-a u odnosu na prilagođene omotače na podatkovnom skupu boli	68
4.4.4	Ponašanje ftFS-a u odnosu na osnovne inačice omotača na podatkovnom skupu boli	74
4.4.5	Ponašanje ftFS-a na standardnim skupovima podataka	78
4.5	Osvrt na predloženu metodu	82
5	Oblikovanje klasifikacijskog modela radijalne neuronske mreže	84
5.1	Klasifikacijski model radijalne neuronske mreže	85
5.2	Načini oblikovanja klasifikacijskog modela radijalne neuronske mreže	87
5.3	Unaprijeđeni ABC za oblikovanje klasifikacijskog modela RBFN	89
5.3.1	Načela rada algoritma umjetne kolonije pčela	90
5.3.2	Fokusiranje pretrage	93
5.3.3	Korištenje grupiranja podataka	94
5.4	Ekperimentalna analiza i rezultati	95
5.4.1	Postavke eksperimenta	95

5.4.2	Ponašanje VRABC-a na podatkovnom skupu boli	97
5.4.3	Ponašanje VRABC-a na standardnim skupovima podataka	103
5.5	Osvrt na predloženi algoritam	106
6	Zaključak	108
	Literatura	112
	Sažetak	125
	Abstract	126
	Životopis	127
	Prilozi	
	A Podatkovni skupovi s UCI repozitorija	128
	B Implementacijski detalji	131

Popis tablica

2.1	Baze (podatkovni skupovi) za procjenu boli i emocija	18
3.1	Rezultati klasifikacije u obliku težinske mjere AUC za sve subjekte učenjem na svim podacima uz korištenje Bayesove mreže	42
3.2	Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na svim podacima korištenjem Bayesove mreže	44
3.3	Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na svim podacima korištenjem Bayesove mreže	44
3.4	Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na svim podacima korištenjem Bayesove mreže	45
3.5	Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na dijelu podataka korištenjem Bayesove mreže	47
3.6	Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na dijelu podataka korištenjem algoritma k NN	47
3.7	Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na dijelu podataka korištenjem nasumične šume	48
3.8	Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na dijelu podataka korištenjem naivnog Bayesovog algoritma	49
3.9	Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na dijelu podataka korištenjem Bayesove mreže	49
3.10	Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na dijelu podataka korištenjem algoritma k NN	50
3.11	Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na dijelu podataka korištenjem nasumične šume	50
3.12	Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na dijelu podataka korištenjem naivnog Bayesovog algoritma	50

3.13	Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na dijelu podataka korištenjem Bayesove mreže	50
3.14	Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na dijelu podataka korištenjem algoritma k NN	50
3.15	Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na dijelu podataka korištenjem nasumične šume	51
3.16	Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na dijelu podataka korištenjem naivnog Bayesovog algoritma	51
4.1	Karakteristike poduzorkovanih skupova podataka	66
4.2	Postavke parametara pri testiranju ftFS	67
4.3	Performanse odabira značajki predloženog unaprjeđenja u odnosu na algoritam krijesnica	69
4.4	Performanse odabira značajki predložene metode u odnosu na izmijenjeni binarni algoritam optimizacije rojem čestica	70
4.5	Performanse odabira značajki predložene metode u odnosu na izmijenjeni algoritam umjetne kolonije pčela	72
4.6	Performanse odabira značajki predložene metode u odnosu na algoritam umjetne kolonije pčela	75
4.7	Performanse odabira značajki predložene metode u odnosu na algoritam optimizacije rojem čestica	77
4.8	Korišteni podatkovni skupovi s UCI repozitorija za strojno učenje	79
4.9	Performanse osnovnih i inačica omotača u obliku prosjeka mjere F1 s ugrađenim unaprjeđenjem na standardnim skupovima podataka	80
4.10	Prosječna dimenzionalnost vektora značajki kod osnovnih i inačica omotača s ugrađenim unaprjeđenjem na standardnim skupovima podataka	80
5.1	Postavke parametara pri testiranju VRABC	96
5.2	Postignuta prosječna kvaliteta klasifikacije i broj skrivenih čvorova uporabom algoritama MRABC, MRASF i VRABC prema različitim mjerama kvalitete	98
5.3	Postignuta kvaliteta klasifikacije i broj skrivenih čvorova uporabom algoritama CPSO, PSO, FFA, VRABC prema različitim mjerama kvalitete	101
5.4	Performanse osnovnih i inačica omotača s ugrađenim unaprjeđenjem na standardnim skupovima podataka	104
5.5	Usporedba broja skrivenih čvorova u mrežama predloženog algoritma VRABC i ostalih algoritama iz usporedbe	105
B.1	Poveznice na korištene biblioteke i alate	131
B.2	Karakteristike sklopovlja korištenog za potrebe računalne analize	132

Popis slika

2.1	Nacrt klasifikacijske procedure po koracima	8
2.2	Pojednostavljeni prikaz prostiranja osjetilnih informacija od nociceptora do mozga	11
2.3	Modaliteti podataka za raspoznavanje emocija	13
2.4	Različite ljestvice intenziteta boli	14
2.5	Akcijske jedinice pomaka mišićnih skupina prema sustavu FACS	15
2.6	Primjer intenziteta akcijskih jedinica povezanih s boli na licu	16
2.7	Podjela skupa podataka za potrebe analize klasifikacije	20
2.8	Mjere kvalitete raspoznavanja: (a) matrice zabune, (b) krivulja ROC	21
3.1	Dijeljenje frekvencijske domene po indeksima (različitim kombinacijama parametara)	32
3.2	Primjer vizualizacije shearlet koeficijenata i spektra za jednu sliku iz baze UNBC-McMasters	33
3.3	Način rada LBP_8^1 operatora	33
3.4	Različiti LBP operatori prema veličini susjedstva i polumjeru razmatranja, s lijeva na desno: LBP_4^1 , LBP_8^1 , LBP_8^2 , LBP_{16}^2	34
3.5	Uniformni LBP	34
3.6	Primjeri nekih od podjela lica na informativne regije	35
3.7	Predloženi primjer podjele slike lica	36
3.8	Primjer matrice ASC u prilagođenom prikazu	37
3.9	Koraci u predobradi izvornih slika	39
3.10	Različite razine boli na primjerima slika iz baze UNBC-McMasters	39
3.11	Težinska mjera AUC za postupke izdvajanja značajki uključene u eksperimentalnu analizu	43

3.12	Rezultati usporedbe prema težinskoj mjeri AUC za postupke izdvajanja značajki uključene u eksperimentalnu analizu kod učenja na dijelu dostupnih podataka uporabom (a) Bayesove mreže, (b) algoritma k NN, (c) nasumične šume, (d) naivnog Bayesovog algoritma	47
3.13	Broj pobjeda po subjektima u smislu težinske mjere AUC na svim podacima: (a) Bayesova mreža, i na dijelu podataka: (b) Bayesova mreža, (c) nasumična šuma, (d) k NN i (e) naivni Bayesov algoritam	52
3.14	Stabilnost rezultata klasifikacije u smislu težinske mjere AUC prilikom promjena postavki eksperimenta	53
4.1	Nacrt postupka odabira značajki	56
4.2	Nacrt postupka odabira značajki omotačem	62
4.3	Koraci unaprijedene metode odabira značajki	63
4.4	Prikaz kodiranog rješenja unutar populacije za potrebe odabira značajki	67
4.5	Usporedba performansi uporabom algoritma krijesnica u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	70
4.6	Usporedba dimenzionalnosti problema uporabom algoritma krijesnica u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	71
4.7	Usporedba performansi uporabom algoritma izmijenjene binarne optimizacije rojem čestica u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	72
4.8	Usporedba dimenzionalnosti problema uporabom algoritma izmijenjene binarne optimizacije rojem čestica u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	73
4.9	Usporedba performansi uporabom algoritma izmijenjene umjetne kolonije pčela u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	74
4.10	Usporedba dimenzionalnosti problema uporabom algoritma izmijenjene umjetne kolonije pčela u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	75
4.11	Usporedba performansi uporabom algoritma umjetne kolonije pčela u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	76
4.12	Usporedba dimenzionalnosti problema uporabom algoritma umjetne kolonije pčela u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	77
4.13	Usporedba performansi uporabom algoritma optimizacije rojem čestica u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	78
4.14	Usporedba dimenzionalnosti problema uporabom algoritma optimizacije rojem čestica u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	79
4.15	Usporedba performansi klasifikacije na različitim standardnim problemima za FFA i isti algoritam s ugrađenim unaprjeđenjem u smislu (a) mjere F1, (b) broja značajki	81

4.16	Usporedba performansi klasifikacije na različitim standardnim problemima za MRABC i isti algoritam s ugrađenim unaprjedenjem u smislu (a) mjere F1, (b) broja značajki	81
4.17	Usporedba performansi klasifikacije na različitim standardnim problemima za MBPSO i isti algoritam s ugrađenim unaprjedenjem u smislu (a) mjere F1, (b) broja značajki	81
4.18	Prikaz odnosa dopuštenog (korištenog) broja vrednovanja kvalitete rješenja u odnosu na broj potreban za iscrpnu pretragu	83
5.1	Uobičajena struktura RBFN klasifikatora	86
5.2	Prikaz kodiranog rješenja unutar populacije	97
5.3	Kvaliteta najboljeg rješenja tijekom pretrage za MRABC, MRABC_ASF i VRABC na (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	98
5.4	Usporedba performansi klasifikacije uporabom osnovnih algoritama i predloženog unaprijeđenog algoritma u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	99
5.5	Usporedba broja skrivenih čvorova uporabom osnovnih algoritama i predloženog unaprijeđenog algoritma za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 (c) \mathcal{D}_2 i (d) \mathcal{D}_3	100
5.6	Ponašanje najboljeg rješenja prilikom pretrage za PSO, CPSO, FFA i VRABC na (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	102
5.7	Usporedba performansi uporabom algoritama iz literature i predloženog unaprijeđenog algoritma u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	103
5.8	Usporedba broja skrivenih čvorova uporabom algoritama iz literature i predloženog unaprijeđenog algoritma za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3	104
5.9	Usporedba performansi uporabom predloženog unaprijeđenog algoritma i ostalih algoritama za skupove $\mathcal{U}_1, \mathcal{U}_2, \dots, \mathcal{U}_{10}$ u smislu mjere F1	105
5.10	Usporedba broja čvorova u skrivenom sloju mreže uporabom predloženog unaprijeđenog algoritma i ostalih algoritama za skupove $\mathcal{U}_1, \mathcal{U}_2, \dots, \mathcal{U}_{10}$	105

Popis algoritama

Algoritam 1	Predloženi postupak izdvajanja značajki	36
Algoritam 2	Implementacija predloženog unaprjeđenja ftFS	68
Algoritam 3	Skica algoritma ABC	90
Algoritam 4	Nacrt rada prilagođene inačice algoritma ABC	92
Algoritam 5	Izmjena faze pčela istraživača (*M1)	94
Algoritam 6	Izmjena faze pčela skauta (*M2)	95

Popis oznaka

$[M, N]$	Dimenzije digitalne slike
χ	Broj centara kod grupiranja algoritmom k -means
κ	Cohenova kappa statistika
\mathbb{I}	Digitalna slika
$\mathcal{D}_0, \mathcal{D}_1, \mathcal{D}_2, \mathcal{D}_3$	Podatkovni skupovi razina boli
$\mathcal{U}_0, \mathcal{U}_1, \dots, \mathcal{U}_{10}$	Podatkovni skupovi iz različitih domena
ω	Broj vrednovanja nakon kojih se bilježi stanje populacije
Φ	Funkcija jezgre u neuronima skrivenog sloja RBFN
$\psi_{a,s,t}$	Shearlet
σ	Širina djelovanja funkcije jezgre
B	Skup bitovnih maski
b	Bitovna maska
c	Lokacija centra djelovanja funkcije jezgre
d	Dimenzionalnost problema
er	Stopa razmjene
$ftFS$	Metoda praćenja doprinosa značajki
h	Broj skrivenih čvorova u skrivenom sloju RBFN
l_k	Oznaka klase

LBP_n^r	LBP operator
m	Broj klasa
P	Uzorak
PS	Veličina populacije
r_c	Vjerojatnost izmjene iscrpljenog rješenja
S	Podatkovni skup
S_c	Podskup za testiranje
S_p	Podskup za pretragu
S_t	Podskup za treniranje
S_v	Podskup za interno vrednovanje
sc	Broj razina shearlet transformacije
$SH(f)(a, s, t)$	Shearlet transformacija
$uLBP_n^r$	Uniformni LBP operator
w	Težinski faktor na sponi između dvaju neurona
X_i	Vektor značajki
x_j	Značajka
z	Broj instanci
AAM	Aktivni model izgleda
ABC	Algoritam umjetne kolonije pčela
Acc	Točnost klasifikacije
ANN	Umjetna neuronska mreža
AUC	Površina ispod krivulje
CM	Matrica zabune
DCT	Diskretna kosinusna transformacija
DE	Algoritam diferencijalne evolucije
FFA	Algoritam krijesnica

FMSr F1 mjera

GA Genetski algoritam

GD Gradijentni spust

HOG Histogram orijentiranih gradijenata

MLP Višeslojni perceptron

NFE Broj vrednovanja funkcije cilja

PINV Metoda pseudo-inverza

Pre Preciznost

PSO Algoritam optimizacije rojem čestica

RBFN Radijalna neuronska mreža

Rec Odziv, osjetljivost

VRABC Unaprijeđeni predloženi algoritam ABC

Uvod

*"Science is a way of thinking much more
than it is a body of knowledge."
- Carl Sagan*

RASPOZNAVANJE stvari koje ga okružuju i njihovo svrstavanje u kategorije jedan je od prvih intelektualnih zadataka s kojima se čovjek susreće. Ova vještina dolazi intuitivno, razvijanjem spoznajnih sposobnosti ljudskog mozga, a njihovim napredovanjem ljudsko je biće sposobno primijeniti ju na iznimno složene probleme. Računalo se s problemima ovakvog tipa nosi izuzetno teško. Posebice je to izraženo u slučaju razmatranja složenijih prizora, kakvi su primjerice raspoznavanje emocija, izraza lica ili sadržaja kompleksnih scena, prilikom čijeg rješavanja čak i ljudi imaju problema. S ciljem rješavanja navedenih problema, razvijeni su različiti postupci i alati zasnovani na strojnom učenju (engl. *machine learning*, ML). Oni računalu dopuštaju usvajanje novih mogućnosti raspoznavanja, utemeljenih na prethodnom iskustvu. U terminologiji strojnog učenja ranije spomenuti problem kategorizacije naziva se nadziranom klasifikacijom (engl. *supervised classification*), a cilj je na temelju već viđenih pojava s poznatom oznakom pripadnosti nekoj kategoriji, odrediti oznaku tek uočenoj pojavi. Klasifikacija je zastupljena u brojnim područjima i primjenama, poput kontrole kvalitete proizvoda [1], bio-metrike [2], agronomije [3] pa sve do medicine [4].

Medicinski problemi predstavljaju posebice zanimljivo područje primjene gdje računalni postupci sve više dobivaju na značaju. Vjetar u leđa daju kako snažnije sklopovlje, tako i na-

predniji računalni postupci za analizu dostupnih podataka, ali u svakom slučaju i sve veća dostupnost podataka nužnih spomenutim računalnim postupcima za učenje. Primjena se pak u ovom području rasprostire kroz širok spektar dijagnostičkih, terapijskih te u konačnici postupaka nadzora zdravstvenog stanja pacijenta. Nije tako rijetkost susresti u praksi sustave za analizu krvi na temelju slike mikroskopa, sustave koji razlikuju dobroćudne od zloćudnih nakupina tkiva [5], niti sustave koji na temelju praćenja i raspoznavanja emocija otkrivaju pojavu psiholoških poremećaja poput depresije ili bipolarnog poremećaja [6]. Primarni cilj spomenutih sustava jest prepoznati simptome poremećaja pomoću informacija dobivenih iz različitih mjerenja te na temelju prethodno stečenoga znanja donijeti odluku o postupanju u skladu sa zdravstvenim stanjem neke osobe. Otkrivanje postojanja boli, odnosno raspoznavanje razina boli, pripada, prema svojim svojstvima, u opisani skup problema.

Razmatrajući činjenicu da je bol jedan od prvih, a pritom i najvažnijih simptoma bolesti ili ozljede, od iznimne je važnosti na pravilan način odrediti njeno postojanje i intenzitet da bi se pristupilo narednim koracima u liječenju. Danas ovaj postupak u pravilu provodi liječnik temeljem pregleda ili uz pomoć samoprocjene pacijenta. Ipak, računalne metode za određivanje razina boli mogle bi poslužiti kao potpora pri odlučivanju i pridonijeti sigurnosti procjene. Kako je riječ o veoma kompleksnom fenomenu [7], a koji istovremeno spada u klasifikacijske probleme [8], nameće se zaključak kako bi neki od postupaka strojnog učenja primijenjenih u sličnim situacijama bio od koristi.

Trenutno se u kliničkoj praksi prilikom određivanja razina boli računalni sustavi rabe rijetko, unatoč činjenici da je ovaj problem relativno snažno zastupljen u istraživanjima i znanstvenoj literaturi. Navedeno proizlazi iz kompleksnosti samog problema, a upravo iz tog bi razloga bilo dobro uočiti koje je korake unutar klasifikacijske procedure moguće dodatno unaprijediti u svrhu raspoznavanja razina boli. Zahvati unutar pojedinih koraka klasifikacije, bilo da je riječ o prikupljanju podataka, izdvajanju značajki ili izgradnji klasifikacijskog modela, mogli bi u konačnici pospješiti kvalitetu prepoznavanja. Na taj bi se način računalno raspoznavanje bolnih stanja moglo približiti uporabi u svakodnevnom životu, kao potpora odlučivanju.

Podaci koji bi mogli poslužiti u ovu svrhu su raznovrsni, proizlaze iz različitih izvora informacija, a primjeri su izrazi lica, držanja tijela/glave, biološki signali, no također i brojni drugi. Izrazi lica pokazali su se u tom pogledu čestim izborom, s obzirom da se drži da su informacije o razinama boli ovdje najizražajnije, dok prikupljanje izvornih podataka u obliku videosnimki ili slika lica ne predstavlja značajnu neugodu za pacijenta/subjekta. Unutar izraza lica, razmatraju se informacije sadržane u teksturi i obliku, s obzirom da pojavu boli karakterizira aktiviranje točno određenih mišićnih skupina. Štoviše, radovi koji se bave automatiziranim određivanjem razina boli sugeriraju kako je praćenjem ovih aktiviranja moguće dobiti uvid u to koliko je snažna bol. Ipak, novija literatura pokazuje kako je moguće iz-

ravno iz slike dobiti jednako kvalitetna saznanja o razinama boli. Potonji je pristup odabran za postizanje ciljeva definiranih u ovoj disertaciji, s obzirom da preskače posredni korak određivanja aktiviranja mišićnih skupina koji otežava raspoznavanje.

1.1 Ciljevi disertacije

Nadzirana klasifikacija najčešće je susretan razred problema kod raspoznavanja uzoraka, no unatoč velikom broju različitih postupaka za svaki od koraka klasifikacijske procedure, ti se koraci uobičajeno međusobno značajno ne razlikuju od problema do problema. Imajući navedeno u vidu, u sklopu ove doktorske disertacije predlaže se nekoliko mogućih unaprjeđenja pojedinih koraka, koji bi na različite načine mogli utjecati na proceduru klasifikacije te unaprijediti raspoznavanje razina boli.

Najprije se predlaže postupak koji omogućuje izdvajanje značajki iz izvornih podataka, konkretno slika koje prikazuju bolne izraze lica. Riječ je o koraku od iznimne važnosti za klasifikacijske probleme jer je instance problema nužno na adekvatan način predstaviti na računalu. Da bi se olakšalo učenje na osnovi izdvojenih značajki, odnosno olakšala izgradnja klasifikacijskih modela, uklonile bespotrebne ili one značajke koje narušavaju kvalitetu klasifikacije, ali i ubrzao dolazak do odluke o razini boli, predlaže se metoda odabira značajki za smanjenje dimenzionalnosti problema. U konačnici, s ciljem poboljšanja performansi klasifikacijskog modela radijalne neuronske mreže, predlaže se unaprijeđeni algoritam za njegovo oblikovanje. Predloženi unaprijeđeni algoritam zasnovan je na algoritmu umjetne kolonije pčela, prirodno inspiriranom postupku globalne optimizacije već korištenom za potrebe oblikovanja klasifikacijskih modela. Očekivani izvorni znanstveni doprinosi ove doktorske disertacije, koji prema opisanom zadiru u pojedine korake klasifikacijske procedure, su sljedeći:

1. Postupak izdvajanja značajki boli iz slika lica zasnovan na shearlet transformaciji i podjeli slike na informativne regije
2. Poboljšana metoda odabira značajki praćenjem doprinosa opisnih značajki boli tijekom optimizacije metodom omotača.
3. Unaprijeđeni algoritam umjetne kolonije pčela za oblikovanje klasifikacijskog modela radijalne neuronske mreže.

1.2 Sadržaj disertacije

Ova doktorska disertacija organizirana je kako slijedi. U drugom poglavlju dan je uvod u problem računalnog raspoznavanja razina boli, koji predstavlja središnju točku interesa.

Opisana je važnost boli, njena proživljavanja, iskustva, iskazivanja i određivanja. Također, prikazano je računalno određivanje postojanja i razina boli, dane su standardne ljestvice kojima se ona mjeri te su prikazani klasični načini njena mjerenja sa svojim prednostima i nedostacima. S obzirom da je riječ o klasifikacijskom problemu, prikazani su dostupni podaci, mjere kvalitete te načini vrednovanja raspoznavanja boli koji će biti rabljeni u kasnijim poglavljima u svrhu eksperimentalnog vrednovanja i analize rezultata.

U trećem poglavlju opisan je prvi korak u proceduri klasifikacije bolnih stanja, a riječ je o izdvajanju opisnih značajki iz izvornih slika bolnih izraza lica. Predstavljani su postupci iz literature koji se rabe u ovu svrhu te je dan prijedlog postupka za izdvajanje značajki. Spomenuti postupak zasnovan je na koeficijentima shearlet transformacije i podjeli lica na izražajne, informativne regije koje prolaze najveće promjene prilikom osjeta boli. Provedena je i prikazana usporedna eksperimentalna analiza predloženog postupka, koji ujedno predstavlja i prvi očekivani znanstveni doprinos, i nekoliko važnijih postupaka iz literature. Analiza je provedena na standardnom podatkovnom skupu bolnih izraza lica uporabom različitih klasifikacijskih postupaka s ciljem utvrđivanja uspješnosti predloženog postupka.

U četvrtom poglavlju prikazana je predložena metoda vezana uz predobradu značajki kao idući ključan korak klasifikacije, koji slijedi nakon njihova izdvajanja. Nakon opisa problema smanjenja dimenzionalnosti uklanjanjem značajki, detaljnije su prikazane metode za postizanje ovog cilja zasnovane na omotačima. Poseban je naglasak stavljen na prirodnom inspirirane (bio-inspirirane) algoritme korištene kao osnovu za omotače. Na temelju načina pretrage takvih pristupa, predložena je i razvijena unaprijeđena metoda odabira značajki kao drugi očekivani izvorni znanstveni doprinos. Ona omogućuje odabir praćenjem doprinosa pojedinih opisnih značajki boli tijekom pretrage uporabom omotača. Utjecaj unaprijeđenja eksperimentalno je analiziran i vrednovan, kako u kontekstu osnovnih prirodnom inspiriranih algoritama, tako i u kontekstu onih posebno prilagođenih problemu smanjenja dimenzionalnosti. Promatran je doprinos predloženog unaprijeđenja na standardnom podatkovnom skupu za raspoznavanje razina boli, ali i na različitim podatkovnim skupovima iz drugih područja.

U petom poglavlju izložen je klasifikacijski model radijalne neuronske mreže koji predstavlja pouzdan i učestao odabir za probleme nadzirane klasifikacije. Opisani su različiti načini oblikovanja navedenog klasifikacijskog modela iz literature, a posebice je razmatrana uporaba prirodnom inspiriranih algoritama u ovu svrhu. Potom je predloženo unaprijeđenje algoritma umjetne kolonije pčela za potrebe oblikovanja klasifikacijskog modela radijalne neuronske mreže kao treći očekivani izvorni znanstveni doprinos. Spomenuto unaprijeđenje koristi fokusiranje pretrage na bolja rješenja unutar populacije te uvodi ideje iz grupiranja podataka, a sve s ciljem usmjeravanja procesa pretrage na obećavajuće regije prostora. Cilj predloženih unaprijeđenja jest u prvom redu ostvariti bolje raspoznavanje razina boli, a postići navedeno

bez snažnog utjecaja na povećanje kompleksnosti modela. Provedena je eksperimentalna analiza na standardnom skupu podataka za raspoznavanje razina boli, a ponašanje predloženog algoritma uspoređeno je s nekoliko pristupa dostupnih u literaturi. Ova usporedba omogućila je, kako provjeru učinkovitosti i opravdanosti predloženog unaprjeđenja, tako i uvid u njegova moguća ograničenja.

Konačno, šesto poglavlje, donosi zaključke dobivene na temelju provedenog istraživanja u sklopu doktorske disertacije. U zaključku su najprije dani osvrti na ostvarenje očekivanih izvornih znanstvenih doprinosa te zaključci izvedeni na temelju polučeni rezultata eksperimentalnog vrednovanja i analize. Uz navedeno, ukratko su opisane prednosti i ograničenja predloženih, odnosno ostvarenih znanstvenih doprinosa, a vezano uz potonje ponuđene su i određene smjernice koje se tiču budućeg istraživanja s ciljem njihova ublažavanja ili otklanjanja.

Računalno raspoznavanje boli

*"Učenje nije dječja igra;
ne možemo učiti bez boli."
- Aristotel*


OSJET boli predstavlja jedan od najvažnijih osjeta prisutnih kod većine živih bića. Ovaj osjet u značajnom udjelu usmjerava ponašanje u situacijama u kojima je organizam ugrožen. Da bi se uopće moglo pristupiti automatskom, odnosno računalnom otkrivanju postojanja i određivanju razina boli, što ujedno predstavlja središnji problem ove doktorske disertacije, potrebno je razumjeti njenu važnost, načine izražavanja i osjeta. S tim ciljem u vidu, u ovom poglavlju bit će razmotren koncept boli i njegovo značenje. Uz to, namjera je ovog poglavlja prikazati mogućnosti uporabe računalnih sustava u medicinskim primjenama s posebnim fokusom na njihovoj uporabi u raspoznavanju razina boli. S obzirom da se kod navedenog u prvom redu radi o problemu raspoznavanja uzoraka, konkretno o klasifikacijskom problemu, koji se u pravilu rješava postupcima strojnog učenja, dan je prije svega kratak uvod u isto, s naglaskom na postupke nadziranog strojnog učenja. Potom je dan uvid u mogućnosti određivanja intenziteta boli različitim ljestvicama, podatke koji su dostupni u literaturi za analizu korištenih metoda, kao i uobičajene postupke vrednovanja spomenutih metoda. Oni će pak biti korišteni za potrebe eksperimentalne analize u kasnijim poglavljima.

2.1 Raspoznavanje uzoraka

Theodoridis i Koutrumbas u [9] definirali su raspoznavanje uzoraka (engl. *pattern recognition*) kao znanstvenu disciplinu kojoj je cilj rasporediti objekte u ograničen broj kategorija, odnosno klasa. Iako korijene vuče još od polovice dvadesetog stoljeća, snažniji zamah dobiva razvojem računala i značajnim povećanjem računalne snage. Pri tome, često sustav za prepoznavanje uzoraka postaje središtem složenih sustava za različite namjene, poput primjerice detekcije pogrešaka u proizvodima na radnoj traci, biometrike, prepoznavanja alfanumeričkih znakova i slično. Postoje dva glavna oblika raspoznavanja uzoraka, nadzirana i nenadzirana klasifikacija, a u ovom radu razmatra se jedan problem iz domene nadzirane klasifikacije. Opažanja koja se prikupljaju prilikom rada na ovakvim problemima općenito se nazivaju uzorcima, a kod nadzirane klasifikacije (za razliku od nenadzirane) unaprijed su poznate sve kategorije u koje je moguće svrstati prikupljena opažanja. Drugim riječima, znane su oznake kategorija koje se pridružuju opažanjima, u ovisnosti o njihovim karakteristikama. Da bi se moglo računalno baratati uzorcima, nužno je odabrati prikladnu reprezentaciju [10], odnosno preslikavanje koja će sirove, izvorne podatke visoke dimenzionalnosti preslikati u prostor niže dimenzionalnosti. Stoga je uobičajeno opažanje prikazati nizom kategoričkih, numeričkih, logičkih i inih vrijednosti, koje se nazivaju značajkama. Označava ih se s $x_j \in X_i, j = 1, \dots, d$, gdje $d \in \mathbb{N}$ predstavlja ukupan broj značajki, odnosno dimenzionalnost problema. Takav niz vrijednosti, koji opisuje uzorak, naziva se vektorom značajki i označava s $X_i \in S, i = 1, \dots, z$, gdje $z \in \mathbb{N}$ predstavlja ukupni broj dostupnih uzoraka, a S skup svih uzoraka. Svakom je vektoru značajki dodijeljena kategorička oznaka klase $l_k \in L, k = 1, \dots, m$, gdje $m \in \mathbb{N}$ predstavlja ukupan broj mogućih klasa, a L skup svih oznaka klase. Tako se može reći da je svaki uzorak uređeni par vektora značajki i oznake klase, odnosno $P_i = (X_i, l_k)$, a za nove, do sada neviđene uzorke, oznaka klase nije unaprijed poznata. Cilj klasifikacije jest za novi uzorak s poznatim vektorom značajki odabrati oznaku klase iz skupa L , tako da odgovara stvarnoj klasi uzorka.

U cilju određivanja klase promatranog objekta iz prirode, primjerice kvalitete proizvoda, nužno je provesti nekoliko koraka. Okvirni nacrt tih koraka dan je slikom 2.1. U prvom koraku provodi se prikupljanje izvornih podataka. Ovisno o problemu koji se rješava, to je moguće postići različitim sensorima, kamerama ili drugim metodama, primjerice anketiranjem. Nakon prikupljanja podataka, slijedi korak predobrade tijekom kojeg se podaci prilagođavaju za izdvajanje značajki, odnosno pretvaranje iz izvornih podataka u oblik prikladan za obradu na računalu. Ovaj korak može uključivati otkrivanje regija interesa, uklanjanje pozadine sa slike, promjenu formata boja na slici i drugo. Potom se pristupa izdvajanju značajki, gdje se izvorni podaci preslikavaju u značajke. Nakon izdvajanja, obavlja se prilagodba i oblikovanje značajki. Ovaj korak uključuje postupke filtriranja, odabira značajki, uklanjanja uzoraka i tako dalje. Nakon što su značajke pripremljene, odabire se klasifikator,

odnosno algoritam za klasifikaciju, podaci se dijele na one za učenje i one za analizu te se pristupa izgradnji klasifikacijskog modela. Model se vrednuje prema različitim mjerama kvalitete, a nakon odabira najboljeg, ponovno se provodi izgradnja modela. Ovaj put to se čini na svim dostupnim podacima, nakon čega se klasifikator postavlja u produkcijski rad s novim podacima.



Slika 2.1: Nacrt klasifikacijske procedure po koracima

2.1.1 Klasifikacijski problemi u medicini

Kao što je već spomenuto, računalni sustavi i informacijsko-komunikacijska tehnologija snažno su zastupljeni u medicini i zdravstvu. Navedeno zapažanje uočljivo je od sustava za praćenje i komunikaciju s pacijentima pa sve do sustava koji liječnicima olakšavaju dijagnostičke postupke ili omogućuju kontinuirano praćenje stanja zdravstveno ugroženih osoba. Takvi sustavi u pravilu su izgrađeni u suradnji s liječnicima, a osim što ih odlikuje ugradnja novih medicinskih spoznaja, sve se češće zasnivaju i na različitim postupcima strojnog učenja. Tako su u kliničkoj praksi dostupni sustavi za automatsko razvrstavanje nakupina tkiva, kao i sustavi za potrebe automatske analize medicinskih snimaka nastalih na različitim izvorima.

Posebno je, u kontekstu ove disertacije, značajna sprega postupaka strojnog učenja i područja afektivnog računarstva [11] (engl. *affective computing*) u medicini. Upravo je iz područja afektivnog računarstva potekla ideja za automatskim raspoznavanjem razina boli. Afektivna stanja i izražavanje emocija predstavljaju osnovu ili važan segment različitih medicinskih postupaka, a njihova odsutnost ili prenaplašenost često su uzrokom postojanja određenih bolesti. U [12, 13] opisano je stanje medicinskog aspekta afektivnog računarstva gdje je moguće vidjeti u kojoj su mjeri zastupljeni postupci strojnog učenja kao i dobiti uvid u važnost afektivnih stanja. Postoje brojne različite grane medicine u kojima se aktivno isprepliću afektivno računarstvo i strojno učenje, a zasigurno je ponajviše zastupljena psihijatrija. Izostanak ili prenaplašenost emocija ovdje ne samo da sugeriraju narušeno zdravstveno stanje, već i utječu na organizam sve do razine stvaranja dodatnih poremećaja. Konkretni primjeri uključuju otkrivanje depresije, kao primjerice u [14]. Pri tom se koriste različiti klasifikacijski postupci, a prepoznavanje depresije obavlja se na temelju nekoliko

različitih modaliteta podataka, pokreta očiju kao u [14] ili pokreta cijelog tijela kao u [15]. Druge bolesti, poput bipolarnog poremećaja, isto se tako mogu otkrivati sličnim pristupima. Valenza u [6] prikazuje ostvaren sustav koji na osnovi bioloških signala dobivenih s nosivih senzora omogućuje kliničku procjenu bipolarnog poremećaja. Osim dijagnostičke, prisutna je i terapijska primjena, kao što je prikazano u [16]. Okolina zasnovana na teoriji ozbiljnih igara nudi mogućnost terapijskog djelovanja, dok je raspoznavanje emocija provedeno uporabom značajki izdvojenih iz govora. Primjena afektivnog računarstva moguća je i kod osoba pogođenih autizmom, s obzirom da može omogućiti nadilazak barijere koja postoji između onoga što osoba pogođena autizmom osjeća i što uspijeva ispoljiti. Tsiopela et al. su u [17] prikazali mogućnost unaprjeđenja edukacije djece s autizmom. Uz navedene primjere primjene, zastupljeni su još otkrivanje stresa [18], trajni nadzor zdravstvenog stanja [19], ali i brojne druge, jedna od kojih je i raspoznavanje (razina) boli. Prema Prkachinu [8], ako postoji konfiguracija akcija mišićnih skupina lica koja označava bol, tada se procjena njene prisutnosti svodi na problem prepoznavanja uzoraka, preciznije na problem klasifikacije. Iste se mišićne skupine koriste i kod raspoznavanja emocija, pa stoga postoji snažna povezanost između ova dva problema, što će biti pobliže prikazano u nastavku ovog poglavlja.

2.2 Važnost boli - osjet, izražavanje i opažanje

Bol je, prema [7], vrlo neugodan osjet uzrokovan bolešću ili ozljedom. Prema Međunarodnom udruženju za istraživanje boli (engl. *International Association for the Study of Pain*, IASP) ona je neugodno osjetilno i emocionalno iskustvo povezano sa stvarnom ili mogućom ozljedom tkiva, ili pak iskustvo opisano u kontekstu takve ozljede [20]. Iako uvijek neugodan, ovaj osjet je od iznimne važnosti za svakodnevni čovjekov život jer u velikoj mjeri uvjetuje njegovo ponašanje. Često je upravo bol prvi znak da nešto nije u redu i motivacija za posjet liječniku, prva naznaka poremećaja ili bolesti koji bi kasnije mogli imati poguban utjecaj. Njen je značaj posebice uočljiv u slučajevima gdje je iz nekog razloga izostala njena pojava. Stanja poput kongenitalne neosjetljivosti na bol (engl. *congenital insensitivity to pain with anhidrosis*, CIPA) vezuju se uz izostanak pojave boli [21]. Osobe zahvaćene ovim problemom neće kada dožive traumu potražiti liječničku pomoć, već će u većini slučajeva nastaviti s ponašanjem koje je dovelo do traume. Primjerice, kontakt s izvorom topline i opekline koje nastaju dovode do osjeta boli i refleksne reakcije posljedica koje jest odmicanje od izvora topline. Ako osoba nastavi ostvarivati kontakt s izvorom topline, može doći do trajnih oštećenja tkiva i drugih ozbiljnih komplikacija.

Kod ostalih pacijenata, kod kojih iskustvo boli ne izostaje, opažanje i određivanje postojanja i intenziteta boli postaje korak koji prethodi svim idućim postupcima. Opažanje boli ima nekoliko bitnih zadataka. Prema [22], opažanje se koristi za procjenu ishoda liječenja, pro-


cjenu odnosa između ponašanja i psiholoških i društvenih čimbenika te određivanje podgrupa pacijenata prema bolnom ponašanju. Također, opažanje boli može pružiti uvid u promjene svakodnevnog ponašanja kod pacijenta. Liječnici, ali i drugi sudionici u zdravstvenom sustavu, također ovise o znakovima koji sugeriraju postojanje boli. Refleksi koji se javljaju uslijed bolnog iskustva mogu, prema [23], izmijeniti mehaniku disanja, povećati zahtjeve na kardiovaskularni sustav, izazvati stezanje mišića, dovesti do pojave hiperglikemije, povećane razine kortizola, ali i drugih hormona. S obzirom na važnost osjeta boli, nužno je zapitati se o važnosti njezina pravovremenog otkrivanja i određivanja njena intenziteta. Na temelju procjene intenziteta boli, uz ostale informacije, postavljaju se dijagnoze, sugeriraju daljnje pretrage ili propisuju terapije i postupci liječenja.

2.2.1 Osjet boli

Općenito, za registriranje bilo kojeg osjeta zadužene su osjetilne stanice, odnosno osjetilni neuroni različitih tipova. Kada se radi o osjetu boli, ovi se neuroni nazivaju nociceptorima (lat. *nocere*, povrijediti, ozlijediti). Zadaća ovih neurona jest na temelju intenziteta podražaja različitog porijekla reagirati na potencijalno štetan podražaj i poslati informaciju ka leđnoj moždini i mozgu. Potencijalno štetni podražaji mogu biti toplinski, mehanički i kemijski pa se tako razlikuju i vrste nociceptora koji ih registriraju. Pojedini nociceptori imaju i polimodalna svojstva, što znači da mogu istovremeno registrirati različite oblike podražaja. Signali uzrokovani navedenim podražajima prevode se u živčane signale, no samo ako su prisutni u dovoljnoj mjeri da dovedu do oštećenja tkiva [24]. Ovaj se proces naziva nocicepcijom i u uobičajenim prilikama dovodi do osjeta boli koja se naziva još i nociceptivna bol. Pojednostavljeni prikaz ovog prijenosa dan je slikom 2.2. Tri su osnovna tipa nociceptivne boli, a to su visceralna, somatska i površinska. Nociceptivna bol je uobičajeno kratkotrajna (uz iznimke poput artritisa), prolazi kako tkivo zarasta te reagira dobro na tretman opioidima [25]. Osim nociceptivne, postoje još i neuropatska i kombinirana bol. Neuropatska bol je često kronična, zahtjeva druge vrste lijekova te traje znatno nakon zarastanja oštećenog tkiva. Kod ovog tipa boli, signali koji propagiraju bol gube funkciju upozorenja.

Spomenuti signal boli provodi se živčanim vlaknima prema leđnoj moždini i kasnije mozgu. Tijekom osjeta boli aktivira se velik broj moždanih regija, što sugerira da ne postoji jedinstven centar za bol u mozgu. S obzirom da su navedene regije međusobno povezane, a različiti osjeti boli stvaraju različite interakcije među ovim moždanim strukturama, govori se često o matrici boli u mozgu (engl. *neuromatrix*, *pain matrix*) koju je uveo Melzack [26]. Matrica boli nije jedinstvena za sve ljude, a tijekom vremena se može čak izmijeniti iskustvom. Prema [26], signal koji dolazi preko leđne moždine okida neuromatricu koja stvara takozvani neuropotpis na temelju utjecaja gena, iskustva i osjeta, a kao izlaz iz neuromatrice proizlaze doživljaj boli, ponašanje i reakcija te unutarnja regulacija organizma pojačanim lučenjem

hormona. Informacije o boli koje dolaze s osjetilnih neurona oblikovat će stoga u svakom slučaju kultura, iskustvo, tjeskoba, očekivanje i brojni drugi čimbenici. Posljedično, ljudi na jednak bolan podražaj mogu imati različite reakcije [24, 27].



Slika 2.2: Pojednostavljeni prikaz prostiranja osjetilnih informacija od nociceptora do mozga

2.2.2 Izražavanje boli

Izražavanje boli je, baš kao i bolno iskustvo, podložno utjecaju dobi, kulture i drugih vanjskih čimbenika, a služi za komunikaciju postojanja bolnog stanja. Ljudi koji prolaze bolno iskustvo mogu to iskazati riječima, stenjanjem, plakanjem, žaljenjem te mogu iskazati određena držanja ili izraze lica. Prema Keefe [22], ova se ponašanja nazivaju bolnim ponašanjima, s obzirom da iskazuju postojanje bolnog stanja. Ponašanje koje iskazuje bol, prema [28], zapravo je surogat za bol, primjerice šepanje. Promatranjem bolnih ponašanja, moguće je doći do informacije o razinama boli koje pacijenti izdržavaju. Što se tiče intenziteta iskazivanja razina boli, osobe tijekom ranih faza života povezuju koncept boli s različitim bolnim iskustvima [20]. Prema tome, temeljem vlastitog iskustva i praga tolerancije definiraju bol različitog intenziteta.

Proučavanje razina boli uglavnom se još uvijek oslanja na usmena izvješća, odnosno verbalne informacije dobivene od pacijenata, usprkos činjenici da postoje opravdane sumnje vezane uz njihovu objektivnost, točnost i podložnost pristranosti [8]. Razlog tome vjerojatno leži u činjenici da je određivanje informacija o boli na temelju iskazanog ponašanja iznimno složen


zadatak. Ako bi se za informacije o boli koristio kakav sustav za promatranje pokreta mišića na licu, tada liječnik mora biti upoznat s takvim sustavom te mora proći adekvatnu pripremu za njegovu uporabu. Automatski sustavi ovakvog tipa ovise kako o snažnom sklopovlju, tako i o programskoj podršci koja još uvijek nije dostupna za provođenje analize u praksi. Iako se smatraju objektivnima, ovakvi pristupi i dalje mogu patiti od subjektivnosti [8]. Nadalje, iskazivanje bolnih stanja ponašanjem također je subjektivno i ovisi o pacijentu. Određeni ljudi iskazat će značajno veću razinu takvog ponašanja od drugih [22]. Osim toga, pod utjecajem vanjskih čimbenika, ali i vlastitog iskustva te trajnog trpljenja boli, moguće je i da pacijenti izražavaju nižu razinu boli nego što objektivno osjećaju. Ipak, usprkos svemu, izravno opažanje i bilježenje boli može dati objektivniju i točniju mjeru nego se može dobiti verbalnim iskazom [22, 8] ili ju barem upotpuniti, odnosno potvrditi.

2.2.3 Povezanost raspoznavanja emocija i razina boli

Bol je od početaka proučavanja smatrana emocionalnom kategorijom. Darwin je tako bio prvi koji je bol držao na istoj razini kao i ostala emocionalna iskustva. Prema [20], bol je osjećaj u dijelovima tijela, no bez sumnje je neugodan osjećaj te prema tome predstavlja također i emocionalno iskustvo. Ako se ode korak dalje, vidljivo je da bol ne mora biti samo fizička kategorija, već je moguće osjećati i takozvanu „emocionalnu” bol koja nastaje, primjerice, gubitkom bliskih osoba. Prema [29], prisutnost boli uzrokuje promjene u dijelovima mozga zaduženim za prepoznavanje emocija. S obzirom da je, prema navedenom, bol povezana s emocijama od uzroka, preko izražavanja pa sve do percipiranja, ne začuđuje činjenica kako su prvi koraci vezani uz računalno raspoznavanje boli krenuli iz raspoznavanja emocija i afektivnih stanja. Raspoznavanje emocija uporabom računalnih sustava aktivno je područje istraživanja koje rabi podatke različitih modaliteta u svrhu njihove klasifikacije. Unatoč mogućnosti korištenja bioloških signala poput elektrokardiograma (EKG), elektroencefalograma (EEG), vodljivosti kože, ili mogućnosti korištenja snimki govora koje je uglavnom lakše obraditi, korištenje izraza lica pokazalo se čestim odabirom. Pregledom literature provedenim u [30], otkriveno je kojim se podacima najčešće koristi kako bi se provelo raspoznavanje emocija, a udio pojedinih modaliteta, odnosno izvora podataka, prikazan je slikom 2.3.

Iz slike 2.3 moguće je uočiti da digitalne slike ili videozapisi izraza lica predstavljaju važan i čest izbor za dobivanje informacija. Pri tom se učestalo rabe različiti sustavi za obilježavanje pomaka mišićnih skupina na licu kodovima. Na temelju ovih kodova, koji bilježe kako konkretnu mišićnu skupinu, tako i intenzitet njena aktiviranja, moguće je zaključiti da je došlo do pojave emocije. Jedan od najkorištenijih sustava za kodiranje jest sustav kodiranja akcijskih jedinica (engl. *facial action coding system*, FACS) kojeg je dizajnirao P. Ekman [31]. Osim dizajna sustava za kodiranje, Ekman je ustvrdio kako izrazi lica kod izražavanja

emocija nadilaze kategorije poput dobi, spola, rase, pa čak i vrste. Prilikom svog rada na istraživanju mišićnih skupina za izražavanje boli, Prkachin je u [8] ustvrdio da među svim akcijskim jedinicama na licu uistinu postoje određeni mišići, odnosno postoji podgrupa akcijskih jedinica, koji se aktiviraju u ovisnosti o postojanju i intenzitetu boli.



Slika 2.3: Modaliteti podataka za raspoznavanje emocija


2.3 Računalno raspoznavanje razina boli

Trenutno se za potrebe određivanja razina boli rabe različiti protokoli koji uključuju samoizvješćivanje pacijenta uporabom različitih ljestvica. Na temelju ovog samoizvješćivanja liječnik može prosuditi o intenzitetu boli. Određivanje boli na temelju promatranja pacijenta, odnosno na temelju bolnih ponašanja, a na čemu bi se zasnivao i mogući računalni sustav, danas se rabi kao dodatan izvor informacija i podrška samoprocjeni. Još uvijek ne postoji računalni sustav koji bi u potpunosti automatski mogao odrediti razinu boli s visokim postotkom uspjeha. Cilj ovakvog, eventualnog, sustava nikako nije zamijeniti liječnika, već služiti kao sustav podrške njegovoj odluci, pogotovo u slučajevima gdje je interakcija s promatranim pacijentom otežana ili nije moguća. Kod računalnog određivanja razina boli, jedini mogući način jest rabiti bolna ponašanja kao dokaz o postojanju boli. Ipak, kod stvaranja podatkovnih skupova nužno je odrediti temeljnu istinu (engl. *ground truth*) o razini boli. Važno je stoga uzeti u obzir i klasične ljestvice, kakve se danas rabe kod samoprocjene i iskazivanja boli pacijenata, kako bi se kasnije računalne metode mogle vrednovati. Često se upravo pomoću njih određuje temeljna istina oko razine boli.

2.3.1 Ljestvice određivanja boli

S obzirom na subjektivni dojam i utjecaj vanjskih čimbenika koji oblikuju njen doživljaj, mjerenje boli nije lak zadatak. Uobičajeno se za određivanje razine boli rabe ljestvice intenziteta ili trajanja, a mjerenje obavlja ili liječnik (engl. *observer rating*) ili sam pacijent

pod nadzorom liječnika (samoprocjena, engl. *self-assessment*). Neke od najčešćih ljestvica su vizualno-analogni ljestvica (engl. *visual-analogue scale*, VAS), numerička ljestvica, kategorička ljestvica, a u specifičnim se slučajevima (primjerice kod djece) mogu rabiti i druge ljestvice određivanja boli poput ljestvice čaša, ljestvica lica i slično. Izgled nekih od mogućih ljestvica prikazan je slikom 2.4. Kvantificiranje se pri tome obavlja diskretnim razinama (izuzev VAS-a), gdje najniža predstavlja stanje bez boli, dok najviša razina predstavlja ekstremne razine boli. Prilikom uporabe navedenih ljestvica važno je, naravno, da i promatrač i pacijent budu upoznati s njihovim korištenjem.




Slika 2.4: Različite ljestvice intenziteta boli

Kod verbalnih ljestvica, pacijentu se nudi nekoliko riječi prema kojima treba odrediti razinu boli, a iste su uobičajeno poredane prema intenzitetu, primjerice: bez boli, slaba, umjerena, jaka. Prednost ove ljestvice leži u tome što je relativno jednostavna i moguće je njome brzo dobiti informaciju o razini boli. Navedene prednosti ne vrijede ukoliko se rabi velik broj razina, a također je važno naznačiti da razlike među ponuđenim kategorijama često nisu jednake, iako ih se u pravilu takvima doživljava i tretira. Kod numeričkih ljestvica, razine boli označene su brojčanim vrijednostima, gdje najmanja vrijednost predstavlja stanje bez

boli, dok najviša vrijednost predstavlja najgoru moguću bol. Vrlo se često primjenjuju jer ih pacijenti dobro prihvaćaju, lake su za interpretaciju, a omogućuju i različite načine prikupljanja podataka. Nedostaci su slični onima kod verbalnih ljestvica i vezani uz broj razina i razliku među pojedinima od njih. Kod vizualno analognih ljestvica od pacijenta se zahtijeva da na dužini između dvije krajnje vrijednosti naznači razinu boli koju osjeća. Mehanički se ovakve ljestvice ostvaruju otisnutim dužinama na listu papira ili posebnim ravnalima. Prednost ovakvih ljestvica jest puno bolja granulacija razina boli, no nedostatak jest puno dulje vrijeme potrebno za analizu rezultata, kao i činjenica da pacijenti najteže shvaćaju ovaj način vrednovanja boli u odnosu na ostale moguće. Specifične ljestvice, kao što su ljestvica čaša ili lica predstavljaju opet kategorički pristup mjerenju boli s jednakim prednostima i nedostacima, ali prikazom su prihvatljivije i prilagođene ciljanim skupinama.

Uz navedene su ljestvice prisutne također i ljestvice, odnosno mjerenja prema ponašanju, koje na važnosti dobivaju kod određivanja razine boli promatranjem. U slučaju računalnog određivanja razina boli, pojavila se, unazad nekoliko godina, nova mjera intenziteta pod nazivom Prkachin-Solomon indeks intenziteta boli (engl. *Prkachin Solomon pain intensity*, PSPI). Ova mjera zasnovana je na mjerenju intenziteta pomaka mišićnih skupina lica. Naime, P. Ekman uočio je je niz mišićnih skupina na licu čije aktiviranje i intenzitet istoga određuju izražavanje emocija i afektivnih stanja. Ove akcijske jedinice (engl. *action unit*, AU) nadilaze kako rasu, dob, tako čak i vrstu, s obzirom da su uočljive kako kod ljudi, tako i kod nekih životinja. Definiran je također sustav FACS kojime je moguće kvantizirati aktiviranje i intenzitet aktiviranja pojedine jedinice, i to na šest diskretnih razina. Kako bi se dobio bolji uvid u opisani sustav, slikom 2.5 dan je prikaz regija lica uz koje su vezane pojedine akcijske jedinice.



Slika 2.5: Akcijske jedinice pomaka mišićnih skupina prema sustavu FACS

Prkachin i Solomon u svom su radu [32] uočili da određeni podskup ovih akcijskih jedinica sudjeluje u izražavanju boli, te su prema postojanju aktiviranja i njegovu intenzitetu definirali indeks PSPI koji kvantizira bol u 16 diskretnih razina. Izraz prema kojem se određuje iznos boli dan je prema

$$PSPI = AU4 + \max\{AU6, AU7\} + \max\{AU9, AU10\} + AU43, \quad (2.1)$$

gdje je AU_i određena akcijska jedinica, to jest njen intenzitet. Vidljivo je, prema danom izrazu, da se pri određivanju razine boli razmatraju akcijske jedinice 4, 6, 7, 43, 9 te 10. Riječ je o jedinicama koje opisuju redom spuštanje obrva, podizanje obraza, sklapanje očnih kapaka, zatvaranje očiju, mreškanje nosa te podizanje gornje usne. Za svaku se od ovih akcijskih jedinica određuje intenzitet i to tako da se oznaci akcijske jedinice pridoda znakovna oznaka od A do E, gdje A predstavlja minimalan, a E maksimalan intenzitet. Prikaz akcijskih jedinica kod prisutnosti boli kao i određivanje PSPI indeksa dani su slikom 2.6.



Slika 2.6: Primjer intenziteta akcijskih jedinica povezanih s boli na licu

Niti jedan od načina određivanja razine boli nije bez problema. Problem kod samoprocjene i izražavanja boli opisanim ljestvicama jest subjektivnost, čiji utjecaj može odrediti razinu boli na različite načine, pristrano, radi osobnog iskustva i praga tolerancije. Kod procjene promatrača, odnosno liječnika nužno je da isti posjeduje potrebno znanje i iskustvo, ali je potrebno uzeti u obzir utjecaj psihofizičkog stanja promatrača poput umora, smetenosti ili stresa. Uz to, prema [23], interpretacija boli koju provodi liječnik, odnosno zdravstveni djelatnik podložna je izazovima iz različitih razloga, poput intubacije, problema s motorikom, kulturnih i jezičnih barijera te izmijenjenih stanja svijesti.

Automatski sustav koji bi se rabio kao alat za određivanje razine boli i koristio kao potpora odluci liječnika uklonio bi, barem dijelom, problem subjektivnosti procjene. Neka od svojstava koje bi automatski sustav trebao posjedovati su:

- Neinvazivnost u radu,
- Praćenje promjena intenziteta boli tijekom duljeg vremenskog perioda,

- Neovisnost o pacijentu,
- Objektivna procjena,
- Informacija o sigurnosti (uvjerenosti) u procjenu,
- Mogućnost korištenja u kliničkom okruženju i
- Očuvanje privatnosti podataka pacijenta.

2.3.2 Dostupni podaci s prikazom bolnih stanja

Jedan od osnovnih problema koji se, u manjoj ili većoj mjeri, pojavljuje u svim problemima raspoznavanja i kategorizacije uzoraka jest dostupnost podatka. Često je broj dostupnih podataka ograničen, a u najgorem slučaju uopće ne postoji skup podataka koji bi se rabio kao temelj za usporedbu različitih postupaka. Prikupljanje podataka kod složenih problema samo je po sebi zahtjevno, s obzirom da istraživač koji je uključen u prikupljanje podataka strogo mora pratiti proceduru koju definira struka. Ako se govori o medicinskim problemima, tada podatke prikuplja stručnjak u kontroliranim uvjetima i na kontroliran način. Neodgovarajuće prikupljanje podataka može imati snažan utjecaj na pristranost kasnijih metoda analize. Kod podataka vezanih uz medicinske postupke, problem prikupljanja podataka dobiva i dodatnu dimenziju koja se tiče privatnosti pacijenta. Za sve je prikupljene podatke nužno osigurati odobrenje pacijenta koji je promatran, pri čemu se određuju točne kategorije primjena za koje se dopušta uporaba, primjerice znanstvena istraživanja, komercijalne primjene, kao i obim radnji koji je dozvoljen, primjerice dijeljenje, izmjena i slično. Trenutno je za istraživačke potrebe dostupno više različitih baza s podacima o boli pacijenta, od kojih su najvažnije prikazane u tablici 2.1. S obzirom da raspoznavanje razina boli korijene vuče iz afektivnog računarstva, postoji pitanje razlikovanja boli i osnovnih emocija [33], a moguće je koristiti podatke vezane uz izražavanje emocija kao potporu raspoznavanja boli kao u [34]. Tablica 2.1 upotpunjena je stoga dodatnim informacijama i o takvim skupovima podataka. Detaljniji opis baza koje su strogo vezane uz raspoznavanje boli dan je u nastavku.

Baza koja se rabi za procjenu boli kod novorođenčadi prikazana je u [37] i nazvana *Infant COPE*. Ona sadrži 204 fotografije 26-ero novorođenčadi, stare između 18 i 36 sati. Riječ je o slikama koje prikazuju lice novorođenčeta koje je u trenutku slikanja stimulirano različitim načinima. Bol je izazivana ubodom u petu, a primijenjena su i tri druga podražaja, koji ne uključuju izazivanje boli: struganje pete, puhanje zraka po nosu te prijenos između kolijevki. Navedeni podražaji su korišteni za izazivanje reakcije na licu, s ciljem uviđanja razine utjecaja drugih reakcija novorođenčeta na raspoznavanje boli. Konačno, baza sadrži i slike izraza lica gdje nije bilo nikakvog podražaja (engl. *baseline*).

Tablica 2.1: Baze (podatkovni skupovi) za procjenu boli i emocija

Naziv	Opis	Izvor
UNBC-McMaster	Slike lica, bol inducirana rotacijom i pomicanja ozlijeđenog ramena, sve slike FACS kodirane, dani PSPI i VAS	[35]
BioVID	Video lica i biometrijski signali, bol inducirana toplinskom narukvicom, četiri razine boli	[36]
Infant COPE	Slike lica novorođenčadi	[37]
DEAP	Biosignali	[38]
GEMEP	Multimodalna	[39]
DISFA	Slike lica	[40]
Cohn Kanade (CK+)	Slike lica	[41]
Mahnob laughter	Multimodalna	[42]
Mahnob HCI	Multimodalna	[43]
SEMAINE	Multimodalna	[44]
NVIE	Slike lica	[45]

Jedna od prvih dostupnih baza bolnih izraza lica odraslih osoba jest baza bolnih slika lica nastala na *University of North British Columbia* (UNBC) pod nazivom „UNBC-McMaster”, a koja je predstavljena u [35]. Baza je nastala snimanjem pacijenata video kamerom u kliničkim uvjetima, tijekom pregleda bolnog ramena. Pacijentima je zakretana i pomicana ruka kod koje je došlo do iščašenja ramena, a svaki video okvir (engl. *frame*) iz sekvence je dan kao slika u bazi. Od većeg broja snimljenih pacijenata dostupne su video sekvence za njih 25, s ukupno nešto manje od 50 tisuća slika. Za svaku sekvencu dane su sve slike koje ju sačinjavaju, a procjene boli dane su, kako za pojedinu sekvencu, tako i za pojedinu sliku. Razine boli definirane su PSPI indeksom, vizualno analognom ljestvicom i procjenom promatrača.

Nešto novija je baza pod nazivom BioVID [36] koja uz slike lica donosi i druge podatke na temelju kojih je moguće određivati razine boli. Naime, baza je kreirana na temelju promatranja i snimanja 90 dobrovoljaca različitih dobnih skupina prilikom primanja bolnog stimulansa izazvanog toplinskom narukvicom. Za prikupljanje sirovih podataka korišteni su različiti biološki senzori poput EKG-a, elektromiograma i EEG-a, tri videokamere postavljene pod kutovima 90° te 45° slijeva i zdesna te konačno Microsoftove Kinect kamere kako bi se prikupile informacije o dubini. Razina boli dobivena je samoprocjenom, a razmatraju se četiri različite razine boli. Da bi se uvidjelo koliko sustav može razlikovati stvarnu bol od emocionalnih stanja i glumljene boli, kandidati su morali glumiti bolna stanja i osnovne emocije, a nakon svega su im prikazivane videosekvence koje izazivaju emocionalnu reakciju. Ovakve postavke eksperimenta za cilj su imale ispitati utjecaj položaja glave kandidata na procjenu razine boli, važnost bioloških signala za istu potrebu te mogućnost razlikovanja između stvarne i glumljene boli te boli i stvarnih odnosno glumljenih osnovnih emocija.


S obzirom da je izražavanje boli različito kod djece i odraslih, rabi se različita metodologija za određivanje razina boli. U ovoj disertaciji cilj je obraditi raspoznavanje razine boli kod

odraslih osoba, kod kojih je lice u potpunosti formirano pa stoga baza Infant-COPE nije razmatrana. Nadalje, kod određivanja razine boli, kao što je ranije opisano, postoje različiti načini procjene. Za bazu UNBC-McMaster dane su oznake klasa na različitim ljestvicama, a navedene vrijednosti prikupljene su na temelju procjene stručnjaka. Za bazu BioVID dane vrijednosti nastale su na temelju samoprocjene. Postavke eksperimenta značajno se razlikuju kod ove dvije baze, jer se kod UNBC-McMasters koristilo kliničko okruženje s jednom kamerom i pacijenti s kroničnom boli, dok su kod baze BioVID podaci prikupljeni na dobrovoljcima bez boli gdje je ona umjetno inducirana. Također, količina senzora koja je primijenjena prilikom prikupljanja podataka kod potonje predstavlja optimističan scenarij prikupljanja podataka koji često nije moguće postići. S obzirom na navedeno, ali i na činjenicu da je baza UNBC-McMasters snažnije zastupljena u literaturi, ona je i odabrana kao testna okolina za unaprijeđene postupke predložene u ovoj disertaciji. U budućem bi radu bilo dobro iskoristiti i druge postojeće baze, kao i baze s prikazom emotivnih stanja radi razmatranja utjecaja prikupljanja podataka, metodologije procjene razina boli i drugih faktora na uspješnost raspoznavanja razina bol te mogućnosti razlikovanja između boli i primarnih emocija. Iz odabrane baze UNBC-McMasters korištene su pojedine slike kako bi se procijenila bol, iako je procjenu boli moguće provesti i na razini sekvence. U tom slučaju postoji i vremenska komponenta boli, odnosno vrijeme kada nastupa vršna razina boli što u ovoj doktorskoj disertaciji nije razmatrano.

2.3.3 Vrednovanje raspoznavanja razina boli

Računalno raspoznavanje razina boli pripada skupini klasifikacijskih problema unutar područja raspoznavanja uzoraka. Procjena uspješnosti rješenja ovakvih problema je složena, a moguće ju je postići na više različitih načina. Glavni problem kod vrednovanja bilo kojeg postupka na problemima ovog tipa leži u činjenici da se radi na uzorku podataka čija raspodjela ne mora odgovarati razdiobi stvarnih podataka. Također, broj dostupnih podataka je često ograničen. S obzirom na navedeno, moguće je da dobiveni rezultati ne odražavaju rezultate koji se kasnije uporabom istog modela postižu na novim, nepoznatim uzorcima. Spomenuto proizlazi iz potrebe ovih postupaka da moraju iskoristiti dio podataka za učenje (treniranje klasifikatora, odnosno oblikovanje klasifikacijskog modela), a dio za njegovo testiranje i vrednovanje. Raspodjela podataka pri tome može imati značajan utjecaj na rezultate. Nadalje, ovim se postupcima smanjuje broj uzoraka dostupnih za učenje, što može dovesti do modela koji je pretjerano prilagođen podacima koje je vidio (engl. *overfitting*). Najčešći postupci raspodjele podataka za potrebe vrednovanja su postupak izostavljanja (engl. *holdout*), postupak unakrsne provjere k preklopa (engl. *k-fold cross-validation*) i metoda *bootstrap*, a načela rada svakog od navedenih ilustrirani su slikom 2.7.

Postupak izostavljanja prilikom izgradnje i vrednovanja klasifikacijskog modela dijeli podatke



Slika 2.7: Podjela skupa podataka za potrebe analize klasifikacije

s poznatim oznakama na dva disjunktna podskupa. Prvi skup uobičajeno sadrži veći broj instanci od drugog i koristi se za izgradnju modela, dok se drugi rabi za vrednovanje. Ovo se čini da bi se u potpunosti odvojili podaci na kojima model uči od onih na kojima je vrednovan, sve u svrhu uklanjanja pretjerane prilagodbe modela poznatim podacima. U određenim slučajevima, kada je primjerice potrebno provesti i određeno unutarnje podešavanje, podaci se mogu podijeliti i na tri dijela, pri čemu se na najvećem dijelu uči, na jednom od manjih provodi unutarnja provjera (engl. *validation*), a na preostalom se provodi vrednovanje.

S obzirom da je broj podataka koji su dostupni za izgradnju klasifikacijskog modela u najvećem broju slučajeva ograničen, razlamanje u nekoliko odvojenih skupova za učenje i testiranje još će više umanjiti količinu podataka na kojima bi model mogao naučiti. Stoga se često koristi unakrsno vrednovanje kod kojeg se skup podataka dijeli na k disjunktivnih podskupova, najčešće 5 ili 10. Svaki od navedenih skupova koristi se samo jednom za testiranje, dok se preostalih $k - 1$ skupova koristi za učenje. Na ovaj se način u potpunosti iskorištavaju svi dostupni podaci, a također se smanjuje utjecaj nasumične podjele originalnog skupa na rezultate vrednovanja. Posebna inačica ovog načina raspodjele dobiva se izostavljanjem jedne instance (engl. *leave-one-out-cross-validation*), gdje se samo ona koristi za vrednovanje, dok se sve ostale instance rabe za učenje.


Metoda *bootstrap* koristi se kod podatkovnih skupova s malim brojem instanci. Kod nje se umjetno stvara niz skupova na temelju izvornih instanci uporabom odabira sa zamjenom. Naime, generira se relativno velik broj novih skupova koji sadrže originalne instance s duplikatima. Tada se vrednovanje provodi na pojedinim skupovima dok se preostali koriste za učenje.

Kod raspoznavanja boli pojavila se prilagođena inačica unakrsne provjere koja se naziva izostavljanje subjekta (engl. *leave one subject out*, LOSO) [46, 47, 48]. Ova inačica podrazumijeva izgradnju klasifikacijskog modela na temelju podataka dobivenih od $n - 1$ subjekata, odnosno osoba koje su sudjelovale u prikupljanju podataka, gdje se preostali subjekt koristi za potrebe testiranja. Nakon provođenja opisanog postupka treniranja i testiranja za svakog subjekta, računa se prosjek rezultata po subjektima i uzima kao mjera kvalitete. Ovaj pristup je relativno strog, s obzirom da prisiljava klasifikator raspoznavati razine boli osoba

koje ranije nije susreo i na čijim licima nije imao priliku učiti.

2.3.4 Mjere kvalitete raspoznavanja

U svrhu predstavljanja rezultata klasifikacije, odnosno mjerenja kvalitete raspoznavanja bolnih stanja rabe se standardne mjere kvalitete iz literature. Dva su različita načina za definiranje mjera kvalitete, a to su matrica zabune (engl. *confusion matrix*, CM), primjer koje je dan slikom 2.8 i analiza krivulje operativnih karakteristika (engl. *receiver operator characteristic*, ROC), također prikazana slikom 2.8.



Slika 2.8: Mjere kvalitete raspoznavanja: (a) matrice zabune, (b) krivulja ROC

Kod mjera kvalitete koje proizlaze iz CM, najčešće je korištena preciznost klasifikacije (engl. *classification accuracy*, *Acc*) koja predstavlja omjer uspješno klasificiranih uzoraka i ukupno dostupnih uzoraka za testiranje, odnosno vrednovanje, a dana je izrazom

$$Acc = \frac{T_p + T_n}{P + N}, \quad (2.2)$$

pri čemu T_p označava broj ispravno klasificiranih uzoraka jedne klase (stvarno pozitivni, engl. *true positive*), T_n broj ispravno klasificiranih uzoraka druge klase (stvarno negativni, engl. *true negative*), dok P i N predstavljaju ukupan broj uzoraka prve, odnosno druge klase. Ipak, kod korištenja ove mjere treba biti oprezan jer uvelike ovisi o podatkovnom skupu na koji se primjenjuje. Naime, ako je riječ o skupu podataka gdje broj instanci različitih klasa nije ujednačen, *Acc* neće ponuditi adekvatnu ocjenu uspješnosti. Ako se, primjerice, rješava binarni klasifikacijski problem, a jedna je klasa zastupljena s 95 posto podataka, tada će kategorizacija svih dostupnih testnih instanci u većinsku klasu rezultirati uspješnošću u smislu *Acc* od 0.95. Posebice ovo predstavlja problem uzevši u obzir činjenicu da je kod većine problema u prirodi interesna klasa u stvari manjinska (detekcija pogreške, postojanje boli). Da bi se doskočilo ovom problemu, razvijene su na temelju CM-a različite mjere kvalitete koje omogućuju detaljniji prikaz rezultata, poput preciznosti (engl. *precision*, *Pre*)

i odziva ili osjetljivost (engl. *recall*, *sensitivity*, *Rec*). Preciznost predstavlja omjer točno klasificiranih uzoraka neke klase i svih uzoraka koji su klasificirani kao članovi te iste klase, čak i onih koji joj ne pripadaju (lažno pozitivni, engl. *false positive*, F_p) i dana je prema

$$Pre = \frac{T_p}{T_p + F_p}. \quad (2.3)$$

Odziv predstavlja omjer broja ispravno klasificiranih uzoraka neke klase i broja svih instanci koje pripadaju toj klasi, uključujući i one kojima je dodijeljena oznaka neke druge klase (lažno negativni, engl. *false negative*, F_n), a dan je prema

$$Rec = \frac{T_p}{T_p + F_n}. \quad (2.4)$$

S obzirom da je razmatranje i konačna ocjena kvalitete postupka složena i nepregledna ako se koristi više pokazatelja, definirani su pokazatelji koji se oslanjaju na njih i objedinjuju informacije koje donose navedeni osnovni pokazatelji. Jedan od njih je i F-mjera (engl. *F-score*), koja je dana prema

$$F_\beta = (1 + \beta^2) \cdot \frac{Pre \cdot Rec}{(\beta^2 \cdot Pre) + Rec}. \quad (2.5)$$

Najčešća vrijednost koja se odabire za parametar β jest 1, pa se tako i F-mjera često naziva F1-mjera. Ova mjera nije toliko osjetljiva na udio instanci pojedine klase u podatkovnom skupu pa se prema tome često koristi i u problemima ranije navedenih svojstava.

Drugi način prikaza rezultata je korištenje ROC krivulje koji omogućuje grafički prikaz rezultata klasifikacije na temelju različitih točki promatranja. Kao kod ranijih, i kod nje je bilo nužno omogućiti brz i jednostavan uvid u kvalitetu na temelju jedne vrijednosti pa je za te svrhe upotrijebljena površina ispod krivulje (engl. *area under the curve*, *AUC*). Nasumičan klasifikator ima $AUC = 0.5$, savršeni klasifikator $AUC = 1$, a klasifikatore je moguće izravno usporediti prema ovoj vrijednosti.

Kao što je vidljivo iz izraza (2.3) i (2.4), te su mjere kvalitete definirane za probleme binarne klasifikacije. Moguće ih je proširiti tako da se primjenjuju i na probleme višeklasne klasifikacije kakav je i problem raspoznavanja razina boli, a to se postiže korištenjem takozvanog sam-protiv-svih pristupa, gdje se problem svodi na problem binarne klasifikacije tako da se promatrana klasa tretira kao pozitivna dok se sve ostale klase tretiraju kao negativna klasa. Zatim se provodi mikro ili makro agregacija rezultata, ovisno o potrebi [49]. Pri tome mikro agregacija uzima u obzir raspodjelu klasa, dok makro agregacija tretira svaku klasu na jednak način. Analiza ROC krivulje također je definirana za binarne klasifikacijske probleme, a na višeklasne je primjenjiva tako da se izradi zasebna ROC krivulja za svaku klasu. Što

se tiče mjere AUC koja proizlazi iz ROC krivulje, ona se proširuje na višeklasne probleme upravo računanjem mjere AUC iz zasebnih krivulja ROC.

Izdvajanje opisnih značajki boli iz slika lica

*"The key to artificial intelligence has always been the representation."
- Jeff Hawkins*

PREDSTAVLJANJE izvornog signala, odnosno izvornih podataka, nizom vrijednosti koje ga opisuju, bilo da je riječ o slici, zvuku ili kakvom drugačijem obliku podataka dobivenom s različitih izvora, naziva se izdvajanjem značajki. Izdvajanje značajki jedan je od prvih i osnovnih koraka nužnih u raspoznavanju uzoraka, kategorije problema u koju pripada i raspoznavanje razina boli. Navedeni zadatak u pravilu nije jednostavan te zahtijeva dobro poznavanje problema da bi se izdvojile one značajke koje u najvećoj mjeri omogućuju diskriminaciju između klasa. Ovo poglavlje ima za cilj predstaviti problem izdvajanja značajki te poteškoće koje se pri tome susreću, pri čemu će biti opisani neki od postupaka izdvajanja značajki iz slika bolnih lica predstavljeni u literaturi. Također, bit će predstavljen unaprijeđeni postupak za izdvajanje značajki, zasnovan na shearlet transformaciji, koji ujedno predstavlja i prvi očekivani izvorni znanstveni doprinos. Detaljnije će biti izloženi pojedinačni koraci ovog postupka, a u svrhu procjene njegove uspješnosti provest će se eksperimentalna analiza na standardnom podatkovnom skupu bolnih izraza lica. Kvaliteta klasifikacije ostvarena uporabom značajki proizašlih iz predloženog pristupa bit će uspoređena s kvalitetom postignutom uporabom značajki proizašlih iz nekoliko različitih postupaka

iste namjene predstavljenih u literaturi. Uvid u rezultate treba dati dojam o prednostima i mogućim nedostacima predloženog postupka.

3.1 Problem izdvajanja opisnih značajki

Flach u [50] predstavljanje instance problema vektorom značajki naziva apstrakcijom, a ista je rezultat uklanjanja viška informacija. Iz izvornih vrijednosti signala koji su uobičajeno vrlo visoke dimenzionalnosti, primjerice digitalne slike visoke razlučivosti, cilj je dobiti značajno manji broj značajki koji problem opisuje na bolji način. Theodoridis i Koutroumbas u [9] navode kako postoje dvije glavne skupine značajki, one koje pripadaju kontinuiranom skupu (primjerice \mathbb{R}) te one koje pripadaju konačnom diskretnom skupu (primjerice krvne grupe). Formalnije rečeno, kod izdvajanja opisnih značajki boli iz slika sivog intenziteta, kakve prikazuju izraze lica, uglavnom se rabe značajke koje dolaze iz kontinuiranog skupa, a dobivaju se na temelju preslikavanja $f : \mathbb{I} \rightarrow \mathbb{R}^d$ koje problem iz prostora izvornih podataka, odnosno digitalne slike, označene s \mathbb{I} , preslikava u prostor značajki.

Dva ključna pitanja koja je moguće susresti prilikom apstrakcije uključuju način izdvajanja značajki, odnosno definiranje preslikavanja f te određivanje potrebnog (najboljeg) broja značajki. Oba ova problema usko su vezana uz osnovni problem iz prirode koji se rješava, a ovisni su o njegovim svojstvima. Određivanje preslikavanja f važno je jer značajke koje se izdvoje moraju posjedovati dobra svojstva u smislu razdvajanja instanci po klasama. Prema [10], idealan postupak izdvajanja značajki učinio bi zadatak klasifikatora trivijalnim u tom smislu, dok bi idealan klasifikator isto učinio postupku izdvajanja značajki. Budući da takvi postupci ipak nisu dostupni, rabi se znanje o problemu te se značajke modeliraju na temelju njega. S obzirom da problem koji se razmatra u ovoj disertaciji dolazi iz područja računalnog vida, odnosno da su podaci na temelju kojih se donose konačne odluke digitalne slike, ideje za značajke koje bi mogle biti izdvojene u dobrom dijelu slučajeva proizlaze iz razmatranja rada ljudskog sustava za vid. Uočavaju se zakonitosti koje ondje vrijede prilikom obrade te ih se pokušava prenijeti na računalo. Detalji slike koji se često koriste kao izvori informacija vezani su uz postojanje snažnije ili blaže naglašenih oštarih prijelaza, odnosno rubova površina na slici, tekstura i geometrije dijelova lica. Riječ je o dvjema glavnim grupama značajki, prema [47, 48], značajkama oblika i značajkama izgleda čijom se zajedničkom uporabom može raspoznati razine boli na ljudskom licu.

Kod uporabe velikog broja značajki važno je povesti računa o takozvanom "*prokletstvu dimenzionalnosti*". Riječ je o terminu koji je uveo R. Bellman u [51], a prisutan je u brojnim područjima, od kojeg je jedno i raspoznavanje uzoraka. Ovaj termin opisuje činjenicu da rastom dimenzionalnosti podataka raste i količina podataka koja je nužna da bi se potkrijepili bilo kakvi zaključci dobiveni na temelju tih podataka u prostoru visoke dimenzionalnosti.

Posebice je zanimljiv u ovom kontekstu Hughesov fenomen, koji govori da kod ograničenog broja instanci mogućnost predviđanja opada porastom dimenzionalnosti [52]. Prema tome, vidljivo je da složenost problematike uvelike raste porastom dimenzionalnosti. Broj potrebnih značajki ovisan je o problemu koji se rješava, odnosno o njegovim svojstvima poput broja instanci, kompleksnosti granice odluke, klasifikatoru koji se rabi te raznim drugim parametrima. Stoga često nije moguće unaprijed reći ili na kakav način empirijski odrediti koja je vrijednost odgovarajuća za određeni problem. Pri tom će u pravilu manji broj značajki dovesti do lakšeg oblikovanja klasifikacijskog modela, dok će veći broj značajki otežati ovaj posao. No, potonji će slučaj istovremeno moguće uvesti dodatne informacije koje će pridonijeti diskriminaciji među klasama. Čest je u praksi slučaj da se unaprijed odabere veći broj značajki nego je potreban, a da se tek nakon toga pristupa odabiru najboljeg njegova podskupa, što je detaljnije opisano u poglavlju 4. Ovim načinom unaprijed se ne odbacuju informacije koje bi mogle unaprijediti kvalitetu prepoznavanja uzoraka, isključivo radi održavanja niske dimenzionalnosti problema, premda ovo ipak predstavlja izrazito poželjno svojstvo.

3.2 Postojeći postupci izdvajanja značajki za predstavljanje bolnih stanja

Postupci za izdvajanje značajki kojima bi se predstavila razina boli na slikama lica oslanjaju se uglavnom na regije lica koje iskazuju najveće promjene prilikom osjeta boli te ranije opisane promjene u izgledu i obliku koje se pojavljuju na tim regijama. Spomenute regije vezane su uz pojedine mišićne grupe na licu, koje su često kodirane nekim sustavom za kodiranje mišićnih akcijskih jedinica. Najpopularniji takav sustav za kodiranje zasigurno je sustav FACS. Na temelju FACS kodova dobivena je uostalom i temeljna istina, odnosno informacija o razini boli, za bazu UNBC-McMaster, kao što je je i opisano u poglavlju 2.3. Ta baza korištena je u brojnoj literaturi kao skup podataka uključen u eksperimentalno vrednovanje. S obzirom na važnost problema raspoznavanja razina boli, ne začuđuje kako su u literaturi dostupni različiti postupci za izdvajanje značajki u svrhu njena predstavljanja.

Brahnam et al. su u [53] rabili koeficijente diskretne kosinusne transformacije (engl. *discrete cosine transform*, DCT) za klasifikaciju postojanja boli kod novorođenčadi na osnovu baze *Infant COPE*. Nakon predobrade koja se sastojala od rotiranja i skaliranja slike lica djeteta, na svakoj je slici obavljena DCT. Na temelju njenih koeficijenata kreirana su dva podatkovna skupa. U prvom skupu koeficijenti su rangirani prema varijanci, dok je za drugi skup empirijski određeno 80 najznačajnijih koeficijenata. U potonjem je slučaju proveden i odabir značajki što je konačan broj koeficijenata spustilo na 15. Analiza je provedena metodom izostavljanja subjekta, a rezultati sugeriraju da ove značajke mogu pokazati prisutnost boli

kod novorođenčadi.

Tvorci baze UNBC-McMasters u [48] pretpostavili su da su za otkrivanje akcijskih jedinica kojima je bol predstavljena važne značajke oblika i značajke izgleda. U tu svrhu kreirali su nekolicinu podatkovnih skupova. Prvi od njih sastojao se od koordinata točaka koje predstavljaju vrhove trokuta u mreži trokuta nastaloj stvaranjem aktivnog modela izgleda (engl. *active appearance model*, AAM). Skup ukupno sadrži 68 točaka u dvije dimenzije, odnosno vektori značajki imaju 136 elemenata. Drugi skup dobiven je primjenom afinog izobličenja svakog od spomenutih trokuta s ciljem dobivanja kanoničkog izgleda lica. Kako bi izravna primjena kanoničkog izgleda lica bila neupotrebljiva u praksi (riječ je o vektoru značajki od 27000 elemenata), na njemu je provedena DCT, a uzimano je 100, 200 i 500 koeficijenata. Dodatni, treći, skup podataka dobiven je spajanjem prethodno opisanih dvaju skupova, odnosno provedena je fuzija na razini podataka. Pokazano je da su pojedine akcijske jedinice bolje otkrivane jednim tipom značajki, pojedine drugim, dok je prosječno najbolje rezultate dala kombinacija AAM značajki i 500 DCT koeficijenata. Ista vrsta značajki korištena je u [54] i kasnije u [55], kako za otkrivanje akcijskih jedinica i računanje razine boli, tako i za izravno otkrivanje postojanja boli. Sličan oblik značajki, točke dobivene iz AAM-a, kao i kanonički izgled lica korišteni su i u [56]. Međutim, u ovom slučaju nije provedena DCT već su značajke korištene izravno, što je rezultiralo vektorima od preko 27000 elemenata. Iste metode izdvajanja značajki korištene su i u [57].

Hammal i Cohn koristili su ranije opisani postupak predobrade slike lica (stvaranje AAM-a) kao osnovu za automatsko raspoznavanje razina boli u [46]. Naime, na kanonički prikaz lica dobiven na temelju AAM-a primijenjena je banka *log-normal* filtara, a odziv na iste, nakon primjene inverzne Fourierove transformacije, korišten je kao vektor značajki. Ukupno je takav vektor značajki sadržavao 9216 elemenata. Za klasifikaciju su korišteni strojevi s vektorima podrške (engl. *support vector machine*, SVM), a problem velikog broja instanci riješen je nasumičnim uzorkovanjem i uporabom oko petnaest posto od ukupnog broja instanci za učenje. Korištena su dva načina analize, izostavljanje subjekta i metoda unakrsne provjere korištenjem k preklopa. Uočeno je da metoda izostavljanja subjekta dovodi do znatno niže kvalitete raspoznavanja, što je i očekivano s obzirom da je riječ o vrlo strogom načinu vrednovanja.

Navedene osnovne postupke koristili su i Kaltwang et al. u [47] za kontinuiranu procjenu intenziteta boli iz izraza lica. Uz AAM točke i 500 DCT koeficijenata, autori su predložili i uporabu lokalnih binarnih uzoraka (engl. *local binary patterns*, LBP) kao značajki izgleda. Slika lica podijeljena je na 81 nepreklapajuću regiju, a na svakoj od regija izračunat je histogram uniformnih LBP-a. Konačni vektor značajki dobiven je spajanjem pojedinih histograma, što je rezultiralo vektorom značajki od 4779 elemenata. Svakim od podatkovnih skupova treniran je jedan stroj s vektorima relevantnosti (engl. *relevance vector machine*,

RVM). Riječ je o klasifikatoru, po strukturi i načinu rada jednakom SVM-u, no kao rezultat on daje vjerojatnost pripadnosti klasi. Odluke navedenih klasifikatora dovedene su na novi RVM koji je omogućio fuziju na razini odluke o intenzitetu boli. Provedena su dva eksperimenta, jedan s ciljem određivanja akcijskih jedinica, a drugi s ciljem automatskog određivanja razine boli. Prikazani rezultati sugeriraju da su vektori značajki zasnovani na LBP-ima dali najbolje rezultate pojedinačno, a da se fuzijom na razini podataka, kao i fuzijom na razini odluke može postići i veća kvaliteta raspoznavanja.

S ciljem smanjenja broja značajki, a istovremenog povećanja kvalitete raspoznavanja boli, Khan et al. su u [58] predložili piramidalnu podjelu lica na regije. Inicijalno se lice dijeli na dvije polovice, gornju i donju. Iterativno se zatim svaka regija dijeli na četiri nove, vertikalnom i horizontalnom simetralnom podjelom do zadane razine (skale). Na svakoj od regija dohvaćaju se najprije histogrami uniformnih LBP-a, a zatim i histogrami orijentacijskih gradijenata (engl. *histogram of oriented gradients*, HOG). Svi se ovi histogrami na koncu spajaju pri čemu se dobiva vektor značajki. Najbolji rezultati ostvareni su uporabom dvije razine podjele, vektorima značajki od 2814 elementa. Analiza je provedena na cijelom skupu UNBC-McMasters, korištenjem unakrsne provjere k preklopa s različitim vrijednostima parametra k , a kao klasifikatori su korišteni SVM, algoritam k najbližih susjeda (engl. *k nearest neighbour*, k NN), stablo odluke i nasumična suma.

Florea et al. su u [59] rabili histograme topoloških značajki dobivene iz slika lica, a učenje su dodatno potpomogli slikama iz drugih baza, kao što je Cohn-Kanade+ baza izražaja emocija. Promatrano je pet značajnih regija lica te su dobiveni histogrami spajani u konačni vektor značajki. Analiza je provedena izostavljanjem subjekta, ujednačavanjem udjela pojedinih klasa u podacima te uporabom triju klasifikatora i kasne fuzije na razini odluke. Pokazano je da opisani sustav daje dobre rezultate u usporedbi s drugima iz literature, kao i da prijenos učenja potpomaže u procesu raspoznavanja boli. Detaljnija analiza ovog pristupa dana je u [34].

Modeliranjem točaka nastalih AAM-om uporabom splineova tankih ravnina (engl. *thin plate spline*, TPS) prilikom njihova deformiranja tijekom bolnog iskustva, Rathee i Ganotra su u [60] kreirali novi skup značajki. TPS je omogućio praćenje afinih i nelinearnih transformacija među točkama na slikama bez postojanja boli, kao i na onima gdje je bol nazočna. Kako bi se uvećala mogućnost diskriminacije između različitih razina boli, korišteno je preslikavanje vektora značajki u prostor viših dimenzija metodom učenja metrike udaljenosti. Analiza je provedena na umanjenom skupu slika, odnosno birano je najviše 250 slika po pojedinoj PSPI vrijednosti. Prikazani su rezultati dobiveni na temelju analize izostavljanjem pojedinačnog uzorka, kao i analize unakrsnom provjerom k preklopa.

Izravnim određivanjem razina boli bavili su se Irani et al. u [61]. Koristili su prostorno-vremenske značajke kojima su opisane razine energije nastale tijekom stezanja mišića lica.

Smjer i iznos energije određivan je primjenom Gaussovog filtra i Hilbertove transformacije u različitim smjerovima i na različitim razinama. Uočeno je da je za izražavanje boli ključno šest regija na licu, koje su simetrične u odnosu na njegovu vertikalnu simetralu, no regije koje se nalaze na jednoj strani lica drugačije utječu na izraz boli od regija koje se nalaze na drugoj. Regije se dobivaju na temelju točaka lica koje su ranije određene AAM-om, a analiza je provedena na dijelu slika korištenjem izostavljanja subjekta. Navedene su značajke korištene i u [62], gdje je razvijen poseban sustav za izazivanje bolnih stanja i snimanje reakcije subjekata. Osim klasične slike lica, korišteni su još i dubinska slika nastala Kinect kamerom te slika nastala toplinskom kamerom.

Osim opisanih značajki koje se oslanjaju na slike lica i rabe klasične postupke strojnog učenja, postoje i drugi pristupi u literaturi koji se bave raspoznavanjem razina boli. Werner et al. predstavili su bazu bolnih stanja u [33], unutar koje se rabi nekoliko kamera, među kojima i Kinect kamera radi što boljeg zabilježavanja izražavanja boli. Osim slike lica, procijenjen je i položaj glave subjekta, ali i drugi fiziološki parametri poput vodljivosti kože, EEG-a, EKG-a i elektromiograma. Navedena baza postala je javno dostupna istraživačima, a detaljan opis dan je u [36]. Nove metode raspoznavanja uzoraka, preciznije dubinsko učenje, također ostvaruje prve utiske u problemu raspoznavanja razina boli. Pedersen je tako u [63] koristio autoenkoder za izdvajanje značajki i u konačnici SVM za klasifikaciju. Analiza je napravljena izostavljanjem subjekata, ali na dijelu baze, te je pokazano da i postupci izdvajanja značajki zasnovani na dubinskom učenju mogu doprinijeti raspoznavanju boli.

3.3 Postupak izdvajanja značajki zasnovan na shearlet transformaciji

Bol je sama po sebi složen fenomen, a prvi korak u njenu računalnom raspoznavanju predstavlja izdvajanje značajki kojim bi se ona predstavila. Stoga je u ovom je poglavlju opisan predloženi postupak izdvajanja opisnih značajki boli, zasnovan na shearlet transformaciji i podjeli lica na informativne regije. Navedeni postupak ujedno predstavlja prvi očekivani izvorni znanstveni doprinos. U literaturi koja se bavi postupcima izdvajanja značajki moguće je pronaći sugestije da su informacije o boli dostupne u značajkama oblika i značajkama izgleda [48]. Također, sugerirano je i da značajke izgleda u većoj mjeri doprinose ukupnoj mogućnosti raspoznavanja boli [47]. Cilj je iskoristiti poželjna svojstva shearlet transformacije u izoliranju prijelaza u različitim orijentacijama i razinama s ciljem dobivanja informacije o razini boli. Za očekivati je da bi se ovim načinom mogle dobiti informacije o aktivnim dijelovima lica koji prolaze najveće promjene prilikom izražavanja boli. S obzirom da ne sudjeluje cijelo lice u njezinu izražavanju te da postoje razlike i između simetričnih polutki lica kod izražavanja, važno je razmotriti i na koje dijelove lica usmjeriti pozornost za iz-

dvajanje ključnih informacija. Cilj predloženog postupka je na što jednostavnijim regijama dobiti što korisnije informacije o razinama boli, da bi rezultirajući vektor značajki bio čim niže dimenzionalnosti. Iz tog će razloga najprije biti prikazana shearlet transformacija te način njena provođenja. Nakon toga, bit će detaljnije razjašnjeno prikupljanje histograma LBP-a, s obzirom da se dio značajki izdvaja upravo na temelju istih. Potom će biti razmotreni različiti načini podjele lica u informativne regije kakvi se rabe u literaturi koja se bavi sličnim ili istim problemom, kao i način podjele kakav se sugerira unutar predloženog postupka. Na temelju opisanog postupka izdvajanja značajki bit će kreiran podatkovni skup uz pomoć kojega će biti provedena usporedna eksperimentalna analiza za ocjenu valjanosti predloženog postupka izdvajanja značajki.

3.3.1 Shearlet transformacija

U području računalnog vida i obrade signala vrlo je česta potreba za analizom digitalnih slika. Za te potrebe dostupni su brojni alati, među kojima se ističe transformacija valića (engl. *wavelet*). Popularnost je stekla radi mogućnosti višerezolucijske analize koju pruža, povezanosti diskretne i kontinuirane teorije valića (diskretna slijedi izravno iz kontinuirane) te lake računalne implementacije. Ipak, dobrim svojstvima unatoč, prema Kutyniok [64], valići nisu optimalan način za predstavljanje dvodimenzionalnih (i, općenito, višedimenzionalnih) signala. Razlog tome leži u činjenici kako valići mogu predstaviti podatke sa singularitetima u točki (engl. *pointwise singularities*), s obzirom da je riječ o izotropnim objektima. Kod višedimenzionalnih signala singulariteti često ne dolaze u točkama, već su izduženi i nalaze se duž krivulja [65]. Navedeno je posebice važno u svjetlu činjenice da višedimenzionalni signali obiluju singularitetima poput rubova ili granica površina [64]. Da bi se doskočilo navedenom problemu, posljednjih godina predložene su brojni valni oblici s ciljem njegova ublažavanja ili otklanjanja. Neki od njih su contourleti, ridgeleti, bandleti, curveleti, te konačno shearleti. Od navedenih, shearleti su pokazali brojna dobra svojstva i bolje performanse u usporedbi s ostalima, bilo da je riječ o obradi slike [66], klasifikaciji tkiva u zloćudne ili dobroćudne tumore [5] ili raspoznavanju emocija na temelju izraza lica [67].

Da bi se pristupilo analizi izraza lica kakvi su prisutni kod boli, a slični se problemi pojavljuju i primjerice kod analize emocija i sl., potrebno je na slici lica odrediti singularitete duž rubova površina. Drugim riječima, treba odrediti mjesta gdje funkcija, a slika nije ništa drugo doli funkcija, gubi svojstva (poput glatkosti) te mjesta na kojima su najizraženije promjene i prijelazi. Prema Qu et al. [67], shearleti ne samo da imaju dobru lokalizaciju i kompaktnu potporu u frekvencijskoj domeni, već i poželjna svojstva poput anizotropnosti i usmjerenosti. Prema tome, mogu točno i učinkovito predstaviti geometrijske informacije o rubovima i teksturi koje su ključne u raspoznavanju izraza lica. Iz navedenih razloga, ova transformacija odabrana je u predloženom postupku kao osnovni korak za dobivanje

informacija o razinama boli u izrazima lica.

Shearlet transformacija definira se pri tome kao

$$SH(f)(a, s, t) = \langle f, \psi_{a,s,t} \rangle, a \in \mathbb{R}^+, s \in \mathbb{R}, t \in \mathbb{R}, \quad (3.1)$$

gdje je a parametar skaliranja, s parametar smicanja, dok je t operator translacije. Matrica skaliranja za parametar a dana je izrazom (3.2), dok je matrica smicanja (engl. *shearing matrix*) za parametar s dana izrazom (3.3).

$$A_a = \begin{bmatrix} a & 0 \\ 0 & a^{-\frac{1}{2}} \end{bmatrix} \quad (3.2)$$

$$S_s = \begin{bmatrix} 1 & s \\ 0 & 1 \end{bmatrix} \quad (3.3)$$

Shearleti $\psi_{a,s,t}$ nastaju skaliranjem, smicanjem i translacijom osnovne funkcije ψ (uobičajeno funkcija iz skupine dopustivih valića, poput primjerice Meyerova valića) prema izrazu

$$\psi_{a,s,t}(x) = a^{-\frac{3}{4}} \psi(A_a^{-1}) S_s^{-1}(x - t). \quad (3.4)$$

Diskretna shearlet transformacija dobiva se na temelju kontinuirane, diskretizacijom parametara, i izravni je nastavak kontinuirane teorije, što je i jedna od prednosti ove transformacije nad ostalima (za detalje vidi [64, 68]). Postoji nekoliko različitih, javno dostupnih, programskih biblioteka sposobnih obaviti diskretnu shearlet transformaciju, a svaka od njih dobiva koeficijente shearlet transformacije na različit način. Neke od njih su „Local Shearlet Toolbox” [69], „ShearLab” [70] te „Fast finite shearlet transform” [71]. Potonja je odabrana za potrebe računanja shearlet koeficijenata jer je riječ o brzjoj biblioteci koja u potpunosti diskretizira sve parametre potrebne za transformaciju. Osim što se diskretiziraju svi uključeni parametri, uzima se konačan broj diskretnih translacija, a detalji implementacije mogu se pogledati u [71].


Broj razmatranih razina (skala) moguće je odrediti prema veličini slike i to kao $sc = \left\lceil \frac{1}{2} \log_2(\max\{M, N\}) \right\rceil$, gdje M predstavlja broj redaka, a N broj stupaca slike. Isti je izraz korišten i prilikom određivanja broja razina i u sklopu provedene eksperimentalne analize. Odabran je s obzirom na činjenicu da to sugeriraju tvorci diskretne shearlet transformacije u [71], ali i preliminarno eksperimentalno vrednovanje koje je ukazalo na pogodnost navedenog broja razina u usporedbi s drugim odabranim vrijednostima. Diskretizacija parametara skaliranja, smicanja i translacije provodi se prema

$$\begin{aligned}
a_i &= 2^{-2i}, \quad i = 0, \dots, sc - 1, \\
s_{i,j} &= j2^{-i}, \quad -2^i \leq j \leq 2^i, \\
t_{x,y} &= \left(\frac{x}{M}, \frac{y}{N} \right), \quad x = 1, \dots, M, \quad y = 1, \dots, N.
\end{aligned} \tag{3.5}$$


Dodatne detalje vezane uz implementaciju diskretne shearlet transformacije, ali i dokaze, potporu shearletima u frekvencijskoj domeni, računanje shearleta na konusu moguće je dobiti uvidom u [71] te [64]. Korištenjem opisanih shearleta te diskretizacije parametara računaju se koeficijenti za sve skale a te sva smicanja s . Uvedeno je indeksiranje dijelova frekvencijske domene prema slici 3.1, slično kao što je u [71], gdje svaki indeks predstavlja jednu kombinaciju parametara. Za odabrani broj razina, a na primjeru jedne od slika iz baze UNBC McMasters, slikom 3.2 ilustrirani su dobiveni shearlet koeficijenti kao i shearleti za svaki indeks.

3.3.2 Lokalni binarni uzorci

Lokalni binarni uzorci predstavljaju deskriptore slike koji se često rabe u različitim problemima klasifikacije slika, tekstura i drugih uzoraka [58, 47, 72]. Slika LBP-a nastaje primjenom takozvanog LBP operatora, označenog s LBP_n^r , gdje n predstavlja veličinu susjedstva koja se razmatra, dok r predstavlja udaljenost do susjeda koji se uzimaju u obzir, na prozorima izvorne slike. Operator LBP_n^r primjenjuje se tako da se promatra središnji piksel, njegov intenzitet uspoređuje se s intenzitetima piksela u susjedstvu koje je određeno parametrima operatora LBP_n^r . Na mjesta susjeda upisuje se 1, ukoliko je intenzitet susjeda veći od intenziteta središnjeg, odnosno 0, ako je manji ili jednak. Zatim se provodi zamjena cijele



Slika 3.1: Dijeljenje frekvencijske domene po indeksima (različitim kombinacijama parametara)




Slika 3.2: Primjer vizualizacije shearlet koeficijenata i spektra za jednu sliku iz baze UNBC-McMasters

regije određenom vrijednošću, najčešće korištenjem nekog oblika težinske sume, uobičajeno prema


$$L_{x,y} = \sum_{i=0}^n \text{sign}(p_i - p_c) \cdot 2^i, \quad \text{sign}(e) = \begin{cases} 1, & \text{ako } e \geq 0 \\ 0, & e < 0, \end{cases} \quad (3.6)$$

gdje je $L_{x,y}$ lokalni binarni uzorak za trenutno razmatrani, središnji piksel $p_c = \mathbb{I}(x, y)$, a p_i trenutno razmatrani susjedni piksel. Veličina susjedstva (prozora) može varirati, kao i udaljenost na kojoj se promatraju susjedi, a osnovni je operator LBP_8^1 , koji promatra 8 susjeda oko centralnog, na udaljenosti od jednog piksela, kako je prikazano slikom 3.3.




Slika 3.3: Način rada LBP_8^1 operatora

Kod većeg susjedstva ili druge udaljenosti do susjeda moguće je da promatrana točka nije konkretan piksel, a u tom se slučaju pribjegava interpolaciji. Neka moguća susjedstva s različitim promatranim udaljenostima prikazana su slikom 3.4.



Slika 3.4: Različiti LBP operatori prema veličini susjedstva i polumjeru razmatranja, s lijeva na desno: LBP_4^1 , LBP_8^1 , LBP_8^2 , LBP_{16}^2

S obzirom da su LBP-i pokazali dobra svojstva za različite klasifikacijske probleme, nastala su brojna njihova unaprjeđenja. Jedno takvo unaprjeđenje, uniformni LBP, $uLBP$, predstavljen u [73], korišten je i u ovom radu. Naime, uočeno je da svi LBP-i nisu jednako važni za definiranje uzoraka. Točnije, ako se promatraju samo uzorci koji nemaju više od dvije kontinuirane regije, postiže se uobičajeno bolji rezultat prepoznavanja te neosjetljivost na rotaciju. Kada se govori o kontinuiranim regijama misli se na broj prijelaza $1 \rightarrow 0$ i $0 \rightarrow 1$ unutar pojedinog binarnog uzorka. Takvi se uzorci nazivaju uniformnima i prikazani su slikom 3.5. Vektori značajki koji se dobivaju na temelju LBP-a uobičajeno su histogrami njihovih vrijednosti. Također, dobivanje LBP-a se uobičajeno provodi na manjim regijama slike, nakon čega se histogrami ovih vrijednosti spajaju (lijepe jedan na drugoga) i stvaraju se konačni vektori značajki. Podjela cjelokupne slike na regije obavlja se tako da se uzimaju nepreklapajuće regije čiji je broj proizvoljan i ovisi o složenosti problema, kao i o svojstvima koje problem ispoljava.




Slika 3.5: Uniformni LBP

3.3.3 Informativne regije slike lica s gledišta bolnih stanja

Kod raspoznavanja emocija, afektivnih stanja te bolnih stanja na temelju izraza lica, uobičajeno je, ali ne i neophodno, da se cjelokupno lice podijeli na više regija. Svaka od regija tada se može razmatrati zasebno ili se informacije dobivene na temelju pojedinih regija mogu

objediniti. U ovom je radu korišten potonji pristup, koji je rabljen i drugdje u literaturi, poput primjerice u [59, 58, 47]. Podjela lica na regije uvelike utječe na kvalitetu klasifikacije jer nisu sve regije jednako uključene u izražajni proces [8]. Međutim, problem nastaje pri odlučivanju o načinu odabira regija, s obzirom da povećan broj regija ima nepovoljan utjecaj na dimenzionalnost problema. Također, suviše male regije moguće će dovesti do šuma u podacima na temelju kojih će se obavljati klasifikacija. Slikom 3.6 ilustrirani su neki od pristupa dostupnih u literaturi. Još vrlo rano uočeno je koje su mišićne skupine uključene u izražavanje boli pa se regijama pokušalo obuhvatiti iste. Tako su Kalatwang et al. podijelili sliku lica na 81 nepreklapajuću regiju [47]. Khan et al. primijenili su piramidalnu podjelu lica, gdje su nakon inicijalne podjele na gornji i donji dio dijelili regije na četiri nove. Ovaj su postupak ponavljali i došli do zaključka kako se najbolji rezultati ostvaruju značajkama dobivenima na temelju regija koje su rezultat dvaju ponavljanja podjele [58]. Detaljnija podjela lica na regije koja se oslanja na ključne točke lica dobivene AAM-om korištena je u [61]. Naime, izdvojene su samo malene regije ograničene mnogokutima definiranim točkama lica koje omeđuju ključne mišićne skupine, to jest mišići oko očiju, usta, nosa i slično. Problem ovakvog pristupa je što ove točke moraju biti unaprijed poznate za promatranog subjekta ili se moraju pronaći na njegovu licu, što iziskuje dodatne računalne resurse. Drugačiji pristup, praćenje lica uporabom Viola-Jones algoritma predstavljen je u [59]. Na pronađenom licu zatim su pronađene 4 regije koje se djelomično preklapaju, a pokrivaju ključne informativne dijelove lica. Ovaj pristup također, nakon otkrivanja lica, na slici zahtijeva dodatno ulaganje resursa u pronalazak regija korištenjem Haarovih kaskada. Iako se radi o relativno brzom proceduri, moguće je da zbog različitih uvjeta osvjetljenja ili drugih okolnosti neka od tih regija ne bude pronađena.



Slika 3.6: Primjeri nekih od podjela lica na informativne regije, (a) podjela prema [59], (b) podjela prema [58], (c) podjela prema [47], (d) podjela prema [61]

U ovom radu predlaže se podjela slike lica na tri regije. Svaka od regija sadrži informacije o različitim akcijskim jedinicama, a riječ je o regiji očiju, regiji nosa i regiji usta. Sa svakom od regija se zatim može raditi izravno, odnosno bez potrebe za daljnjim koracima predobrade kako bi se pristupilo izdvajanju značajki. Pri tome treba uzeti u obzir kako značajke koje se izdvajaju iz ovakvih regija moraju biti poprilično robusne, s obzirom da se ne provodi

detaljna analiza scene te da među regijama na slikama različitih subjekata mogu postojati i određena odstupanja. Glavna prednost ovakve podjele jest njena jednostavnost, malen broj regija koji će u konačnici rezultirati vektorima značajki relativno niskih dimenzionalnosti uz dobre performanse, što će biti pokazano u kasnijoj analizi. Podjela lica na informativne regije prikazana je slikom 3.7.



Slika 3.7: Predloženi primjer podjele slike lica

3.3.4 Izdvajanje opisnih značajki predloženim postupkom

S ciljem izdvajanja opisnih značajki iz slike lica, najprije se na cjelokupnoj slici provodi shearlet transformacija prema pristupu danom u [71], a detaljnije opisanom u potpoglavlju 3.3.1. S obzirom na dimenzije ulazne slike, broj odabranih razina $sc = 3$, što rezultira matricom SH , dimenzija $M \times N \times 29$. Nakon provođenja shearlet transformacije izdvajaju se dvije skupine značajki, prva skupina zasnovana na histogramima LBP-a, a druga na histogramima apsolutnih vrijednosti koeficijenata shearlet transformacije. Koraci predloženog postupka na visokoj su razini prikazani Algoritmom 1.

Algoritam 1 Predloženi postupak izdvajanja značajki

```

sc := 3; bin := 8; operator :=  $uLBP_8^2$ ;
 $\mathbb{I} \leftarrow$  učitaj_sliku(); [M, N] := dimenzije( $\mathbb{I}$ );
 $\mathbb{I} \leftarrow$  ukloni_boju( $\mathbb{I}$ );
 $ROI \leftarrow$  nadji_bolno_lice( $\mathbb{I}$ );
 $ROI \leftarrow$  ukloni_rotaciju( $ROI$ );
 $ROI \leftarrow$  skaliraj_sliku( $ROI$ );
 $SH \leftarrow$  shearlet_transformacija( $ROI, sc$ );
for i := 1  $\cdots$  M, j := 1  $\cdots$  N do
  for z := 5  $\cdots$  12 do
     $ASC_{i,j} = ASC_{i,j} + |SH_{i,j,z}|$ ;
  end for
end for
//  $ASC[a:b,c:d]$  označava pod-matricu matrice  $ASC$ , uzimaju se retci a:b i stupci c:d
 $X_{lbp} = Lbp(ASC[1 : \frac{M}{3}, 1 : N], operator) \cup Lbp(ASC[\frac{M}{3} : \frac{2M}{3}, 1 : N], operator) \cup Lbp(ASC[\frac{2M}{3} : M, 1 : N], operator)$ 
for z = 1  $\cdots$  z = 12 do
   $X_{hist} = X_{hist} \cup Hist(SH[1 : \frac{M}{3}, 1 : N, z], bin) \cup Hist(SH[\frac{M}{3} : \frac{2M}{3}, 1 : N, z], bin) \cup Hist(SH[\frac{2M}{3} : M, 1 : N, z], bin)$ ;
end for
 $X = X_{lbp} \cup X_{hist}$ ;


```

Prva skupina značajki

Prva skupina značajki dobiva se na temelju koeficijenata shearlet transformacije za indekse $z = 5, \dots, 12$ i to tako da se na temelju navedenih matrica kreira nova matrica kao zbroj apsolutnih vrijednosti svih shearlet koeficijenata na odgovarajućim lokacijama, prema

$$ASC_{i,j} = \sum_{z=5}^{12} |SH_{i,j,z}|, \quad i = 1, \dots, M, \quad j = 1, \dots, N, \quad (3.7)$$

gdje je SH matrica shearlet koeficijenata dimenzija $M \times N \times 29$, a z razmatrani indeks shearlet transformacije, odnosno konkretna kombinacija diskretnih parametara. Matrica ASC dijeli se potom na tri regije: regiju očiju, regiju nosa i regiju usta. Primjer jedne ovako dobivene matrice na temelju jedne slike iz baze UNBC-McMasters, uz podjelu na regije, dan je slikom 3.8. Na svakoj od regija primjenjuje se operator uniformnih lokalnih binarnih uzoraka $uLBP_8^2$ da bi se dobila LBP slika. S obzirom da je riječ o uniformnim LBP-ima, računa se histogram s 59 stupaca za danu regiju. Histogrami se tada nadovezuju jedan na drugi, što je uobičajeno i u literaturi. Opisani postupak rezultirat će s ukupno 59 vrijednosti za svaku regiju, odnosno 177 značajki ukupno za ovu skupinu.



Slika 3.8: Primjer matrice ASC u prilagođenom prikazu

Druga skupina značajki

Značajke druge skupine dobivaju se na temelju matrice shearlet koeficijenata SH za $z = 1, \dots, 13$. Koeficijenti na posljednjoj razmatranoj razini ($z > 13$) nisu uzimani u obzir jer sadrže fine detalje koji, prema provedenoj preliminarnoj eksperimentalnoj analizi, ne pridonose kvaliteti rezultata, a uvelike doprinose uvećanju vektora značajki. Svaka razmatrana matrica shearlet koeficijenata dijeli se na tri regije, kao i u prethodnom slučaju, a uzimaju se apsolutne vrijednosti koeficijenata. Na temelju dobivenih apsolutnih vrijednosti koeficijenata

računa se normalizirani histogram s osam stupaca. Svi izračunati histogrami nadovezuju se jedan na drugi. Ovaj postupak rezultira s $3 \cdot 8$ značajki po matrici shearlet koeficijenata, odnosno ukupno 312 značajki. Konačni vektor značajki sastoji se od vektora značajki prve skupine na koji se nadovezuje vektor značajki druge skupine pri čemu je ukupna dimenzionalnost 489. Ovo je i dalje relativno visok broj značajki, no u usporedbi s pristupima dostupnima u literaturi, dimenzionalnost je ipak značajno niža (primjerice, postupak LBP koristi $9 \cdot 9 \cdot 59 = 4779$ značajki).

3.4 Ekperimentalna analiza i rezultati

S ciljem utvrđivanja prikladnosti predloženog postupka za izdvajanje opisnih značajki boli u sklopu ostvarivanja prvog izvornog znanstvenog doprinosa, provedena je usporedna ekperimentalna analiza. Uporabom standardnog skupa podataka iz literature dobivenog tijekom kliničkog pregleda, baze UNBC-McMasters slika bolnih izraza lica, analizirana je mogućnost prepoznavanja različitih razina boli na temelju podataka dobivenih predloženim pristupom te na temelju nekoliko pristupa iz literature. U tu svrhu upotrijebljeni su različiti klasiifikacijski modeli te različiti načini vrednovanja. Priprema podataka, postavke provedenog eksperimenta, kao i rezultati predstavljeni su u nastavku.

3.4.1 Priprema podataka


Prvi korak koji je prethodio izdvajanju značajki bio je prilagodba ulaznih slika iz UNBC-McMasters baze. Slike su prikupljane u stvarnom, kliničkom okruženju pod paskom liječnika, a uporabom videokamere. Svaki okvir video zapisa predstavlja jednu instancu, odnosno sliku (uzorak), koja osim lica trenutnog pacijenta sadrži i dio pozadine prostorije u kojoj je prikupljanje podataka obavljeno. Stoga je bilo potrebno izdvojiti lice subjekta od ostatka scene. U tu svrhu moguće je koristiti primjerice Viola-Jones algoritam za pronalazak lica uporabom Haarovih kaskada kako je predloženo u [58]. S obzirom da je moguće da lice ne bude pronađeno, a i da bi se osiguralo da svi postupci rade isključivo s licem, za potrebe ekperimentalne analize, izdvajanje lica oslanja se na AAM točke. Njih su autori baze pružili uz svaku od slika, a upravo one označavaju točke interesa. Uporabom programskog okvira OpenCV [74] i korištenjem programskog jezika C# ostvareno je programsko rješenje koje je ponajprije iz scene izdvojilo samo sliku lica. Ova je slika zatim pretvorena u sliku s 256 razina sive boje, s obzirom da takva slika značajno olakšava obradu, a zadržava sve važne osobine izgleda lica nužne za otkrivanje razina boli. Slike lica su zatim rotirane kako bi se uklonila razlika među licima nastala rotacijom glave prilikom zakretanja i pomicanja bolnog ramena, a nakon toga skalirane da bi se uklonile razlike između različitih veličina lica na

slici. Prikaz ovih transformacija, od izvorne slike pa do slika primijenjenih u analizi dan je slikom 3.9. Ovako obrađene slike pohranjene su zajedno s indeksom boli definiranim prema PSPI indeksu.



Slika 3.9: Koraci u predobradi izvornih slika

Izdvajanje navedenih značajki obavljeno je također uporabom programskog okvira OpenCV i programskog rješenja ostvarenog u programskom jeziku C#. Ugrađen je predloženi postupak zasnovan na shearlet transformaciji i nekoliko postupaka iz literature. Za svaku sliku izdvojeni su vektori značajki prema odabranom postupku, svakom je vektoru dodijeljena oznaka klase i to tako da je $PSPI = 0$ označavao stanje bez boli, $PSPI = 1,2$ stanje sa slabom boli, a $PSPI \geq 3$ stanje snažne boli. Prikaz različitih razina boli dan je slikom 3.10. Za svakog pojedinog subjekta kreirana je datoteka u atributno-relacijskom datotečnom formatu (engl. *attribute-relation file format*, ARFF). Riječ je o standardnom formatu zapisa, odnosno tekstualnoj ASCII datoteci koja opisuje niz instanci koje dijele skup atributa. Ovo je napravljeno za sve postupke uključene u eksperimentalnu analizu, koja je provedena uporabom alata za strojno učenje Weka [75]. Naime, unutar vlastitog programskog rješenja korištene su komponente koje dolaze kao dio alata Weka.



Slika 3.10: Različite razine boli na primjerima slika iz baze UNBC-McMasters

3.4.2 Postavke eksperimenta

Eksperimentalna analiza podijeljena je u dva glavna dijela: dio u kojem su rezultati klasifikacije dobiveni učenjem na temelju cjelokupnog skupa podataka, izuzev subjekta koji je u danoj iteraciji izostavljen za testiranje i dio u kojem su rezultati dobiveni na temelju učenja na dijelu skupa. U potonjem slučaju, nakon učitavanja podataka za sve subjekte, osim testnog, provedeno je poduzorkovanje (engl. *subsampling*) bez zamjene kako bi se smanjio broj instanci i time ubrzalo učenje, slično kao u pristupu korištenom u [46]. U konačnici, ovaj je korak za učenje rabio 15% od broja instanci cjelokupnog podatkovnog skupa. Eksperimentalna analiza provedena je zatim korištenjem različitih klasifikacijskih postupaka dostupnih kao dio Weka programskog alata, odabranih tako da postavke parametara ne igraju veliku ulogu prilikom izgradnje klasifikacijskog modela ili je parametre bilo moguće lako odrediti.

Kratak opis klasifikacijskih postupaka korištenih u usporedbi

- **Naivni Bayesov klasifikator**

Naivni Bayesov klasifikator jednostavan je vjerojatnosni klasifikator čiji naziv proizlazi iz činjenice da pretpostavlja međusobnu neovisnost svih varijabli, odnosno značajki. Iako ova pretpostavka često ne vrijedi, usporedne analize pokazuju da ovaj klasifikator iskazuje performanse usporedive s puno složenijim postupcima klasifikacije, a prema [76] iskazuje i visoku preciznost i brzinu kada se primjenjuje na velikim podatkovnim skupovima. Zasnovan je na Bayesovu teoremu, a parametri modela određuju se temeljem podataka dostupnih u skupu za treniranje tako da se računaju srednje vrijednosti i standardno odstupanje za svaku varijablu i za svaku klasu. Konačna se pripadnost klasi određuje temeljem pravila maksimalne a posteriori vjerojatnosti. Za više detalja može se pogledati [77].

- **Bayesova mreža**

Bayesove mreže ili mreže uvjerenja (engl. *belief networks*) su usmjereni aciklički grafovi, čiji su čvorovi varijable, a bridovi predstavljaju uvjetne vjerojatnosti. Svi su čvorovi povezani sa skupom uvjetnih vjerojatnosti $P(x_i|A_i)$, gdje je x_i varijabla povezana sa specifičnim čvorom, a A_i skup njegovih roditelja na grafu [9]. Ovakva mreža uči u dvije faze. Najprije se određuje topologija mreže na temelju skupa podataka za treniranje, a zatim se opet na temelju uzoraka za učenje određuju vjerojatnosti. Detaljniji uvid u način rada ovog klasifikatora moguće je dobiti u [9, 78].

- **Algoritam k najbližih susjeda**

Algoritam k najbližih susjeda je unaprijeđena inačica pravila najbližeg susjeda [79], gdje se pri klasifikaciji novog uzorka nepoznate klase ona određuje na temelju njemu k

najbližih uzoraka u skupu \mathcal{S} prema nekoj mjeri udaljenosti. Uobičajeno se u tu svrhu koristi Euklidska udaljenost. Parametar k najčešće se određuje eksperimentalno, korištenjem unakrsne provjere korištenjem k preklopa. Ovaj algoritam spada u skupinu takozvanih „lijenih” algoritama strojnog učenja. Prednosti algoritma k NN su njegova jednostavnost, jasnoća postupka kojim određuje klasu, jako dobri rezultati u odnosu na kompleksnost postupka te izostanak potrebe za treniranjem. Međutim, sam postupak klasifikacije je relativno dugotrajan te je osjetljiv na lokalnu strukturu podataka. Neki od ovih nedostataka manje su ili više uspješno ublaženi, a primjeri unaprijeđenih inačica ovog klasifikatora, kao i detaljniji uvid u njegov rad prikazani su u [80].

- **Nasumična šuma**

Nasumična šuma ili nasumična šuma odluke je klasifikator koji rabi učenje zasnovano na ansamblima. Kreira se niz stabala odluke [81] tijekom procesa učenja te se na temelju objedinjavanja njihovih odluka dolazi do konačne odluke o klasi novog uzorka. Svako stablo odluke ovisi o nasumičnom uzorkovanju značajki iz vektora značajki na temelju kojeg se izgrađuje, a nakon izgradnje većeg broja stabala, odluke im se objedinjuju. Ovaj klasifikator otporan je na šum u podacima, pokazuju dobre performanse prilikom klasifikacije, no ovisi o snazi pojedinih stabala. Detaljniji uvid u način rada ovog klasifikatora dan je u [82].

Kao što je ranije opisano, dostupni su brojni postupci u svrhu izdvajanja značajki za određivanje razina ili postojanje boli na osnovu slika lica. Da bi se provjerila uspješnost predloženog postupka izdvajanja značajki zasnovanog na podjeli lica na informativne regije te uporabi koeficijentata shearlet transformacije, provedena je usporedba s nekoliko pristupa dostupnih u literaturi. Za potrebe analize odabrani su pristupi opisani u 3.2, i to onaj predstavljen u [58], označen s PHOG, pristupi predstavljeni u [48] označeni s AAM, odnosno DCT, a koji su kasnije primijenjeni u [47]. Uz navedene, u usporedbu je uključen i treći pristup korišten u [47] zasnovan na LBP te jednako tako označen u ovoj usporedbi. Predloženi pristup, opisan u 3.3.4, nosi oznaku SHEAR.

3.4.3 Ponašanje predloženog postupka prilikom učenja na svim dostupnim podacima

S ciljem usporedbe performanse različitih postupaka za izdvajanje značajki, provedena je analiza na svim dostupnim podacima iz baze UNBC-McMasters. S obzirom na činjenicu da baza sadrži velik broj podataka, kao klasifikator za ove potrebe odabrana je Bayesova mreža. Također, ovaj izbor uvjetovan je njenom brzinom i performansama pri klasifikaciji te dobrim ponašanjem kod velikih skupova podataka. Prema ranije opisanoj proceduri, provedeno je 25 odvojenih eksperimenata, gdje je u danom eksperimentu jedan subjekt korišten za potrebe

testiranja kvalitete klasifikacije, dok je klasifikacijski model oblikovan na svim slikama svih preostalih subjekata. Tablicom 3.1 dani su rezultati klasifikacije za sve subjekte u obliku težinske mjere AUC. Prema [83], riječ je o mjeri koju se sugerira koristiti kod nebalansiranih podatkovnih skupova, a za razliku od mjera proizašlih iz CM-a, koje razmatraju samo jednu točku na krivulji ROC [jednu vrijednost praga (engl. *threshold*)], analiza ROC krivulje, a posljedično i mjera AUC čini to za čitav niz različitih vrijednosti praga [84]. Iz navedenih razloga odabrana je kao primarni pokazatelj rezultata. U tablici su također prikazani prosječni rezultati na svim subjektima, kao i broj subjekata za koji je svaki od pristupa ponudio najbolje rezultate, odnosno broj pobjeda koje je ostvario svaki od pristupa.


Tablica 3.1: Rezultati klasifikacije u obliku težinske mjere AUC za sve subjekte učenjem na svim podacima uz korištenje Bayesove mreže

#	Br. Instanci	AAM	DCT	LBP	PHOG	SHEAR
1	2134	0.6228	0.7333	0.7116	0.8300	0.7968
2	1120	0.2766	0.3193	0.4161	0.6319	0.8173
3	1608	0.3895	0.3251	0.9505	0.9557	0.9043
4	894	0.6325	0.3203	0.6650	0.5848	0.6525
5	2752	0.3693	0.6993	0.3900	0.5265	0.4580
6	2609	0.7352	0.6956	0.7647	0.6824	0.8409
7	773	0.4365	0.5170	0.7017	0.7198	0.7562
8	1612	0.5944	0.4775	0.6766	0.6336	0.7406
9	2474	0.5010	0.5590	0.7535	0.7529	0.7127
10	2038	0.4133	0.4886	0.6252	0.6330	0.7237
11	1502	0.5273	0.6757	0.6156	0.6697	0.7525
12	809	0.7888	0.7040	0.8454	0.7763	0.6396
13	2361	0.6325	0.7219	0.8680	0.8630	0.7987
14	3360	0.2448	0.2781	0.3444	0.6870	0.6190
15	2819	0.0000	0.0000	0.0000	0.0000	0.0000
16	3592	0.5242	0.5874	0.7419	0.7517	0.7720
17	2798	0.4125	0.5609	0.4754	0.4837	0.9393
18	2041	0.6208	0.5282	0.5453	0.5536	0.8150
19	2908	0.7055	0.7970	0.7296	0.7637	0.8109
20	1905	0.3136	0.7978	0.6630	0.6758	0.9117
21	1327	0.5886	0.7073	0.7739	0.8355	0.8640
22	1566	0.8559	0.8814	0.8290	0.8626	0.6569
23	518	0.4371	0.5857	0.5570	0.5826	0.4136
24	1183	0.4599	0.5389	0.5810	0.6320	0.8207
25	1695	0.7228	0.4170	0.7475	0.7883	0.6507
sr.vr.		0.5122	0.5566	0.6389	0.6750	0.7147
std.dev.		0.1887	0.1966	0.1971	0.1786	0.1917
pobjeda		0	3	4	4	13

Iz tablice 3.1 vidljivo je da predloženi pristup za većinu subjekata ostvaruje najbolje rezultate u smislu navedene mjere kvalitete te kako je ponudio najbolje rezultate u prosjeku. Navedeno sugerira da predloženi postupak može dobro predstaviti razine boli na temelju slika izraza lica. U pogledu kvalitete, najbliži predloženom postupku su dva postupka iz literature koji rezultiraju vektorima značajki najviše dimenzionalnosti, a to su postupci LBP i PHOG. Zanimljivo je primijetiti relativno visoku standardnu devijaciju rezultata za svaki od postupaka korištenih u usporedbi. U tom smislu, važno je napomenuti da ona proizlazi iz činjenice da su lica subjekata vrlo različita prema dobi, spolu, rasi kao i iz drugih specifičnih razloga, poput nošenja naočala. Primjerice, za subjekta pod oznakom 5, svi su postupci ponudili relativno loše performanse, čak ispod slučajnog pogađanja. To se kod konkretnog

subjekta može pripisati nošenju naočala, koje značajno mijenja izgled lica te utječe na mogućnost otkrivanja informacija o bolnom stanju, poglavito kod pristupa koji se oslanjaju na izgled, odnosno na prijelaze i nabore na koži. Ovakvi bi se problemi mogli otkloniti u ranijem stadiju procedure raspoznavanja boli, odnosno skidanjem naočala prilikom prikupljanja podataka. Također, prilikom zakretanja bolnog ramena dolazilo je i do pomaka glave, odnosno lica, što u pojedinim slučajevima može uzrokovati lošiju mogućnost raspoznavanja. Uz navedeno, značajne oscilacije u rezultatima očekivane su s obzirom da se analiza provodi na subjektu čije lice klasifikator nije imao priliku ranije vidjeti. Uočljiv je također i rezultat kod kojega je površina ispod krivulje jednaka nuli za sve pristupe. Riječ je o subjektu za kojeg u bazi postoje samo slike bez boli, a s obzirom da alat korišten za testiranje i analizu u takvim slučajevima kao rezultat daje nulu, ovaj subjekt ostavljen je u tablici radi cjelovitosti rezultata.

Da bi se dobio detaljniji uvid u razdiobu ostvarenih rezultata, rezultati predstavljeni tablicom 3.1 prikazani su dijagramima pravokutnika (engl. *box and whisker plots*) na slici 3.11. Ovi dijagrami daju informaciju o najboljem ostvarenom rezultatu (gornji brk), najlošijem rezultatu (donji brk) te prvom, drugom i trećem kvartilu. Kvartili dijele podatke u četiri skupine, gdje je četvrtina podataka manja ili jednaka prvom kvartilu, drugi kvartil je medijan, dok je tri četvrtine podataka manje ili jednako trećem kvartilu. Uz navedeno, dijagrami prikazuju sumnjive vrijednosti (engl. *outlier*). Iz prikazanih se dijagrama lakše mogu uočiti razlike među postupcima uključenim u analizu, a uz to su iskazani drugačiji pokazatelji u odnosu na one dane tablicom 3.1. Uočljiva je pojava sumnjivih vrijednosti kod svakog postupka, a riječ je upravo o subjektu za kojeg je težinska mjera AUC bila jednaka nuli. U prvom je redu važno zamijetiti medijan, koji je za predloženi postupak osjetno viši nego



Slika 3.11: Težinska mjera AUC za postupke izdvajanja značajki uključene u eksperimentalnu analizu

kod ostalih postupaka uključenih u analizu, a to navodi na zaključak da vektori značajki dobiveni uporabom predloženog postupka dovode do boljeg raspoznavanja razina boli. Iako su neki od postupaka (LBP i PHOG) uspjeli postići veću kvalitetu prilikom najboljeg ostvarenog rezultata, kod predloženog pristupa cijela gornja polovina ostvarenih rezultata nalazi se u rasponu najbolje četvrtine konkurentskih postupaka iz literature. Ta činjenica stavlja naglasak na opetovano dostizanje rezultata bolje kvalitete prilikom uporabe predloženog postupka.

Prosječna kvaliteta rezultata na svim subjektima u vidu različitih mjera kvalitete predstavljena je tablicom 3.2. Može se primijetiti kako je predloženi pristup i prema drugim mjerama kvalitete usporediv s ostalim pristupima primijenjenim u eksperimentalnoj analizi. Razmatrajući preciznost klasifikacije (Acc), postoje pristupi koji ga nadmašuju, no ova mjera kvalitete može biti zavaravajuća, kao što je i opisano u poglavlju 2.3.4. Stoga je važno razmotriti prvenstveno težinsku mjeru AUC koja sugerira da predloženi pristup nudi najbolje ponašanje za klasifikaciju razina boli između uspoređenih pristupa. Također, nužno se podsjetiti da predloženi pristup prikazane rezultate ostvaruje uporabom značajno manjeg broja značajki u odnosu na dva, prema ostvarenim performansama, glavna konkurenta u usporedbi. Radi se o gotovo deset puta manje značajki od postupka LBP i gotovo šest puta manje značajki od postupka PHOG.

Tablica 3.2: Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na svim podacima korištenjem Bayesove mreže

Postupak Mjera	AAM sr.vr. \pm std.	DCT sr.vr. \pm std.	LBP sr.vr. \pm std.	PHOG sr.vr. \pm std.	SHEAR sr.vr. \pm std.
Acc	0.5969 \pm 0.1667	0.7438 \pm 0.1737	0.7487 \pm 0.1475	0.7041 \pm 0.1963	0.7233 \pm 0.1583
AUC	0.5122 \pm 0.1887	0.5566 \pm 0.1966	0.6389 \pm 0.1971	0.6750 \pm 0.1786	0.7147 \pm 0.1917
FMSr	0.6370 \pm 0.1463	0.7198 \pm 0.2020	0.7542 \pm 0.1364	0.7097 \pm 0.1952	0.7369 \pm 0.1502
Pre	0.7543 \pm 0.1495	0.7629 \pm 0.1545	0.8045 \pm 0.1203	0.8121 \pm 0.1130	0.8148 \pm 0.1302
Rec	0.5969 \pm 0.1667	0.7438 \pm 0.1737	0.7487 \pm 0.1475	0.7041 \pm 0.1963	0.7233 \pm 0.1583

Nadalje, s obzirom na različit broj instanci dostupan za svakog od subjekata, koji varira od 518 do 3592, što je prikazano tablicom 3.1, zanimljivo je promotriti rezultate dane tablicom 3.3. U njoj su dani prosječni rezultati po instanci, odnosno uzet je u obzir broj slika pojedinog subjekta prilikom računanja prosječnih rezultata. Iz prikazanih rezultata uočljivo je da u prosjeku po svim instancama predloženi pristup u odnosu na ostale iz usporedbe iskazuje

Tablica 3.3: Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na svim podacima korištenjem Bayesove mreže

Postupak Mjera	AAM sr.vr.	DCT sr.vr.	LBP sr.vr.	PHOG sr.vr.	SHEAR sr.vr.
Acc	0.5911	0.7569	0.7472	0.7098	0.7587
AUC	0.4950	0.5538	0.6162	0.6615	0.7099
FMSr	0.6362	0.7361	0.7560	0.7209	0.7649
Pre	0.7623	0.7742	0.8074	0.8159	0.8226
Rec	0.5912	0.7568	0.7472	0.7098	0.7587

najbolje ponašanje. Iako promatrano po subjektima s gledišta težinske mjere F1 LBP pokazuje bolji rezultat, gledajući po instancama to nije slučaj. Predloženi pristup je prema tome bio bolji za subjekte za koje je dostupno više instanci. Kvaliteta u smislu težinske mjere AUC zadržana je i kod ovog načina vrednovanja te ide u korist predloženog pristupa.

Dodatan detalj vezan uz kvalitetu klasifikacije može se uočiti iz tablice 3.4. Naime, danom tablicom prikazana je mjera AUC za svaku klasu, odnosno uzet je prosjek po subjektima, ali tako da se vidi ponašanje po pojedinoj klasi. Vidljivo je da za stanje bez boli predloženi pristup nudi najbolju kvalitetu. Isto je vidljivo i za slabu razinu boli, no tu su rezultati za sve postupke iz usporedbe relativno niski. Za neke od njih čak je vidljivo da razina kvalitete pada ispod razine slučajnog pogađanja. Ovaj fenomen proizlazi iz samih slika koje su prikupljene i koje se analiziraju, jer je često moguće pronaći prijedloge dodatnih koraka predobrade slike lica i svođenje lica na kanonički prikaz. Ipak, svi pristupi u usporedbi djelovali su u jednakim uvjetima i na jednakim podacima. Tako je moguće pretpostaviti da bilo kakva dodatna predobrada može pridonijeti kvaliteti konačnog rezultata za svakoga od korištenih postupaka. Također, važno je uzeti u obzir da je promjena na licu između stanja bez boli i stanja niske razine boli izuzetno mala. To granicu odluke među ovim klasama čini složenom i dovodi do lošijeg raspoznavanja konkretne razine boli. Kod najviše razine boli uočljivo je da predloženi pristup nije pokazao najbolje performanse, već je metoda PHOG nešto bolja u tom pogledu. Ipak, razlika u korist pristupa PHOG nije velika. Uzevši u obzir ranije opisane ciljeve prvog predloženog izvornog znanstvenog doprinosa (što manji broj značajki i što višu kvalitetu klasifikacije), ostvarenu prednost prema prikazanim rezultatima, kao i važnu činjenicu da predloženi pristup koristi vektore značajki gotovo šest puta niže dimenzionalnosti, svakako valja razmotriti predloženi postupak prilikom rješavanja problema raspoznavanja razina boli.

Tablica 3.4: Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na svim podacima korištenjem Bayesove mreže

Klasa Mjera	Bez boli sr.vr. \pm std.	Slaba bol sr.vr. \pm std.	Jaka bol sr.vr. \pm std.
AAM	0.5366 \pm 0.1700	0.4648 \pm 0.1739	0.6631 \pm 0.2463
DCT	0.5852 \pm 0.1660	0.4641 \pm 0.1568	0.7226 \pm 0.1604
LBP	0.6637 \pm 0.1587	0.5282 \pm 0.1659	0.8311 \pm 0.1542
PHOG	0.7009 \pm 0.1252	0.5698 \pm 0.1458	0.8634 \pm 0.1148
SHEAR	0.7531 \pm 0.1294	0.6101 \pm 0.1767	0.8482 \pm 0.1038

3.4.4 Ponašanje predloženog postupka pri učenju na dijelu podataka

S ciljem daljnje analize performansi predloženog pristupa dohvaćanja značajki, provedena je dodatna analiza korištenjem nekoliko dodatnih klasifikatora često korištenih u literaturi, a opisanih u potpoglavlju 3.4.2. S obzirom na složenost problema i velik broj instanci,


kod ekperimentalne analize na drugim klasifikatorima provedena je redukcija podatkovnog skupa na sličan način kao u [46]. Naime, ponovno je provedena analiza izostavljanjem subjekta. Međutim da bi se olakšao postupak učenja, smanjen je broj instanci koje su korištene za oblikovanje klasifikacijskog modela. Najprije su za tu potrebu izdvojene sve instance subjekta za testiranje da bi se osiguralo da klasifikator ne uči na testnom subjektu, a zatim je provedeno nasumično poduzorkovanje kojim je zadržano 15% instanci na temelju kojih je oblikovan klasifikacijski model. Nakon oblikovanja modela, test je proveden na svim instancama izostavljenog subjekta. Ove radnje ponovljene su za sve subjekte. Klasifikatori odabrani za analizu uključivali su ponovno Bayesovu mrežu, s ciljem dobivanja uvida u odnos između učenja na svim podacima i dijelu podataka, te Naivni Bayesov klasifikator, algoritam k NN i nasumičnu šumu.

Prvenstveno su rezultati predstavljeni kroz težinsku mjeru AUC. Ponovno je u tu svrhu dan uvid u razdiobu rezultata klasifikacije slikom 3.12. Njome su, kao i u ranijem slučaju u kojem se koristio cijeli skup, dani dijagrami pravokutnika za sve ostvarene rezultate u smislu težinske mjere AUC te za svaki od postupaka izdvajanja značajki i za svaki pojedini klasifikator.

Iako se na prvi pogled čini da niti jedan od pristupa ne ostvaruje izrazitu prednost, predloženi postupak u smislu medijana težinske mjere AUC nudi ipak nešto bolje rezultate u odnosu na ostale postupke u usporedbi. Naime, ako se promotri ponašanje po različitim klasifikatorima, uočava se da predloženi postupak nudi najkonzistentnije rezultate. Za ostale postupke koji su mu bliski po kvaliteti, to se može reći tek u manjoj mjeri, dok za postupak AAM koji u jednom slučaju ostvaruje najbolji rezultat ova činjenica uopće ne vrijedi. Te činjenice sugeriraju da je predloženi postupak relativno otporan na izbor klasifikatora. Uz to, u odnosu na prva dva pratitelja (LBP, PHOG) s gledišta medijana težinske mjere AUC, predloženi pristup je bolji od svakoga od njih pojedinačno u tri od četiri slučaja, odnosno prilikom korištenja tri od četiri klasifikatora. Slijedom navedenog, a u kontekstu rezultata postignutih prilikom učenja na cijelom podatkovnom skupu, ali i broja značajki koji je samo fragment broja koje koriste druga dva pristupa, može se zaključiti da predloženi postupak iskazuje najbolja svojstva među postupcima uključenima u ekperimentalnu analizu.

Rezultati provedene analize učenja na dijelu podataka u obliku različitih mjera kvalitete predstavljeni su nadalje tablicama 3.5 do 3.8 redom za Bayesovu mrežu, algoritam k NN, nasumičnu šumu i Naivni Bayesov algoritam.

Prije svega, uočljivo je da je međusobni odnos u pogledu kvalitete između postupaka za izdvajanje značajki zadržan prilikom korištenja istog klasifikatora, Bayesove mreže, kao i kod učenja na svim dostupnim podacima. Stoga se može zaključiti da provedeno poduzorkovanje nije uzrokovalo značajna odstupanja niti potaklo različito ponašanje. Ipak, kvaliteta raspoznavanja nešto je niža nego slučaju učenja na temelju svih dostupnih podataka. Općenito se,



Slika 3.12: Rezultati usporedbe prema težinskoj mjeri AUC za postupke izdvajanja značajki uključene u eksperimentalnu analizu kod učenja na dijelu dostupnih podataka uporabom (a) Bayesove mreže, (b) algoritma k NN, (c) nasumične šume, (d) naivnog Bayesovog algoritma

Tablica 3.5: Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na dijelu podataka korištenjem Bayesove mreže

Postupak Mjera	AAM	DCT	LBP	PHOG	SHEAR
	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.
Acc	0.5055 \pm 0.1916	0.6848 \pm 0.1654	0.7121 \pm 0.1609	0.6771 \pm 0.2041	0.6756 \pm 0.1886
AUC	0.5096 \pm 0.2038	0.5628 \pm 0.1893	0.6367 \pm 0.2040	0.6848 \pm 0.1771	0.7224 \pm 0.1896
FMsr	0.5631 \pm 0.1734	0.6905 \pm 0.1831	0.7284 \pm 0.1461	0.6892 \pm 0.2036	0.7020 \pm 0.1676
Pre	0.7516 \pm 0.1496	0.7566 \pm 0.1545	0.8030 \pm 0.1217	0.8167 \pm 0.1094	0.8128 \pm 0.1360
Rec	0.5055 \pm 0.1916	0.6848 \pm 0.1654	0.7121 \pm 0.1609	0.6771 \pm 0.2041	0.6756 \pm 0.1886

Tablica 3.6: Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na dijelu podataka korištenjem algoritma k NN

Postupak Mjera	AAM	DCT	LBP	PHOG	SHEAR
	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.
Acc	0.6170 \pm 0.1606	0.6936 \pm 0.1448	0.6298 \pm 0.1490	0.6437 \pm 0.1570	0.5432 \pm 0.1942
AUC	0.5389 \pm 0.1345	0.5405 \pm 0.1684	0.5820 \pm 0.1990	0.5709 \pm 0.1670	0.5991 \pm 0.1713
FMsr	0.6642 \pm 0.1535	0.7149 \pm 0.1493	0.6626 \pm 0.1440	0.6729 \pm 0.1488	0.5957 \pm 0.1840
Pre	0.7546 \pm 0.1537	0.7632 \pm 0.1424	0.7695 \pm 0.1504	0.7659 \pm 0.1525	0.7751 \pm 0.1610
Rec	0.6170 \pm 0.1606	0.6935 \pm 0.1448	0.6298 \pm 0.1490	0.6437 \pm 0.1570	0.5432 \pm 0.1942

razmatrajući rezultate prilikom uporabe različitih klasifikatora, najslabijim pokazao postupak AAM. Iako u slučaju uporabe nasumične šume, on uspijeva ostvariti zapaženo dobar rezultat, pri uporabi drugih klasifikatora to nije slučaj. Po pitanju performansi, vrlo mu je blizak i postupak zasnovan na DCT-u. Težinska mjera AUC uzeta je, kao i u ranijem slučaju, kao primarni izvor informacija o kvaliteti pojedinih postupaka izdvajanja značajki. Zamjetna je i dalje vrlo visoka standardna devijacija za sve postupke, koja je i u ovom slučaju posljedica načina vrednovanja. Važno je također primijetiti razlike koje su prisutne kod različitih klasifikatora, neovisno o razmatranoj mjeri kvalitete. Naime, ne postoji jedan klasifikator koji za sve podatkovne skupove daje općenito najbolje rezultate, baš kao što ne postoji niti podatkovni skup koji ostvaruje uvjerljive pobjede nad svim ostalima, neovisno o klasifikatoru. Jednostavniji klasifikatori, kao što je primjerice algoritam k NN, nisu, čini se, pogodni za ovaj problem, barem u slučaju vrednovanja izostavljanjem subjekta. Iako je kod drugačijeg oblika analize, kao u [58], on pokazao dobra svojstva, u slučaju da među uzorcima koje rabi za pronalazak susjeda nema slika osobe za koju se provodi vrednovanje, kvaliteta klasifikacije trpi.

Prosječni rezultati po subjektu kakvi su prikazani u ranijim tablicama i slici 3.12 ne uzimaju u obzir broj instanci. On je pak uzet u obzir u tablicama 3.9 do 3.12, u kojima su dani prosječni rezultati u obliku različitih mjera kvalitete po instancama, odnosno u kojima subjekti koji nemaju jednak broj dostupnih instanci nisu tretirani na jednak način.

Može se primijetiti da se rezultati razlikuju u odnosu na rezultate gdje predstavljena težinska mjera AUC ne uzima u obzir broj instanci po subjektu. S obzirom na velike razlike među brojem instanci po pojedinim subjektima ove, manje oscilacije, ne začuđuju. Ipak, ključnom ostaje činjenica da odnos u pogledu kvalitete klasifikacije među postupcima za izdvajanje značajki nije izmijenjen. Budući da je korištena baza unatoč veličini i dalje ograničena brojem subjekata i instanci, zadržavanje stalnog odnosa u pogledu kvalitete, čak i kod uzimanja broja instanci po subjektu, nadalje ukazuje na stabilnost predloženog postupka. Da je kojim slučajem ovdje uočena značajnija promjena u kvaliteti rezultata ili pak osjetne izmjene u odnosu među postupcima, trebalo bi se zapitati zašto je tomu tako. S obzirom to nije slučaj, očigledno je da predloženi postupak uspijeva ostvariti relativno dobre rezultate i za one subjekte za koje su dostupni brojni podaci, kao i za one kod kojih je broj podataka značajno

Tablica 3.7: Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na dijelu podataka korištenjem nasumične šume

Postupak	AAM	DCT	LBP	PHOG	SHEAR
Mjera	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.
Acc	0.7927 \pm 0.1439	0.8126 \pm 0.1599	0.7923 \pm 0.1159	0.7863 \pm 0.1503	0.7619 \pm 0.1425
AUC	0.7252 \pm 0.1959	0.6316 \pm 0.1628	0.6776 \pm 0.1844	0.7292 \pm 0.1965	0.6990 \pm 0.1853
FMSr	0.7745 \pm 0.1563	0.7544 \pm 0.2032	0.7732 \pm 0.1464	0.7693 \pm 0.1660	0.7548 \pm 0.1586
Pre	0.7974 \pm 0.1421	0.7734 \pm 0.1489	0.7992 \pm 0.1250	0.7985 \pm 0.1391	0.8022 \pm 0.1314
Rec	0.7927 \pm 0.1439	0.8125 \pm 0.1599	0.7924 \pm 0.1159	0.7863 \pm 0.1503	0.7619 \pm 0.1425

Tablica 3.8: Prosječne vrijednosti rezultata klasifikacije po subjektima, učenjem na dijelu podataka korištenjem naivnog Bayesovog algoritma

Postupak	AAM	DCT	LBP	PHOG	SHEAR
Mjera	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.	sr.vr. \pm std.
Acc	0.3367 \pm 0.1823	0.5897 \pm 0.2150	0.6531 \pm 0.1362	0.6035 \pm 0.1645	0.5885 \pm 0.2252
AUC	0.5394 \pm 0.2261	0.5709 \pm 0.1871	0.5847 \pm 0.1791	0.6473 \pm 0.1856	0.6947 \pm 0.1982
FMSr	0.3792 \pm 0.1913	0.6163 \pm 0.2359	0.6887 \pm 0.1232	0.6464 \pm 0.1606	0.6271 \pm 0.2054
Pre	0.7700 \pm 0.1662	0.7679 \pm 0.1636	0.7911 \pm 0.1283	0.8029 \pm 0.1266	0.8154 \pm 0.1271
Rec	0.3367 \pm 0.1822	0.5897 \pm 0.2150	0.6530 \pm 0.1362	0.6035 \pm 0.1645	0.5885 \pm 0.2252

ograničen.

Na kraju, rezultati po pojedinoj klasi prikazani su tablicama 3.13 - 3.16. Oni su važni jer detaljnije ukazuju na moguće probleme kod raspoznavanja pojedinih klasa. Već je na prvi pogled uočljivo da svi postupci izdvajanja značajki, neovisno o klasifikatoru, najviše problema imaju s raspoznavanjem slabe boli. U nekim slučajevima je razina raspoznavanja čak i na razini nasumičnog pogađanja, kao kod primjerice postupka PHOG i uporabe algoritma k NN ili postupka AAM-a i uporabe bilo kojeg klasifikatora izuzevši nasumičnu šumu. Ove poteškoće proizlaze iz vrlo malih promjena koje se izražavaju na licu kod slabe razine boli, baš kao i u prethodnom eksperimentu, a za ilustraciju je moguće pogledati sliku 3.10.

S obzirom da je razlika između izraza jake boli i slabe boli ipak jače izražena, raspoznavanje jake razine boli u pravilu je bilo značajno bolje. Gledano prema svim klasifikatorima, za stanja bez boli i slabe boli predloženi je pristup u većini slučajeva ponudio nešto bolje rezultate, dok je za razinu jake boli bio među boljim postupcima. Pad performansi uočljiv je kod korištenja nasumične šume. Naime, vidljivo je, kako iz prosječnih rezultata raspoznavanja po klasama, tako i iz ostalih predstavljenih rezultata, da predloženi postupak u kombinaciji s nasumičnom šumom neće dovesti do željenih rezultata. Prema tome, ukoliko se koristi navedeni klasifikator, neki od alternativnih postupaka za izdvajanje značajki predstavlja bolji izbor, uz jednu opasku. Naime, nasumična šuma uvelike ovisi o stablima izgrađenim za potrebe klasifikacije koja se oslanjaju na nasumično odabrane značajke. S obzirom da predloženi postupak sadrži dva različita skupa značajki, moguće je da će ovo na njega imati snažniji utjecaj. Ponašanje izloženo na slici 3.12 ukazuje na opravdanost navedenog zaključka. Vidljivo je kako je za nasumičnu šumu predloženi postupak pokazao slično ponašanje kao i

Tablica 3.9: Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na dijelu podataka korištenjem Bayesove mreže

Postupak	AAM	DCT	LBP	PHOG	SHEAR
Mjera	sr.vr.	sr.vr.	sr.vr.	sr.vr.	sr.vr.
Acc	0.4912	0.6966	0.7129	0.6814	0.7167
AUC	0.4886	0.5530	0.6151	0.6734	0.7179
FMSr	0.5531	0.7052	0.7332	0.6994	0.7370
Pre	0.7547	0.7670	0.8060	0.8208	0.8216
Rec	0.4912	0.6966	0.7129	0.6814	0.7167

Tablica 3.10: Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na dijelu podataka korištenjem algoritma k NN

Postupak Mjera	AAM sr.vr.	DCT sr.vr.	LBP sr.vr.	PHOG sr.vr.	SHEAR sr.vr.
Acc	0.6442	0.7070	0.6341	0.6541	0.5499
AUC	0.5335	0.5291	0.5561	0.5541	0.5821
FMSr	0.6871	0.7276	0.6675	0.6859	0.6047
Pre	0.7676	0.7696	0.7726	0.7715	0.7804
Rec	0.6442	0.7070	0.6341	0.6541	0.5499

Tablica 3.11: Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na dijelu podataka korištenjem nasumične šume

Postupak Mjera	AAM sr.vr.	DCT sr.vr.	LBP sr.vr.	PHOG sr.vr.	SHEAR sr.vr.
Acc	0.8027	0.8230	0.7992	0.8021	0.7858
AUC	0.7096	0.6263	0.6671	0.7317	0.6905
FMSr	0.7848	0.7685	0.7815	0.7855	0.7749
Pre	0.8034	0.7786	0.8049	0.8074	0.8108
Rec	0.8027	0.8230	0.7992	0.8021	0.7858

Tablica 3.12: Prosječne vrijednosti rezultata klasifikacije po instancama, učenjem na dijelu podataka korištenjem naivnog Bayesovog algoritma

Postupak Mjera	AAM sr.vr.	DCT sr.vr.	LBP sr.vr.	PHOG sr.vr.	SHEAR sr.vr.
Acc	0.3341	0.6084	0.6513	0.6211	0.6403
AUC	0.5154	0.5628	0.5634	0.6356	0.6796
FMSr	0.3806	0.6405	0.6899	0.6639	0.6776
Pre	0.7711	0.7799	0.7924	0.8071	0.8231
Rec	0.3341	0.6084	0.6513	0.6211	0.6403

Tablica 3.13: Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na dijelu podataka korištenjem Bayesove mreže

Klasa Mjera	Bez boli sr.vr. \pm std.	Slaba bol sr.vr. \pm std.	Jaka bol sr.vr. \pm std.
AAM	0.5343 \pm 0.1883	0.4598 \pm 0.1856	0.6686 \pm 0.2457
DCT	0.5943 \pm 0.1562	0.4691 \pm 0.1523	0.7139 \pm 0.1603
LBP	0.6631 \pm 0.1697	0.5200 \pm 0.1764	0.8251 \pm 0.1499
PHOG	0.7150 \pm 0.1187	0.5622 \pm 0.1531	0.8651 \pm 0.1137
SHEAR	0.7624 \pm 0.1253	0.6065 \pm 0.1769	0.8431 \pm 0.1029

Tablica 3.14: Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na dijelu podataka korištenjem algoritma k NN

Klasa Mjera	Bez boli sr.vr. \pm std.	Slaba bol sr.vr. \pm std.	Jaka bol sr.vr. \pm std.
AAM	0.5681 \pm 0.0813	0.5307 \pm 0.1288	0.5566 \pm 0.1270
DCT	0.5693 \pm 0.1401	0.5374 \pm 0.1527	0.6086 \pm 0.1403
LBP	0.6159 \pm 0.1705	0.5118 \pm 0.1269	0.6610 \pm 0.1413
PHOG	0.6029 \pm 0.1274	0.4971 \pm 0.1093	0.6531 \pm 0.1210
SHEAR	0.6238 \pm 0.1348	0.5367 \pm 0.1152	0.6667 \pm 0.1363

postupak LBP, dok se kod ostalih klasifikatora ta ponašanja značajnije razlikuju. Uz to, broj korištenih nasumično odabranih značajki po stablu, kao i broj stabala, postavljeni su

Tablica 3.15: Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na dijelu podataka korištenjem nasumične šume

Klasa Mjera	Bez boli sr.vr. \pm std.	Slaba bol sr.vr. \pm std.	Jaka bol sr.vr. \pm std.
AAM	0.7679 \pm 0.1364	0.6031 \pm 0.1822	0.8560 \pm 0.1267
DCT	0.6718 \pm 0.1088	0.5440 \pm 0.1276	0.7835 \pm 0.1170
LBP	0.7222 \pm 0.1303	0.5348 \pm 0.1086	0.8224 \pm 0.1176
PHOG	0.7761 \pm 0.1289	0.5522 \pm 0.1141	0.8619 \pm 0.1129
SHEAR	0.7403 \pm 0.1260	0.5393 \pm 0.1375	0.8137 \pm 0.1117

Tablica 3.16: Prosječne vrijednosti rezultata klasifikacije po klasama u obliku mjere AUC, učenjem na dijelu podataka korištenjem naivnog Bayesovog algoritma

Klasa Mjera	Bez boli sr.vr. \pm std.	Slaba bol sr.vr. \pm std.	Jaka bol sr.vr. \pm std.
AAM	0.5615 \pm 0.2127	0.4772 \pm 0.1821	0.7316 \pm 0.2200
DCT	0.6087 \pm 0.1543	0.4723 \pm 0.1771	0.6737 \pm 0.1840
LBP	0.6153 \pm 0.1347	0.5256 \pm 0.1257	0.6621 \pm 0.2035
PHOG	0.6774 \pm 0.1345	0.5299 \pm 0.1252	0.7491 \pm 0.1849
SHEAR	0.7343 \pm 0.1481	0.5886 \pm 0.1754	0.7916 \pm 0.1375


na podrazumijevane vrijednosti korištene u upotrijebljenoj implementaciji [75].

3.4.5 Razmatranje rezultata usporedno po klasifikatorima

U konačnici, s ciljem dobivanja šire slike o rezultatima, za sve provedene eksperimente dan je broj pobjeda po pojedinim subjektima slikom 3.13, i to u obliku kiviati dijagrama. Svaka linija u dijagramu označava pet subjekata, a vrhovi kod svakog od postupaka govore za koliko je subjekata on ostvario najbolji rezultat u smislu težinske mjere AUC. S obzirom da je broj subjekata u podatkovnom skupu ograničen, a u stvarnom okruženju bi on sasvim sigurno bio veći, korisno je vidjeti međusobne odnose pojedinih postupaka izdvajanja značajki.

Unatoč tome što iznos razlike među postupcima ovdje nije uzet u obzir, već se samo provjeravaju pobjede po subjektima, ipak je indikativno da predloženi postupak za većinu klasifikatora na najvećem broju subjekata nudi najbolje rezultate. Navedeno sugerira da bi za okruženje s većim brojem subjekata, predloženi postupak zadržao takvo ponašanje ili bi u najgorem slučaju ostao usporediv s drugim postupcima izdvajanja značajki.

Osim broja pobjeda po subjektima, zanimljivo je pogledati i stabilnost rezultata ostvarenih uz različite postavke eksperimenata, a koja je predstavljena slikom 3.14. Njome je prikazana srednja vrijednost rezultata, predstavljena rombom na grafu, pri različitim postavkama eksperimenata, odnosno količini podataka za učenje te izmjeni klasifikatora. Sivom je pak linijom naznačen raspon između najboljih i najlošijih postignutih rezultata. Uočava se da predloženi postupak uz prosječno najbolji rezultat iskazuje manje oscilacije kod promjene klasifikatora u odnosu na ostale postupke uključene u analizu. Navedeno sugerira da upo-




Slika 3.13: Broj pobjeda po subjektima u smislu težinske mjere AUC na svim podacima: (a) Bayesova mreža, i na dijelu podataka: (b) Bayesova mreža, (c) nasumična šuma, (d) k NN i (e) naivni Bayesov algoritam

raba predloženog postupka izdvajanja značajki rezultira vektorima značajki koji su robusni i donekle neovisni o korištenom klasifikatoru. Ova činjenica važna je s obzirom da u nekim slučajevima odabir klasifikatora ovisi, ne samo o kvaliteti, već i o drugim čimbenicima kao što su dostupnost implementacije, brzina oblikovanja modela, brzina raspoznavanja i način na koji donosi odluku. Uz to, često se u praksi rabi nekoliko različitih klasifikatora čije se odluke sjedinjuju. Posebice je po tom pitanju osjetljiv postupak AAM, čije su oscilacije najizraženije, no čak i postupak PHOG u određenoj mjeri iskazuje ovo nepoželjno svojstvo.

Usporedni pregled sugerira da predloženi postupak nije bez vrlina. Njegovo razmatranje pri izgradnji sustava za klasifikaciju bolnih stanja moguće bi dovelo do lakšeg raspoznavanja razina boli uz zadržavanje ili uvećavanje kvalitete raspoznavanja. Mogućnost ugradnje u složeniji sustav koji bi rabio nekoliko postupaka za izdvajanje značajki također se čini izglednom, posebice uzevši u obzir broj značajki koji odlikuje predloženi postupak.

3.5 Osvrt na predloženi postupak

Izdvajanje značajki neizbježan je prvi korak u klasifikaciji uzoraka, a samim time i u raspoznavanju razina boli na temelju bolnih izraza prikazanih na slikama lica. Postoje u literaturi brojni pristupi razvijeni za ove potrebe koji se grubo mogu rasporediti u one koji prate značajke oblika i one koji prate značajke izgleda. Budući da se potonja skupina smatra



Slika 3.14: Stabilnost rezultata klasifikacije u smislu težinske mjere AUC prilikom promjena postavki eksperimenta

značajnijom za raspoznavanje boli na osnovu izraza lica, predložen je postupak za izdvajanje značajki zasnovan na shearlet transformaciji i podjeli lica na informativne regije. U odnosu na postojeće pristupe iz literature, predloženi se postupak ističe nižom dimenzionalnošću vektora značajki te jednostavnijom podjelom lica na tri regije. Prema provedenoj usporednoj eksperimentalnoj analizi, za većinu klasifikatora predloženi je postupak iskazao najbolje performanse u smislu težinske mjere AUC. Svakako je dodatna prednost predloženog pristupa relativno malen broj značajki koje izdvaja u odnosu na druge postupke korištene u usporedbi, čak do 10 puta. To smanjuje zahtjevnost učenja i složenost oblikovanja klasifikacijskog modela, kao i vrijeme potrebno za određivanje klase nepoznatog uzorka. S obzirom na navedeno, može se smatrati da je prvi predloženi izvorni znanstveni doprinos ostvaren.

Iz rezultata dobivenih analizom, uočljivo je da performanse dobivene uporabom pojedinih klasifikatora nisu zadovoljavajuće za praktičnu primjenu u kliničkim sustavima, no za to postoji više razloga. Velik utjecaj na kvalitetu rezultata imaju prikupljeni podaci i njihova priprema, odnosno predobrada. Primijenjeni postupak predobrade za cilj je imao omogućiti svim postupcima izdvajanja značajki jednake početne uvjete. Dodatna priprema slika, kao što je tzv. *Procrustes* analiza kakva je primijenjena u [47], svakako bi mogla doprinijeti unaprjeđenju kvalitete. Također, odabrani način testiranja izostavljanjem subjekta predstavlja najstroži oblik vrednovanja dostupan u literaturi. Klasifikacijski postupci prisiljeni su zaključivati o razini boli za osobu na temelju čijih slika nisu trenirali. Iako ovo predstavlja realističan scenarij za određene sustave i probleme, slike pacijenata često su dostupne i unaprijed. Uporaba tih slika svakako bi doprinijela performansama klasifikatora, a posebice se to očituje kod klasifikatora zasnovanog na udaljenosti kakav je i algoritam k NN. Isti algoritam je prema [58] pokazao iznimno dobre performanse kada su u podacima na temelju kojih je zaključivao bili i podaci o osobi za koju je donosio odluke. Prema literaturi,

u pravilu su najbolji rezultati ostvarivani fuzijom različitih postupaka, bilo na razini odluke ili na razini podataka. S obzirom na nisku dimenzionalnost vektora značajki izdvojenih iz izvornih slika, u odnosu na druge postupke, predloženi postupak svakako se može rabiti kao jedan od elemenata takvog sustava fuzije.

Kao glavne prednosti predloženog pristupa pokazuju se njegove performanse na različitim klasifikacijskim postupcima i značajno niža dimenzionalnost vektora značajki u odnosu na glavne konkurentske postupke izdvajanja značajki. Kao glavni nedostaci predloženog postupka, mogu se istaknuti blago složenije prikupljanje podataka koje je nužno obaviti da bi se došlo do vektora značajki u odnosu na, primjerice, postupke DCT i LBP. Ipak, predloženi postupak nije optimiran ni na koji način s ciljem postizanja uvećanja performansi, odnosno skraćivanja potrebnog vremena za preslikavanje iz digitalne slike u vektor značajki. U predloženom postupku ima mjesta i za paralelizaciju, ukoliko bude potrebno, s obzirom da se prikupljaju dva neovisna skupa značajki na tri neovisne regije lica. U slučaju potrebe, moguće je predloženi pristup implementirati na specifično sklopovlje te tako postići daljnja ubrzanja.

Postoje određeni koraci koji se mogu napraviti s ciljem unaprjeđenja predloženog postupka. Iako se podjela na vrlo jednostavne regije, gdje je zamjetna promjena izraza lica, pokazala dobrom, neka složenija podjela potencijalno bi mogla dovesti do daljnjeg poboljšanja performansi. Kod podjele na regije treba ipak biti oprezan jer odabir kompleksnijih regija traži dodatne korake predobrade, primjerice pronalazak ključnih točaka na licu, a povećan broj razmatranih regija doveo bi neminovno do povećanja dimenzionalnosti problema. Također, drugačiji način izdvajanja značajki na temelju shearlet koeficijenata bi mogao umanjiti broj korištenih značajki, ali i dovesti do boljih performansi. Statistike prvog i drugog reda, lokalni ternarni uzorci, uniformni binarni uzorci neosjetljivi na rotaciju, samo su neki od mogućih pristupa u tom pogledu.

Smanjenje dimenzionalnosti problema odabirom značajki omotačem


*"Not everything that can be counted counts, and not everything that counts can be counted."
- Albert Einstein*

PROBLEM visoke dimenzionalnosti podataka, odnosno visokog broja značajki, jedan je od problema koji se često susreću pri različitim klasifikacijskim zadacima. Cilj ovog poglavlja jest najprije predstaviti problem visoke dimenzionalnosti podataka te načine njegova ublažavanja i to odabirom i uporabom samo dijela značajki. Pri tom će poseban naglasak biti stavljen na metode omotača kao mogući način hvatanja u koštac s danim problemom, a koje se redovito pokazuju vrlo sposobnima u potrazi za dobrim podskupovima značajki. Nakon pregleda literature koja se bavi problemom smanjenja dimenzionalnosti, bit će predložena unaprijeđena metoda odabira značajki zasnovana na praćenju njihova doprinosa tijekom optimizacije metodom omotača. Navedena metoda predstavlja ujedno drugi očekivani izvorni znanstveni doprinos. Omotači koji će biti razmatrani su prirodom inspirirani optimizacijski algoritmi, budući da omogućuju dobru pretragu prostora mogućih rješenja. Ideja je iskoristiti znanje koje se stječe ovim omotačima tijekom pretrage, i to u vidu različitih stvorenih kandidata za rješenje. Navedena metoda bit će eksperimentalno vrednovana na standardnom skupu podataka koji opisuju razine boli, s ciljem ostvarivanja dubljeg uvida u ponašanje i

performanse navedene metode te donošenja konačne odluke o opravdanosti njene ugradnje. Uz to, metoda će biti vrednovana i na nekoliko problema koji dolaze iz različitih domena.

4.1 Smanjenje dimenzionalnosti odabirom značajki

Prilikom izdvajanja opisnih značajki koje će se rabiti u kasnijim koracima klasifikacije, njihov broj nije moguće odrediti unaprijed bez dobrog poznavanja problema koji se rješava, a često čak niti tada. Navedeno je poglavito uočljivo ako problem proizlazi iz stvarnog svijeta. Stoga nije neuobičajen odabir neprikladnog broja značajki koje se uključuju u klasifikaciju. Ovaj problem pokazuje se, bilo da je riječ o broju manjem ili većem od najboljeg za dani podatkovni skup. Vrlo često prilikom odabira broja značajki važnu ulogu igra i intuitivan pristup, prema kojem bi uključivanje dodatnih značajki trebalo dovesti do povećanja preciznosti klasifikacije. Pretpostavka je tada da se dodatnim informacijama može samo pospješiti raspoznavanje uzoraka. Međutim, navedeno u pravilu nije slučaj, a uključivanje dodatnih značajki može, a vrlo često tako i biva, rezultirati uključivanjem nevažnih, redundantnih pa čak i značajki koje narušavaju kvalitetu klasifikacije [85]. S ciljem izbjegavanja ovog problema, priskače se smanjenju broja značajki, odnosno umanjenju dimenzionalnosti problema. To se postiže odabirom i uporabom samo određenih značajki među svim dostupnima. Cilj odabira značajki jest pronaći podskup skupa dostupnih značajki tako da se postigne nešto od sljedećeg: podskup određene veličine koji daje najbolje rezultate, podskup manje veličine koji zadovoljava određeni kriterij kvalitete ili podskup koji nudi najbolji omjer veličine i kvalitete [86]. Nacrt postupka odabira značajki dan je slikom 4.1.



Slika 4.1: Nacrt postupka odabira značajki

Pristupi za odabir značajki mogu se grubo podijeliti u dvije skupine: rangiranje značajki (engl. *ranked selection*, RS) i odabir značajki (engl. *feature selection*, FS). Kod metoda prve skupine, sve se značajke rangiraju prema nekom kriteriju te se odabire određeni, unaprijed zadan broj najbolje rangiranih značajki. Problem ovog pristupa jest taj što broj potrebnih značajki ne mora biti unaprijed poznat. Kod metoda druge skupine pokušava se pronaći podskup značajki niže kardinalnosti od originalnoga skupa značajki, tako da se postigne jedan od ranije navedenih ciljeva. Potonje metode se nadalje mogu podijeliti u četiri skupine,

ovisno o načinu na koji se provodi odabir. Riječ je o pristupima zasnovanim na filtrima, pristupima zasnovanim na omotačima, hibridnim pristupima te ugrađenim pristupima [86, 87]. Problem smanjenja dimenzionalnosti detaljno je prikazan u [87, 88], zajedno s uobičajenim načinima njegova ublažavanja.

Metode zasnovane na filtrima ne oslanjaju se na klasifikatore niti uspješnost klasifikacije već isključivo na intrinzične karakteristike podatkovnog skupa s kojim se radi. Općenito gledano, prema navedenome, može ih se smatrati dodatnim korakom predobrade podataka. Prednosti ovih metoda su u pravilu niža računalna zahtjevnost u odnosu na preostale skupine, neovisnost o klasifikatoru, dok su nedostaci uobičajeno veći broj konačno uključenih značajki [89] te potreba odabira filtra koji će se rabiti. Značajan broj dostupnih i često rabljenih filtera te njihovu učinkovitost na problemima koji dolaze iz različitih domena moguće je vidjeti u [90].

S obzirom da predložena unaprijeđena metoda odabira značajki praćenjem doprinosa pojedinih značajki znanje crpi iz postupka pretrage prilikom uporabe omotača, u idućem je potpoglavlju posebna pozornost posvećena metodama zasnovanim na omotačima. Ukratko, riječ je o metodama koje uključuju određeni klasifikator i na temelju njegova rezultata i učinkovitosti klasifikacije vode pretragu ka najboljim podskupovima značajki [91]. Ovi pristupi u pravilu mogu ponuditi bolji krajnji podskup značajki, no računalno su složeniji te postoji rizik od pretjerane prilagodbe klasifikatoru.

Hibridni pristupi kombiniraju ideje iz prethodno opisanih dvaju skupina, pokušavajući pri tome eliminirati nedostatke svake od njih. Uobičajeno se najprije provodi filtriranje, a zatim se na podacima uporabom klasifikatora izvodi preciznija pretraga za boljim podskupovima značajki. Prednost ovakvih metoda su dobre performanse, no istovremeno zahtijevaju odabir, kako odgovarajućeg filtra, tako i klasifikatora kojim će biti vođena pretraga. Prema tome, računalno su zahtjevnije od pojedinačnih metoda zasnovanih na filtrima ili omotačima. Moguća je također i pretjerana prilagodba klasifikatoru te su zato nužni koraci s ciljem umanjenja ovog rizika.

Ugrađeni pristupi oblik su metoda odabira značajki koje se implicitno odvijaju unutar pojedinih klasifikatora. Primjerice, kod nasumičnih se stabala nasumce odabiru značajke koje će se rabiti za klasifikaciju dok se kod raznih inačica umjetnih neuronskih mreža (engl. *artificial neural network*, ANN) ulazni podaci preko spona s težinskim faktorima dovode do skrivenog sloja mreže. Ako su težinski faktori postavljeni na nulu, tada se značajku zapravo ne uzima u obzir prilikom klasifikacije. S obzirom da su spomenute metode izravno ugrađene u klasifikatore, u svakom su slučaju njima prilagođene. Njihovom učinkovitošću vodi se pretraga i postavljaju parametri klasifikacijskog modela koji utječu na odabrane značajke. Potonje može dovesti i do pretjerane prilagodbe skupu za učenje, odnosno do uključivanja ili isključivanja značajki koje za dani podatkovni skup općenito ne iskazuju ista svojstva kao

za njegov podskup određen za oblikovanje klasifikacijskog modela.

4.2 Postupci zasnovani na omotačima

Postupci zasnovani na omotačima predstavljaju danas čest odabir za rješavanje problema visoke dimenzionalnosti. Takve metode „omotaju” se oko određenog klasifikatora i njegovim rezultatima vode pretragu za kvalitetnim podskupom značajki. Opisana pretraga provodi se kroz četiri formalna koraka: najprije se generira podskup, zatim se procijeni njegova kvaliteta, potom se provjerava kriterij prekida te se konačno vrednuju dobiveni rezultati. Formalnije rečeno, cilj je pronaći binarni vektor b^* koji bi se rabio kao maska, s ciljem generiranja smanjenog skupa značajki koji će biti upotrijebljen za klasifikaciju. Ova je pretraga vođena funkcijom cilja f , a formalno se može izraziti kao

$$b^* = \arg \max_{b \in B = \{0,1\}^d} f(S_p, b), \quad (4.1)$$

gdje B označava skup svih binarnih vektora b koji predstavljaju bitovne maske, b^* onu masku za koju funkcija cilja poprima maksimalnu vrijednost, a S_p podatkovni skup s poznatim oznakama. Primjerice, funkcija cilja može biti uspješnost klasifikacije u smislu neke od mjera kvalitete ili pak kompleksnija mjera koja uključuje i kompleksnost pristupa u pogledu broja uključenih značajki.

Općenito, metode omotača su u pravilu preciznije, nude bolje podskupove značajki, no računalo su zahtjevnije te postoji mogućnost pretjerane prilagode klasifikatoru koji se rabi [92]. Detaljniji opis ovih metoda kao i okvir za njihovu analizu predstavljen je u [86]. U literaturi su dostupni brojni omotači koji se razlikuju po složenosti i načinu na koji obavljaju pretragu. Jedan od najjednostavnijih pristupa je nasumična potraga, primjerice uporabom *Las Vegas* omotača [86]. Potraga se obavlja opetovanim stvaranjem nasumičnih bitovnih maski, koje se zatim vrednuju. Postupak se ponavlja dok se ne dostigne maksimalni dopušteni broj vrednovanja, nakon čega se najbolje rješenje uzima kao konačno. S obzirom na nasumičnost pristupa, izvjesno je da kod složenijih problema može doći do konačnih rješenja koja ne iskazuju dobra svojstva. Slijedni odabir (engl. *sequential forward selection*, SFS) ili slijedno uklanjanje (engl. *sequential backwards selection*, SBS) [93] predstavljaju također jednostavne omotače koji dodaju, odnosno uklanjaju pojedinačne značajke sve dok je moguće unaprijediti kvalitetu prema funkciji cilja. Ovakvi pristupi u pravilu dovode do premalog, odnosno prevelikoga broja značajki s obzirom na to da u jednoj iteraciji potrage mogu dodati, odnosno ukloniti samo jednu značajku. Unaprjeđenja u obliku plutajuće pretrage unaprijed (engl. *sequential floating forward selection*, SFFS) ili unatrag (engl. *sequential floating backward selection*, SFBS) i kombinirane plutajuće pretrage (engl. *sequential floating*

forward-backward selection, SFFBS) predložena su s ciljem uklanjanja ovih nedostataka [94]. Međutim, prilikom pretrage mogu imati problema s međuovisnim značajkama, što je čest slučaj u problemima koji proizlaze iz prirode. Drugi algoritmi globalne optimizacije poput algoritama FOCUS ili *Branch and Bound* mogu također biti primijenjeni kao omotači. U posljednje je vrijeme sve češće moguće susresti prirodom inspirirane algoritme za optimizaciju kao omotače, s obzirom na dobro ponašanje prilikom pretrage koje iskazuju. Budući da se predložena unaprijeđena metoda oslanja upravo na proces pretrage spomenutih algoritama, neki su od predstavnika ovakvih omotača поближе prikazani u nastavku.

4.2.1 Prirodom inspirirani algoritmi kao omotači

Prirodom inspirirani algoritmi za optimizaciju našli su vrlo široku primjenu kao omotači za potrebe odabira značajki zbog dobrih svojstava pretrage. Primjerice, u ovu svrhu rabi se algoritam šišmiša (engl. *bat algorithm*) kao što je predstavljeno u [95]. Naime, korištena je binarna inačica navedenog algoritma u kombinaciji s klasifikatorom optimalne šume. Algoritam je binariziran sigmoidnom funkcijom primijenjenom na položaj šišmiša u prostoru, odnosno predloženo rješenje problema. Pokazano je da ponuđeni pristup u pravilu pronalazi najmanji broj značajki i pruža bolje rezultate u odnosu na algoritam krijesnica (engl. *firefly algorithm*, FFA), algoritam optimizacije rojem čestica (engl. *particle swarm optimisation*, PSO), algoritam gravitacijske pretrage (engl. *gravitational search algorithm*) i harmonijsku pretragu (engl. *harmonic search*) na standardnim skupovima podataka u većini slučajeva. Testiranje je obavljeno metodom izostavljanja na deset odvojenih izvođenja. Algoritam krijesnica koristili su Emary et al. u [96]. Usporedbom na različitim klasifikacijskim problemima pokazane su prednosti navedenog algoritma nad genetskim algoritmom (engl. *genetic algorithm*, GA) i algoritmom optimizacije rojem čestica. Zhang et al. su u [97] koristili PSO da bi umanjili broj značajki i pomoću stabla odluke detektirali neželjene poruke elektroničke pošte (SPAM). Binarizacija je provedena korištenjem sigmoidne funkcije, na sličan način kao i kod ranijeg primjera s algoritmom šišmiša. Uvedeno je i ograničavanje brzine radi sprječavanja pretjerano brze konvergencije te dodatni parametar mutacije. Pri testiranju je korišten postupak unakrsne provjere korištenjem k preklopa. Rezultati pokazuju da za dani problem detekcije neželjene elektroničke pošte, opisani pristup daje najbolje rezultate u odnosu na ostale pristupe uključene u analizu (nekoliko inačica PSO-a, algoritam optimizacije kolonijom mrava), a čini to uz najmanji broj značajki. Pristup zasnovan na algoritmu optimizacije kolonije obogaćenih mrava predložen je u [98]. Prikazana su tri različita unaprijeđena algoritma koji kombiniraju oslanjanje na prethodne prolaskе mrava te metode lokalne pretrage za generiranje boljih rješenja, odnosno reduciranih vektora značajki. Kao klasifikatori su rabljeni algoritam k NN i naivni Bayesov klasifikator, a pristup je pokazao dobra svojstva, posebice kod podatkovnih skupova veće dimenzionalnosti. Također, i algoritam

umjetne kolonije pčela (engl. *artificial bee colony algorithm*, ABC) korišten je kao omotač i to u [99]. Korištene su ideje iz PSO-a, a generirani su globalni i lokalni težinski faktori za pojedine izvore hrane. Usporedbe na standardnim skupovima podataka pokazuju uspješnost ovog pristupa u odnosu na druge prirodom inspirirane pristupe. Schiezero et al. u [100] su rabili algoritam umjetne kolonije pčela prilagođen za odabir značajki. Pretraga započinje rješenjima koja koriste samo jednu značajku, a koja se kroz pretragu nadograđuju novim značajkama ukoliko one podižu kvalitetu klasifikacije. Uveden je i faktor koji predstavlja vjerojatnost okretanja bita (engl. *bit-flip*) na pojedinoj komponenti rješenja, to jest njezino uključivanje ili isključivanje. Rezultati na standardnim skupovima podataka pokazuju da je dani pristup ostvario najbolje rezultate koristeći najmanji broj značajki. Ovaj algoritam korišten je i u [101] u kombinaciji s klasifikatorom SVM. Postupak je također zasnovan na ideji da je bitno dobiti najveću kvalitetu klasifikacije uz najmanji broj značajki (nalik SFS-u). Unaprijeđenje osnovnog ABC-a predstavili su Hancer et al. u [102]. Binarna inačica ABC-a s uključenom stopom izmjene omogućuje značajniju izmjenu osnovnog rješenja kada se na osnovu njega stvara novo. Navedena izmjena pogoduje problemima s visokom dimenzionalnošću. Također, uvedeno je korištenje Jaccardova koeficijenta sličnosti binarnih vektora te ideja mutacije, rekombinacije i selekcije iz diferencijalne evolucije (engl. *differential evolution*, DE). Navedeni je pristup u usporednoj analizi u koju je uključeno nekoliko poznatih prirodom inspiriranih optimizacijskih algoritama, ali i njihovih unaprijeđenih inačica, pokazao najbolje performanse. Osim inteligencije rojeva (engl. *swarm intelligence*) često se rabe i evolucijski postupci, poput GA. Tako primjerice [103] koristi GA kao omotač i algoritam k NN kao klasifikator, dok se smanjenje dimenzionalnosti postiže korištenjem težinskih faktora i jedne ili više maski. Da bi se unaprijedio postupak pretrage, u [104] je predstavljen hibridni GA za odabir značajki. U pretragu je uključen algoritam lokalne pretrage temeljen na razlici i informativnoj prirodi značajki izvedenoj iz korelacije među podacima. Kao klasifikator ovdje je korištena umjetna neuronska mreža. Dodatni pristupi zasnovani na GA prikazani su u [105, 106]. Osim GA, koriste se i drugi evolucijski pristupi, poput DE. Jedan takav, zasnovan na arhivi, ponudili su Martinović et al. u [91]. Tijekom procesa pretrage stvara se arhiva znanja na temelju koje se dodatnim vrednovanjem generira najbolji skup značajki. Problem rada s neuravnoteženim skupovima opisan je u [107], gdje je dan primjer korištenja ansambla postupaka odabira značajki. Pokazano je da ansambli u pravilu daju stabilnija rješenja, posebice kod neravnoteže klasa.


4.3 Metoda odabira značajki praćenjem doprinosa opisnih značajki boli

Smanjenje broja značajki u području određivanja intenziteta i postojanja boli pojavljuje se relativno rijetko, iako se, s obzirom na velik broj značajki koje se rabe za njegovo rješavanje, ono čini kao vrlo pogodno područje primjene. Ipak, u [53] prikazano je smanjenje dimenzionalnosti problema korištenjem analize osnovnih komponenata (engl. *principle component analysis*, PCA), pomoću SFS-a i pomoću uklanjanja težinskih koeficijenata ANN-om. S obzirom na pozitivna svojstva koja donosi odabir značajki, kao izvorni znanstveni doprinos predlaže se unaprijeđena metoda koja se oslanja na proces pretrage prirodno inspiriranim algoritmom. Budući da se pretraga prilikom uporabe metoda odabira značajki zasnovanih na omotačima u pravilu vodi učinkovitošću klasifikatora na podskupu ukupnih podataka, moguće je da će omotač, osim prilagodbe klasifikatoru, odabrani vektor značajki prilagoditi i skupu na kojem se radi treniranje. Da bi se to izbjeglo, a istovremeno potaknuo odabir univerzalno dobrih značajki, u pogledu neovisnosti o podjeli skupa podataka, moguće je pratiti različita rješenja koja se pojavljuju tijekom pretrage. S obzirom da praćenje stanja populacije arhivom različitih rješenja visoke kvalitete može u konačnici dovesti do boljeg rješenja u odnosu na rješenje koje je ponudila osnovna metoda [91], jasno je da se tijekom pretrage stječe velika količina znanja o problemu. Ipak, ugradnja takve arhive razmatra rješenja kao cjeline, ne uzimajući u obzir doprinos pojedinih značajki, a zahtijeva i dodatno vrednovanje rješenja. Ideja iza predložene unaprijeđene metode za odabir značajki jest pratiti najbolja i najgora rješenja prema funkciji cilja koja se pojavljuju tijekom potrage nekim od omotača. Iako će se pojedina rješenja razlikovati u uključenim komponentama, neke od značajki češće će ispoljavati pozitivna, odnosno negativna svojstva. Naime, rješenja niske kvalitete imat će često slične značajke ili skupine značajki uključene ili isključene, a isto će vrijediti i za rješenja visoke kvalitete. Informacije o ovim podudarnostima valja zabilježiti te na neki način na temelju njih doći do prijedloga korigiranog konačnog rješenja. S obzirom da ugradnja ovakvog unaprijeđenja ne narušava, niti na bilo koji način utječe na proces pretrage osnovnog omotača, moguće ju je ugraditi u različite omotače, ovisno o potrebi.

4.3.1 Tijek pretrage omotačem

Pretraga omotačem provodi se u nekoliko koraka, prikazanih okvirno slikom 4.2. Najprije se odabiru omotač i klasifikator koji će se koristiti. Nakon toga, podatkovni skup za koji se provodi smanjenje dimenzionalnosti dijeli se na dva disjunktna podskupa, pri čemu će jedan kasnije biti rabljen za testiranje, dok će drugi biti rabljen za vođenje pretrage i pronalazak najboljeg podskupa značajki. Navedeno je moguće ostvariti na više različitih načina, a često


se u tu svrhu odabire metoda izostavljanja [91, 95, 108]. Potom se generiraju rješenja, a svako rješenje predstavlja jedan mogući podskup značajki, odnosno binarnu masku kojom se uključuju ili isključuju značajke. Svako rješenje vrednuje se prema zadanoj funkciji cilja, koja obično predstavlja neku od mjera kvalitete klasifikacije. Pri vrednovanju se rabi inicijalno odabrani klasifikator. Ovo interno vrednovanje sastoji se od oblikovanja klasifikacijskog modela i procjene kvalitete podskupa značajki funkcijom cilja, a nužno ga je provesti uz novu podjelu dostupnih podataka. Ako bi se oboje činilo na svim dostupnim podacima, došlo bi do pretjerane prilagodbe. U svrhu izbjegavanja navedene pojave, skup se dijeli kao i ranije, na dva dijela, dio za izgradnju modela i dio za vrednovanje rješenja. Za potrebe provođenja eksperimentalnog vrednovanja predložene metode, podaci za trening podijeljeni su na k preklopa. Za učenje i vrednovanje koristi se cijeli dostupni skup podataka, ali tako da niti u jednom trenutku ne dođe do ulaska podataka za ocjenu kvalitete rješenja, odnosno pronađenog podskupa značajki, u podatke na temelju kojih se oblikuje model. Opisana mjera kvalitete otpornija je na slučajnu podjelu skupa. Nakon vrednovanja rješenja, provjerava se je li došlo do maksimalnog dopuštenog broja vrednovanja funkcije cilja ili modela zadovoljavajuće razine kvalitete, ovisno o postavkama pretrage. Prema odabranom kriteriju, nastavlja se stvaranje novih rješenja ili se postupak završava. Jednom kada je proces pretrage završen, uzima se najbolje pronađeno rješenje koje se održava tijekom cijelog trajanja pretrage. Korištenjem tog rješenja provodi se konačna analiza uporabom na početku izostavljenog dijela podataka namijenjenog upravo za ovu svrhu.



Slika 4.2: Nacrt postupka odabira značajki omotačem

4.3.2 Praćenje doprinosa značajki

Kao što je spomenuto u prošlom potpoglavlju, cilj predloženog unaprjeđenja je praćenje doprinosa pojedinih značajki. To se postiže tako da se prilikom početka pretrage stvaraju četiri različite arhive za pojedini tip značajki. Tijekom pretrage generiraju se kandidati različitog broja uključenih značajki i kvalitete, a u određenim se intervalima, svakih ω vrednovanja rješenja prema funkciji cilja, provodi bilježenje stanja kandidata, odnosno stanja najboljih i najgorih rješenja. Detalji ugradnje predloženog unaprjeđenja ovise pri tome o korištenom omotaču. Naime, predloženom unaprjeđenju nužno je omogućiti uvid u što više rješenja različite kvalitete. Prema tome, potrebno pratiti nove kandidate koji nastaju u procesu pretrage omotačem, a ne samo najbolja ili najgora rješenja unutar populacije koju omotač održava. Korake predložene unaprijeđene metode prikazuje slika 4.3



Slika 4.3: Koraci unaprijeđene metode odabira značajki

Praćenje zajedničkih povoljnih i nepovoljnih značajki obavlja se prema izrazima (4.2) do (4.5). Pri tome, (4.2) omogućuje praćenje uključenih značajki u najboljim rješenjima, (4.3) praćenje isključenih značajki u najboljim rješenjima, (4.4) praćenje uključenih značajki u najgorim rješenjima, a (4.5) praćenje isključenih značajki u najgorim rješenjima.

$$b_{bst(+)}^j = \begin{cases} b_{bst(+)}^j + 1, & \text{ako } sol_{bst}^j \text{ uključeno} \\ b_{bst(+)}^j, & \text{inače} \end{cases} \quad (4.2)$$

$$b_{bst(-)}^j = \begin{cases} b_{bst(-)}^j + 1, & \text{ako } sol_{bst}^j \text{ isključeno} \\ b_{bst(-)}^j, & \text{inače} \end{cases} \quad (4.3)$$

$$b_{wst(+)}^j = \begin{cases} b_{wst(+)}^j + 1, & \text{ako } sol_{wst}^j \text{ uključeno} \\ b_{wst(+)}^j, & \text{inače} \end{cases} \quad (4.4)$$

$$b_{wst(-)}^j = \begin{cases} b_{wst(-)}^j + 1, & \text{ako } sol_{wst}^j \text{ isključeno} \\ b_{wst(-)}^j, & \text{inače} \end{cases} \quad (4.5)$$

U izrazima od (4.2) do (4.5), $b_{bst(+)}^j, b_{bst(-)}^j, b_{wst(+)}^j, b_{wst(-)}^j$ označavaju praćene uključene i isključene značajke koje doprinose najboljem, odnosno najgorem rješenju tijekom pretrage, $j = 1, \dots, d$, a sol_{bst} i sol_{wst} predstavljaju najbolje i najgore trenutno prisutno rješenje.

Ukoliko je potrebno, učestalost ovog praćenja moguće je prilagoditi problemu. Odabrano je, prema provedenoj preliminarnoj analizi, praćenje nakon onoliko vrednovanja funkcije cilja, koliki je broj jedinki unutar populacije rješenja, odnosno nakon $\omega = PS$ vrednovanja funkcije cilja. S obzirom na različite načine rada pojedinih omotača, navedena je učestalost omogućila da se doprinosi bilježe u jednakim intervalima, neovisno o postupku.

Za razliku od postojećih metoda koje se oslanjaju na praćenje stanja pretrage, poput primjerice arhive korištene u [91], predloženo unaprjeđenje ne zahtijeva dodatno upravljanje podatkovnim skupom, dodatno detaljnije vrednovanje na koncu pretrage niti traži mjerenje različitosti pojedinih rješenja koja se koriste. Praćenjem značajki tijekom same pretrage, odnosno opažanjem opetovane pojave značajki u rješenjima najveće i najmanje kvalitete, moguće je dobiti uvid u značajke koje ne pridonose klasifikaciji i značajke koje su za nju ključne.

4.3.3 Kreiranje rješenja na osnovu arhive znanja

Jednom kada se, na način opisan u potpoglavlju 4.3.2, prikupe informacije o doprinosu pojedinih značajki te kada se dostigne kriterij završavanja pretrage pristupa se korekciji rješenja. Drugim riječima, pristupa se stvaranju novog rješenja na temelju stečenih informacija. Pojedine komponente ispravljenog rješenja uključuju se ili isključuju prema izrazu

$$b_c^j = \alpha \cdot b_{bst(+)}^j - \beta \cdot b_{bst(-)}^j - \gamma \cdot b_{wst(+)}^j + \delta \cdot b_{wst(-)}^j, \quad j = 1 \dots d, \quad (4.6)$$

pri čemu je b_c ispravljeno rješenje, a α, β, γ i δ koeficijenti utjecaja pojedinih elemenata korekcije. Pomoću navedenih koeficijenata omogućena je prilagodba korekcijskog zahvata problemu koji se rješava, uz već raniju mogućnost kontrole učestalosti bilježenja doprinosa značajki. U nekim će slučajevima biti potrebno naglasiti najbolje ili najlošije značajke, a kontrolu je moguće provesti dodatnim vrednovanjem i usporedbom kvalitete s konačnim rješenjem koje je ponudio omotač. Za potrebe eksperimentalne analize, vrijednosti ovih parametara postavljene su na 1.

4.4 Eksperimentalna analiza i rezultati

Da bi se dobile tražene informacije o ponašanju predloženog unaprjeđenja, provedena je odgovarajuća eksperimentalna analiza. Analiza je podijeljena u tri glavna dijela. U prvom dijelu, unaprjeđenje je ugrađeno u nekoliko postupaka namijenjenih odabiru značajki predloženih u literaturi, a ponašanje je procijenjeno na osnovu podatkovnog skupa prikupljenog u kliničkim uvjetima koji opisuje razine boli. U drugom dijelu, predloženo unaprjeđenje ugrađeno je u osnovne oblike prirodom inspiriranih algoritama korištenih u prvom dijelu provedene analize, a ponašanje je opet vrednovano na podatkovnom skupu bolnih izraza lica. Nadalje, u trećem dijelu, razmatrano je ponašanje predloženog unaprjeđenja pri radu s problemima iz različitih područja, a s ciljem dobivanja šire slike o njegovim prednostima i mogućim nedostacima. Priprema podataka, postavke parametara omotača te opis postupka testiranja dani su u nastavku ovog poglavlja, kao i rezultati eksperimentalne analize s komentarima i zaključcima.

4.4.1 Postavke eksperimenta

Osnovna premisa iza eksperimenta za potrebe vrednovanja predloženog unaprjeđenja jest njegova ugradnja u nekoliko postupaka za smanjenje dimenzionalnosti problema iz literature te međusobna usporedba učinkovitosti. S obzirom da metode omotača inspirirane prirodom nisu deterministički već stohastički postupci, a pretraga prostora rješenja pa tako i konačno dano rješenje razlikuju se čak i za jednake ulazne podatka, usporedbu učinkovitosti potrebno je ponoviti određeni broj puta. Na temelju toga mogu se dobiti zaključci o uspješnosti predloženog unaprjeđenja u odnosu na izvorno dobiveno rješenje koje pruža omotač. Da bi se to ostvarilo, za testiranje je odabrana metoda podjele skupa podataka izostavljanjem. Naime, na početku vrednovanja skup podataka podijeljen je na dva podatkovna skupa, označena s S_p i S_c , za potrebe pretrage i potrebe vrednovanja, odnosno testiranja. Omjer broja instanci u ovim skupovima postavljen je na 0.8 : 0.2, što predstavlja odabir pri kojem je dovoljan broj instanci ostavljen za potrebe pretrage. Važno je pritom napomenuti da je podjela stratificirana, odnosno da je zadržan omjer među klasama kakav je i u originalnom skupu podataka u oba navedena skupa. Vrednovanje konačno dobivenih rješenja provedeno je na temelju klasifikacije instanci iz podskupa S_c i to ponavljanjem postupka pronalaska rješenja omotačem 25 puta. Prilikom potrage za rješenjem korišten je skup S_p i to tako da je kod vrednovanja svakog pojedinog kandidata za rješenje rabljena metoda unakrsne provjere korištenjem 5 preklopa. Dakle, prilikom svakog vrednovanja, klasifikacijski model izgrađen je na temelju $k - 1$ preklopa, dok je preostali izostavljen u svrhu internog vrednovanja kandidata. Prosječkom na svih k preklopa omogućena je uporaba cijelog dostupnog skupa S_p za procjenu kvalitete pojedinog kandidata. Ovu unutarnju analizu, također zvanu validacija

(engl. *validation*), moguće je provesti i drugačije, poput primjerice pristupa u [91, 109], gdje se interno ponovno koristila metoda izostavljanja. Prednost potonjeg pristupa je brže vrednovanje, no osjetljivost odabira značajki na pretjeranu prilagodbu razlog je odabira upravo opisanog načina provođenja unutarnje analize.

Da bi se trajanje vredovanja svelo na razumnu razinu, za potrebe provođenja eksperimenta napravljeno je umanjeње broja instanci danog problema. Naime, vrednovanje funkcije cilja zahtjevan je posao u pogledu nužnog računalnog vremena, a vrlo visok broj instanci dodatno naglašava ovu činjenicu. Cjelokupan dostupni skup podataka umanjen je tako nasumičnim odabirom, kako subjekata, tako i uzoraka po subjektu. Prema tome, odabrano je 10 nasumičnih subjekata među dostupnima te je zatim za svaku od klasa po pojedinom subjektu odabrano 20 uzoraka. Navedeno poduzorkovanje provedeno je ukupno četiri puta. Opisanim postupkom tako su stvorena četiri podatkovna skupa s ciljem osiguravanja da skupovi sadrže različite subjekte i različite uzorke za svakog subjekta. Tako je izbjegnuto favoriziranje određenih subjekata, a zadržana je i raznolikost unutar skupova. Kreirani skupovi predstavljeni su tablicom 4.1 u kojoj su vidljivi naziv i oznaka, broj instanci, broj subjekata, broj atributa te broj klasa po podatkovnom skupu. Dodan argument u korist predloženog poduzorkovanja jest činjenica da su skupovi \mathcal{D}_0 do \mathcal{D}_3 neovisni o subjektima, čiji je broj u dostupnoj bazi ograničen, a u stvarnosti bi bio značajno veći.

Tablica 4.1: Karakteristike poduzorkovanih skupova podataka

Naziv	oznaka	br. sub.	br. instanci	br. atributa	br. klasa	inst. po klasi
Bol_0	\mathcal{D}_0	10	580	489	3	200/200/180
Bol_1	\mathcal{D}_1	10	560	489	3	200/180/180
Bol_2	\mathcal{D}_2	10	580	489	3	200/180/200
Bol_3	\mathcal{D}_3	10	560	489	3	200/180/180

Da bi se omogućila ugradnja predloženog unaprjeđenja, potrebno je najprije ugraditi osnovne pristupe jer se ono vodi postupkom pretrage postojećeg prirodno inspiriranog algoritma za optimizaciju. Broj mogućih odabira osnovnih pristupa vrlo je velik, kao što je dijelom predstavljeno u potpoglavlju 4.2.1, a različiti novi pristupi predlažu se praktički na dnevnoj razini. Za potrebe eksperimentalne analize odabrana je stoga nekolicina pristupa zasnovana na često korištenim i popularnim prirodno inspiriranim algoritmima optimizacije.

Dva pristupa uključena u analizu zasnovana su na algoritmu PSO. Riječ je o osnovnoj inačici (oznaka PSO) predstavljenoj u [103] te unaprijeđenoj binarnoj inačici PSO-a (oznaka MBPSO) prikazanoj u [97]. Potonja je uspješno korištena kod problema odabira značajki prilikom klasifikacije neželjene elektroničke pošte i u usporedbi s drugim postupcima pokazala je zavidne performanse. Daljnja dva pristupa zasnovana su na algoritmu ABC. Radi se o osnovnoj inačici predstavljenoj u [110], a korištenoj u [101] (oznaka ABC) te o unaprijeđenoj inačici prilagođenoj radu s problemima visoke dimenzionalnosti (oznaka MRABC). Unaprijeđena inačica detaljno je opisana u [111], a za potrebe odabira značajki ugrađena i

upotrijebljena u [102]. Dodatni pristup zasnovan na ponašanju krijesnica, predstavljen u svrhu odabira značajki u [108], također je implementiran za potrebe analize, a nosi oznaku FFA. Članovi, odnosno moguća rješenja problema, unutar populacije sol_i , za sve pristupe kodirani su kao vektori realnih brojeva ograničeni unutar raspona $[0, 1]$. Prilikom vrednovanja, realni vektori prevedeni su u binarne vektore b_i , čije se komponente određuju prema izrazu

$$b^j = \begin{cases} 1, & \text{ako } sol^j \geq 0.5, \\ 0, & \text{inače,} \end{cases} \quad (4.7)$$

a slikom 4.4 prikazan spomenuti način kodiranja rješenja.

	sol_1	sol_2	sol_3	sol_4	sol_5	sol_6	sol_7	sol_8	sol_9	sol_{10}
sol_i	0.44	0.57	0.75	0.21	0.05	0.89	0.95	0.37	0.64	0.71
	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
b_i	0	1	1	0	0	1	1	0	1	1

Slika 4.4: Prikaz kodiranog rješenja unutar populacije za potrebe odabira značajki

Prilikom svake pretrage svakom omotaču dozvoljeno je najviše $NFE_{max} = 10^3$ vrednovanja funkcije cilja. Ova je vrijednost odabrana da bi se broj vrednovanja funkcije cilja, što predstavlja računalno zahtjevan zadatak, sveo na razumnu razinu. Parametri algoritama postavljeni su prema često odabranim vrijednostima iz literature te prema preliminarnoj eksperimentalnoj analizi, a dani su u tablici 4.2. Za sve ugrađene postupke pretraga je vođena mjerom F1, dok je kao omotač korišten algoritam kNN , gdje je $k = 1$.

Tablica 4.2: Postavke parametara pri testiranju ftFS

Alg.	Korištene vrijednosti parametara
ABC	$PS = 30, limit = 50$
PSO	$PS = 30, c_1 = c_2 = 1.496, \omega = 0.7298$
FFA	$PS = 30, \alpha = 0.5, \gamma = 1, \delta = 0.99, \beta_0 = 0.2$
MRABC	$PS = 30, mr = 0.5, limit = 50$
MBPSO	$PS = 30, c_1 = c_2 = 1.496, \omega = 0.7298$

4.4.2 Detalji ugradnje

U svrhu provođenja eksperimentalne analize ostvareno je programsko rješenje u programskom jeziku C#. Ugrađeni su različiti opisani omotači, a u njima je ugrađeno predloženo unaprjeđenje opisano u potpoglavlju 4.3.2. Bilježenje uključenih i isključenih značajki u najboljim, odnosno najlošijim rješenjima odvijalo se ovisno o algoritmu pretrage u koje je ugrađeno, s obzirom na način izmjene i zamjene rješenja u održavanoj populaciji svakog od algoritama.

Algoritam ABC i njegove izvedenice provode pretragu u tri odvojene faze. Prve dvije mijenjaju dio rješenja i u slučaju da je izmijenjeno rješenje bolje, ono zamjenjuje postojeće. Treća faza zamjenjuje iscrpljeno rješenje nasumičnim. Ugradnja u ovaj tip omotača ostvarena je tako da se bilježe značajke prilikom generiranja izmijenjenih rješenja tijekom prve dvije faze, bez obzira je li došlo do zamjene postojećeg rješenja ili ne. Algoritam PSO i algoritmi koji predstavljaju njegove nadogradnje provode pretragu tako da usmjeravaju postojeća rješenja ka najboljim prošlim položajima u prostoru te najboljem dosad pronađenom rješenju. Za takve je algoritme praćena trenutna populacija stvorenih rješenja. Kod algoritma krijesnica rješenja se stvaraju tako da se rješenje pomiče prema drugim rješenjima unutar populacije, ako su ona bolja od trenutnog rješenja. Ukoliko novo rješenje pruža bolju kvalitetu, ono zamjenjuje postojeće. Kod ovog algoritma također je bilježeno stanje značajki svih generiranih kandidata, bez obzira jesu li zamijenili postojeće ili nisu. Osim onoga što je praćeno, važan je i trenutak u kojem se odvija praćenje stanja značajki. Odabrana je vrijednost da se za svaki algoritam praćenje obavlja nakon $\omega = PS$ vrednovanja funkcije cilja, a prikaz ugradnje postupka dan je algoritmom 2.

Algoritam 2 Implementacija predloženog unaprjeđenja ftFS

```

while  $NFE_{spent} < NFE_{max}$  do
  ...
  Generiraj rješenje kandidata  $cs$ ;
   $A = A \cup cs$ ;
  if  $|A| = PS$  then
    Zabilježi  $b_{bst(-)}, b_{bst(+)}, b_{wst(-)}$  i  $b_{wst(+)}$ ;
     $A = \emptyset$ ;
  end if
end while

```

4.4.3 Ponašanje ftFS-a u odnosu na prilagođene omotače na podatkovnom skupu boli

Predloženo unaprjeđenje uvelike se oslanja na tijek pretrage postojećeg omotača. Nakon završetka pretrage, konačno rješenje koje je dao originalni omotač i korigirano rješenje koje je rezultat djelovanja predložene unaprijeđene metode, uspoređeni su na zasebnom podatkovnom skupu. S obzirom na broj ponavljanja, ostvareni rezultati daju uvid u prednosti i nedostatke predloženog unaprjeđenja. Važno je napomenuti da predloženo unaprjeđenje, odnosno njegovi rezultati, u svim provedenim eksperimentima nosi oznaku ftFS (engl. *feature tracking Feature Selection*, praćenje značajki tijekom odabira značajki). Iako se detalji ugradnje mogu ponešto razlikovati ovisno o omotaču u koje se ugrađuje, koncept rada i namjera se ne mijenjaju pa stoga niti oznaka.


Prvi skup rezultata ostvaren je uporabom algoritma FFA, predloženog u [96] u svrhu smanjenja broja značajki. Ostvarena kvaliteta klasifikacije temeljem smanjenih vektora značajki dana je u obliku više različitih mjera kvalitete tablicom 4.3.

Tablica 4.3: Performanse odabira značajki predloženog unaprjeđenja u odnosu na algoritam krijesnica

Skup	\mathcal{D}_0		\mathcal{D}_1		\mathcal{D}_2		\mathcal{D}_3	
	FFA	ftFS	FFA	ftFS	FFA	ftFS	FFA	ftFS
Acc	0.9155	0.9162	0.9239	0.9268	0.8945	0.8928	0.8914	0.8932
FMsr	0.9150	0.9159	0.9239	0.9267	0.8947	0.8930	0.8909	0.8926
Pre	0.9193	0.9204	0.9282	0.9313	0.9000	0.8985	0.8931	0.8942
Rec	0.9155	0.9162	0.9239	0.9268	0.8945	0.8928	0.8914	0.8932
κ	0.8731	0.8741	0.8860	0.8903	0.8419	0.8393	0.8372	0.8398
Vel.	246.68	227.28	244.16	223.88	245.80	223.84	245.68	222.96

Tablicom su prikazani prosječni rezultati za svaki od podatkovnih skupova bolnih izraza lica, od \mathcal{D}_0 do \mathcal{D}_3 , kako za osnovni omotač, tako i za predloženo unaprjeđenje ftFS, ugrađeno u dani omotač. Ostvareni rezultati sugeriraju da je predloženo unaprjeđenje dovelo do poboljšanja u odnosu na osnovni algoritam. To je posebice izraženo kod broja značajki uključenih u konačno rješenje, kao što je vidljivo u tablici 4.3 pod „Vel.”, gdje je dana veličina, odnosno dimenzionalnost smanjenog vektora značajki. Naime, predloženo unaprjeđenje smanjilo je u prosjeku dimenzionalnost vektora značajki za nešto manje od 10% u prosjeku. To je ostvareno na svim podatkovnim skupovima boli. Nadalje, spomenuto smanjenje dimenzionalnosti nije imalo negativan učinak na kvalitetu rezultata. Odnosno, ona je zadržana ili povećana na većini podatkovnih skupova. U tom smislu posebno je zanimljivo razmotriti mjeru F1 kojom je vođena pretraga za konačnim rješenjem. Predloženo unaprjeđenje dovelo je do poboljšanja prosječne vrijednosti mjere F1 kod većine razmatranih podatkovnih skupova. Ono je ostvareno povećanjem preciznosti i odziva, što sugerira da nije narušavan niti jedan od navedenih pokazatelja kako bi se zadržala, odnosno uvećala mjera F1. Da bi se dobio dublji uvid u ostvarene rezultate, razdioba ostvarenih iznosa mjera F1 dana je slikom 4.5, a razdioba ostvarenih dimenzionalnosti vektora slikom 4.6.

Ako se promotri sliku 4.5, uočljivo je da je kvaliteta klasifikacije prema mjeri F1 zadržana u odnosu na osnovni pristup, što se očituje u medijanu ove mjere. Prednost ftFS-a u odnosu na osnovni pristup iskazana u tablici 4.3, proizlazi iz činjenice da rjeđe pronalazi rješenja niže kvalitete. To se vidi iz prvog kvartila, kao i položaja donjeg brka koji predstavlja najlošije pronađeno rješenje. Također, u većini slučajeva najbolje pronađeno rješenje više je kvalitete od onog danog osnovnim pristupom. Što se tiče broja uključenih značajki, slika 4.6 odražava odnos među rješenjem osnovnog omotača i predloženog unaprjeđenja ugrađenog u isti. Očigledno je da predloženo unaprjeđenje bez iznimke dovodi do uključivanja manjeg broja značajki. Navedeno smanjenje ogleđa se kod svih podatkovnih skupova, a nije rijetkost da je treći kvartil kod predloženog unaprjeđenja niži nego prva kod osnovnog omotača. Kada se navedeno uzme u obzir u kontekstu zadržavanja ili uvećanja kvalitete klasifikacije, neminovno se dolazi do zaključka da predloženo unaprjeđenje pruža bolji način odabira značajki u odnosu na osnovni pristup.



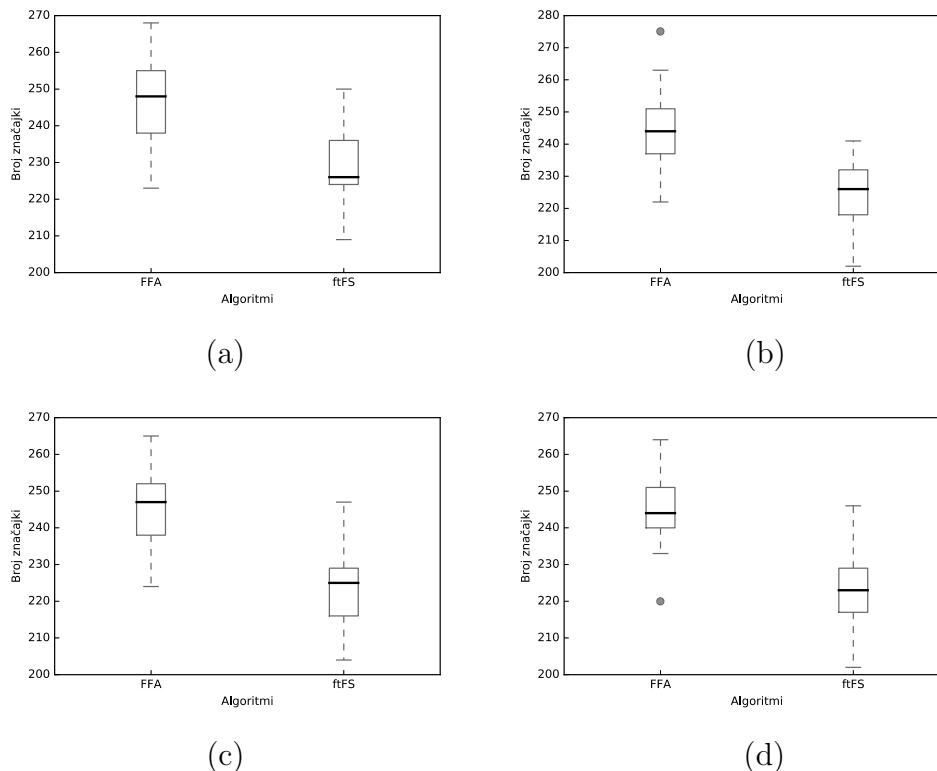
Slika 4.5: Usporedba performansi uporabom algoritma krijesnica u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

Vrednovanje predloženog izvornog znanstvenog doprinosa nastavljena je ugradnjom unaprjeđenja u izmijenjeni binarni PSO. On je, za potrebe smanjenja dimenzionalnosti kod problema klasifikacije neželjene poruka elektroničke pošte predložen u [97]. Kao i u slučaju prethodnog omotača, performanse su najprije dane tablicom 4.4.

Tablica 4.4: Performanse odabira značajki predložene metode u odnosu na izmijenjeni binarni algoritam optimizacije rojem čestica

Skup	\mathcal{D}_0		\mathcal{D}_1		\mathcal{D}_2		\mathcal{D}_3	
	MBPSO	ftFS	MBPSO	ftFS	MBPSO	ftFS	MBPSO	ftFS
Acc	0.9166	0.9217	0.9236	0.9279	0.8921	0.8948	0.8846	0.8964
FMsr	0.9163	0.9216	0.9235	0.9278	0.8924	0.8951	0.8842	0.8960
Pre	0.9204	0.9252	0.9271	0.9317	0.8987	0.9007	0.8857	0.8971
Rec	0.9166	0.9217	0.9236	0.9279	0.8921	0.8948	0.8846	0.8964
κ	0.8746	0.8824	0.8854	0.8919	0.8383	0.8424	0.8270	0.8446
Vel.	242.96	229.44	243.84	224.00	247.64	223.48	244.60	226.64

Iz tablice 4.4 lako su uočljive prednosti ftFS-a. Odnos među brojem značajki koje pronalazi originalni omotač MBPSO te brojem značajki koje nudi ftFS, sličan je kao i u slučaju prethodno korištenog algoritma FFA. Ponovno je riječ o smanjenju od desetak posto u korist ftFS-a. Što se tiče kvalitete rezultata, za sve podatkovne skupove došlo je do unaprjeđenja kvalitete u smislu svih razmatranih pokazatelja. Također, kod mjere F1 ponovno su unaprijeđeni i preciznost i osjetljivost. Ostvareni rezultati sugeriraju stabilnost predloženog




Slika 4.6: Usporedba dimenzionalnosti problema uporabom algoritma krijesnica u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

unaprjeđenja. Ona se ogleda u opetovanom postizanju bolje razine rezultata u pogledu kvalitete uz osjetno niži broj korištenih značajki. Detaljniji uvid u razdiobu rezultata može se dobiti na temelju dijagrama pravokutnika predstavljenih slikom 4.7, za performanse u smislu mjere F1, te slikom 4.8 za dimenzionalnost, odnosno broj uključenih značajki.

Kao što je vidljivo iz dijagrama pravokutnika, medijani mjere F1 jednaki su ili viši za ftFS. Isto se može reći i za najbolje pronađene podskupove značajki u većini slučajeva. Također, najlošiji pronađeni podskupovi u slučaju ftFS-a u većini slučajeva imaju višu kvalitetu nego najlošiji pronađeni podskupovi kod osnovnog omotača. Posebice je zanimljivo promotriti položaje prvog i trećeg kvartila, jer u svim slučajevima su oni više za pristup ftFS. Sve navedeno ukazuje da predloženo unaprjeđenje dovodi do boljih rezultata u odnosu na osnovni pristup. Razmatranjem dijagrama pravokutnika za dimenzionalnost vektora značajki moguće je doći do istog zaključka. U slučaju svih podatkovnih skupova uključenih u eksperiment, pristup ftFS ostvario je osjetno nižu dimenzionalnost. Rečeno se odnosi, kako na medijan, tako i na sve ostale pokazatelje. Također, moguće je doći do zaključka da i u slučaju drugačijeg tipa omotača predloženi pristup ftFS zadržava pozitivna svojstva, odnosno ostvaruje jednaku ili višu kvalitetu rezultata klasifikacije, koristeći pritom osjetno niži broj značajki.

Dodatni omotač u koji je ugrađeno predloženo unaprjeđenje zasnovan je na algoritmu umjetne kolonije pčela u koji je, radi boljeg ponašanja na problemima visoke dimenzionalnosti, uve-




Slika 4.7: Usporedba performansi uporabom algoritma izmijenjene binarne optimizacije rojem čestica u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

dena stopa izmjene [111]. Rezultati predloženog unaprjeđenja u odnosu na ovaj omotač u vidu različitih pokazatelja kvalitete klasifikacije dani su tablicom 4.5.

Tablica 4.5: Performanse odabira značajki predložene metode u odnosu na izmijenjeni algoritam umjetne kolonije pčela

Skup	\mathcal{D}_0		\mathcal{D}_1		\mathcal{D}_2		\mathcal{D}_3	
	MRABC	ftFS	MRABC	ftFS	MRABC	ftFS	MRABC	ftFS
Acc	0.9166	0.9200	0.9214	0.9254	0.8917	0.8952	0.8907	0.9000
FMsr	0.9162	0.9197	0.9214	0.9253	0.8919	0.8952	0.8902	0.8998
Pre	0.9202	0.9233	0.9254	0.9302	0.8978	0.9009	0.8919	0.9015
Rec	0.9166	0.9200	0.9214	0.9254	0.8917	0.8952	0.8907	0.9000
κ	0.8747	0.8798	0.8822	0.8881	0.8378	0.8429	0.8361	0.8500
Vel.	247.12	238.44	250.88	233.76	241.36	233.84	247.48	236.40

Ponašanje utvrđeno kod ranijih omotača ponavlja se i kod MRABC-a, bez obzira na razlike među načinima rada i svojstvima pretrage koje postoje među omotačima. Smanjenje broja značajki, iako blaže izraženo nego kod ostalih omotača, prisutno je i lako uočljivo i u ovom slučaju. Bez obzira na smanjenje, zadržana je ili unaprijeđena i kvaliteta ostvarenih rezultata u vidu svih prikazanih pokazatelja, neovisno o korištenom podatkovnom skupu. Za daljnje razmatranje, detaljniji prikaz raspodjele rezultata u pogledu mjere F1, odnosno u pogledu dimenzionalnosti vektora značajki, moguće je pronaći na dijagramima pravokutnika prikazanim slikama 4.9 i 4.10.



Slika 4.8: Usporedba dimenzionalnosti problema uporabom algoritma izmijenjene binarne optimizacije rojem čestica u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3


Uočljivo je iz dijagrama pravokutnika da kvaliteta rezultata u smislu mjere F1 ide u korist ftFS-a. Ostvareni medijani mahom su veći nego što je to slučaj za rješenja koja je ponudio MRABC. Uz navedeno, uočljivo je da je kvaliteta u većini slučajeva najboljeg, odnosno najlošijeg rješenja viša za ftFS, a također se isto može reći za prvi i treći kvartil. Posebice je zanimljivo primijetiti da je u slučajevima \mathcal{D}_1 i \mathcal{D}_3 najlošije rješenje koje je dao ftFS u razini prvog kvartila MRABC-a. Navedeno ponašanje u pogledu kvalitete ponovno je popratio i manji broj značajki unutar rješenja. Za sve podatkovne skupove svi pokazatelji pravokutnog dijagrama u tom pogledu idu u korist ftFS metode.

S obzirom na prikazane rezultate ostvarene prilikom ugradnje predloženog unaprjeđenja u omotače različitih svojstava, može se zaključiti da predloženo unaprjeđenje poboljšava svojstva odabranih vektora značajki što i jest cilj drugog predloženog izvornog znanstvenog doprinosa. Naime, dimenzionalnost rješenja s ugrađenim ftFS-om u pravilu je osjetno niža u odnosu na rješenja koje nudi osnovni omotač. Ova pojava neovisna je o korištenom omotaču, s obzirom na različit način pretrage omotača uključenih u eksperimentalnu analizu što sugerira stabilnost u ponašanju. Ostvareno smanjenje dimenzionalnosti problema time je značajnije, jer ne dovodi do narušavanja performansi klasifikacije. Štoviše, u većini je slučajeva predloženo rješenje dovelo do unaprjeđenja kvalitete klasifikacije u pogledu svih prikazanih mjera.


4.4.4 Ponašanje ftFS-a u odnosu na osnovne inačice omotača na podatkovnom skupu boli

U prvom dijelu eksperimentalne analize predloženog drugog izvornog znanstvenog doprinosa razmatrani su njegovi učinci kod ugradnje u prirodno inspirirane algoritme optimizacije na određen način prilagođene problemu smanjenja dimenzionalnosti. Zanimljivo je također razmotriti i utjecaj unaprjeđenja na omotače koji predstavljaju osnovne inačice algoritama korištenih u prvom dijelu analize. U tu su svrhu odabrana i ugrađena dva osnovna algoritma. Konkretno, algoritam umjetne kolonije pčela (ABC) kao osnovna inačica MRABC-a te algoritam optimizacije rojem čestica (PSO) kao osnovna inačica MBPSO-a. U ove osnovne inačice ugrađeno je predloženo unaprjeđenje te performanse vrednovane na jednak način kao u prethodnom poglavlju. Najprije je predloženo rješenje ugrađeno u ABC, a ponašanje izvornog omotača kao i omotača s ugrađenim unaprjeđenjem dano je tablicom 4.6.

Ponovno se vidi smanjen broj korištenih značajki koji je prisutno kod svih razmatranih podatkovnih skupova. On je u slučaju primjene ABC-a kao osnovnog omotača slabije izražen nego u ranijim slučajevima. Također, uočava se da je ugradnja unaprjeđenja u dijelu slučajeva u manjoj mjeri narušila performanse klasifikacije. Naime, za prva dva podatkovna skupa, ugradnja ftFS-a dovela je do boljih rezultata, dok su za posljednja dva skupa rezul-



Slika 4.9: Usporedba performansi uporabom algoritma izmijenjene umjetne kolonije pčela u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3




Slika 4.10: Usporedba dimenzionalnosti problema uporabom algoritma izmijenjene umjetne kolonije pčela u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

Tablica 4.6: Performanse odabira značajki predložene metode u odnosu na algoritam umjetne kolonije pčela

Skup	\mathcal{D}_0		\mathcal{D}_1		\mathcal{D}_2		\mathcal{D}_3	
	ABC	ftFS	ABC	ftFS	ABC	ftFS	ABC	ftFS
Acc	0.9176	0.9193	0.9229	0.9268	0.9000	0.8931	0.8932	0.8871
FMsr	0.9172	0.9190	0.9228	0.9268	0.9003	0.8934	0.8926	0.8866
Pre	0.9210	0.9226	0.9270	0.9307	0.9053	0.8987	0.8941	0.8884
Rec	0.9176	0.9193	0.9229	0.9268	0.9000	0.8931	0.8932	0.8871
κ	0.8762	0.8788	0.8844	0.8903	0.8502	0.8398	0.8398	0.8308
Vel.	247.52	239.12	243.96	236.84	245.24	237.20	247.96	237.80

tati blago lošiji nego za osnovni algoritma. Radi utvrđivanja razloga tog ponašanja, te s ciljem boljeg uvida u rezultate, njihova je razdioba ponovno prikazana uporabom dijagrama pravokutnika slikama 4.11 i 4.12.


Kod primjene algoritma ABC, vidljivo je da u slučaju prva dva podatkovna skupa primjena predložene metode ftFS ima smisla, s obzirom da se kvaliteta rezultata povećava. To je vidljivo iz viših medijana mjere F1 te istih ili viših performansi najboljeg pronađenog rješenja (izuzevši sumnjive vrijednosti). Problematično ponašanje uočljivo je kod posljednja dva skupa, poglavito za \mathcal{D}_2 . Naime, u ovom slučaju kvaliteta u smislu medijana i najboljeg rješenja slabija je od osnovnog pristupa, iako je čak i ovdje najlošije rješenje više kvalitete nego najlošije rješenje koje je ponudila inačica omotača bez ugrađenog unaprjeđenja. Što se



Slika 4.11: Usporedba performansi uporabom algoritma umjetne kolonije pčela u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

tiče broja značajki, trend smanjenja broja značajki i dalje je vidljiv. Pronađena rješenja metodom ftFS u pravilu su manje dimenzionalnosti u odnosu na rješenja koja je ponudio ABC, iako je ova razlika manje izražena nego u usporedbi s drugim metodama. Spomenuta ograničenja otežavaju preporuku ugradnje predloženog unaprjeđenja ako se koristi kao omotač osnovna inačica ABC-a. Razloge slabije mogućnosti unaprjeđenja rješenja ostvarenog osnovnim omotačem treba tražiti upravo u načinu pretrage i načinu praćenja stanja pretrage. Ovaj omotač radi vrlo male izmjene na članovima populacije prilikom pretrage. Riječ je o izmjeni samo jedne komponente unutar cijelog rješenja. S obzirom na izrazito visoku dimenzionalnost problema, lako je moguće da su generirana rješenja vrlo slična već postojećima, što dakako smanjuje bazen dostupnih rješenja na temelju kojih se prate doprinosi pojedinih značajki. S obzirom da rješenja koja je predložio ABC ne zaostaju za rješenjima ostalih pristupa uključenih u analizu (iako ih nije moguće izravno uspoređivati), za pretpostaviti je da je izvor ovakvog ponašanja unaprjeđenja upravo u opisanom načinu pretrage.

Konačno, predloženo unaprjeđenje ugrađeno je u algoritam optimizacije rojem čestica, a rezultati su predstavljeni tablicom 4.7. Prednosti ftFS-a ostvarene na prethodno korištenim omotačima i dalje su prisutne. To se ponajprije ogleda u broju korištenih značajki, koji je ponovno osjetno manji nego kod osnovnog pristupa. U ovom slučaju, ta je razlika značajnija nego kod osnovnog ABC omotača.




Slika 4.12: Usporedba dimenzionalnosti problema uporabom algoritma umjetne kolonije pčela u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

Tablica 4.7: Performanse odabira značajki predložene metode u odnosu na algoritam optimizacije rojem čestica

Skup	\mathcal{D}_0		\mathcal{D}_1		\mathcal{D}_2		\mathcal{D}_3	
	PSO	ftFS	PSO	ftFS	PSO	ftFS	PSO	ftFS
Acc	0.9189	0.9169	0.9239	0.9246	0.9007	0.8958	0.8889	0.8896
FMsr	0.9187	0.9167	0.9239	0.9245	0.9009	0.8961	0.8885	0.8893
Pre	0.9231	0.9214	0.9284	0.9291	0.9056	0.9007	0.8909	0.8914
Rec	0.9190	0.9169	0.9239	0.9246	0.9007	0.8959	0.8889	0.8896
κ	0.8783	0.8751	0.8860	0.8871	0.8512	0.8439	0.8335	0.8345
Vel.	247.48	217.52	243.32	213.32	243.56	214.88	245.76	216.52

Što se tiče kvalitete klasifikacije, iako se čini da je ona narušena, potrebno je pogledati razdiobu rezultata prikazanu slikom 4.13 za uvid u kvalitetu rješenja, odnosno slikom 4.14 za uvid u dimenzionalnost vektora značajki. Medijani mjere F1 u većini slučajeva su viši u slučaju ugradnje unaprjeđenja, dok su najbolja rješenja iskazala jednaku ili bolju kvalitetu. Kada se u obzir uzmu vektori značajki kojima su navedene performanse klasifikacije ostvarene, može se reći da je predloženo unaprjeđenje u prednosti.

Ugradnja unaprjeđenja u osnovne algoritme ukazala je na određene detalje o kojima je važno povesti računa prilikom njegove uporabe. Metoda ftFS, kao i u prethodnim slučajevima, iskazala je dobro ponašanje u smislu broja značajki. Bez iznimke su pronađena rješenja koja u odnosu na osnovni omotač, bez ugrađenog rješenja, imaju nižu dimenzionalnost.

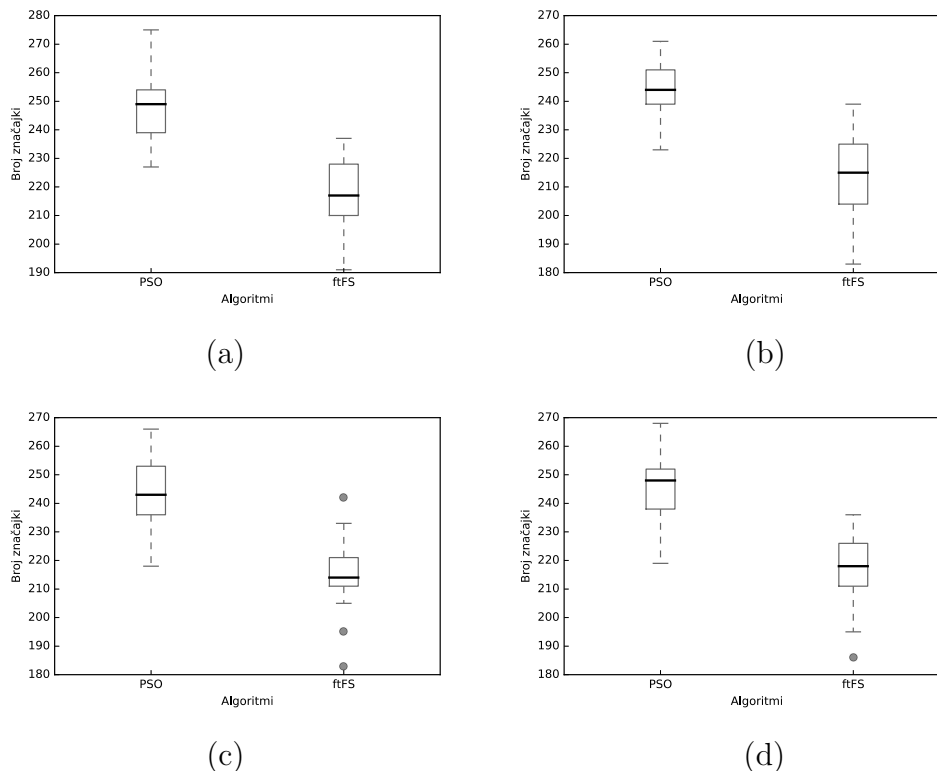


Slika 4.13: Usporedba performansi uporabom algoritma optimizacije rojem čestica u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

Pri tom je kvaliteta rješenja u većini slučajeva povećana ili barem očuvana. U tom smislu zamjetne su određene poteškoće prilikom korištenja osnovne inačice algoritma ABC. Budući da se predloženo unaprjeđenje uvelike oslanja na raznovrsnost pretrage te rješenja visoke kvalitete koja pritom nastaju, izostanak raznolikosti može potencijalno dovesti do problema u trenutku odluke o uključivanju značajki. Ipak, važno je napomenuti da mehanizam za korekciju koji koristi predloženo unaprjeđenje ne koristi dodatna vrednovanja funkcije cilja niti narušava ponašanje osnovnog omotača. Tako je moguće jednom pretragom doći do dva različita prijedloga rješenja te eventualnom naknadnom analizom utvrditi koje je od njih prikladnije.

4.4.5 Ponašanje ftFS-a na standardnim skupovima podataka

U svrhu daljnje provjere opravdanosti predloženog unaprjeđenja, ono je iskorišteno za odabir značajki kod smanjenja dimenzionalnosti podatkovnih skupova nastalih u različitim domena i vezanim uz različite probleme, poput primjerice raspoznavanja materijala na slici ili dijagnosticiranja kožnih bolesti i drugih. Riječ je o javno dostupnim podacima na repozitoriju za strojno učenje sveučilišta Irvine u Kaliforniji [112], koji se često rabe u svrhu vrednovanja postupaka strojnog učenja. Ponašanje omotača predstavljenih u potpoglavlju



Slika 4.14: Usporedba dimenzionalnosti problema uporabom algoritma optimizacije rojem čestica u smislu broja značajki za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

4.2.1 te istih omotača s ugrađenim unaprjeđenjem uspoređeno je na nekoliko odabranih podatkovnih skupova različitih karakteristika. Karakteristike podatkovnih skupova dane su tablicom 4.8, dok su skupovi poblizje opisani u prilogu A. Metodologija provedbe eksperimenata i usporedbe rezultata jednaka je kao i ranije.

Tablica 4.8: Korišteni podatkovni skupovi s UCI repozitorija za strojno učenje

Oznaka	Naziv	# instanci	# značajki	# klasa
\mathcal{U}_1	Climate	540	18	2
\mathcal{U}_2	Dermatology	358	34	6
\mathcal{U}_3	Imageseg	210	19	7
\mathcal{U}_4	Ionosphere	351	34	2
\mathcal{U}_5	Libras	360	90	15
\mathcal{U}_6	Mesothelioma	324	34	2
\mathcal{U}_7	MuskV1	476	166	2
\mathcal{U}_8	UrbanLand	675	147	9
\mathcal{U}_9	Voice	126	310	2
\mathcal{U}_{10}	Wine	178	13	3

Performanse osnovnih inačica omotača te istih omotača s ugrađenim unaprjeđenjem dani su u obliku mjere F1 tablicom 4.9, dok je za dane rezultate prosječna dimenzionalnost vektora dana tablicom 4.10. Ponašanje unaprjeđenja već na prvi pogled iskazuje stabilnost, s obzirom da uspijeva u pravilu unaprijediti kvalitetu rezultata, čineći to većinom uz primjenu nižeg broja značajki. Posebnu pažnju pritom je potrebno usmjeriti na podatkovne skupove nešto više dimenzionalnosti, poput primjerice skupova od \mathcal{U}_7 do \mathcal{U}_9 . Kod ovakvih skupova

ostvareno je uočljivo povećanje performansi, a pritom su korišteni vektori značajki niže dimenzionalnosti. Navedeno ukazuje da predloženo unaprjeđenje uspijeva pronaći ključne značajke.

Tablica 4.9: Performanse osnovnih i inačica omotača u obliku prosjeka mjere F1 s ugrađenim unaprjeđenjem na standardnim skupovima podataka

Skup	FFA		MRABC		MBPSO	
	FFA	ftFS	MRABC	ftFS	MBPSO	ftFS
\mathcal{U}_1	0.8894	0.8965	0.8892	0.9043	0.8862	0.9049
\mathcal{U}_2	0.9557	0.9646	0.9497	0.9630	0.9570	0.9778
\mathcal{U}_3	0.8221	0.8616	0.8229	0.8469	0.8433	0.8591
\mathcal{U}_4	0.9267	0.9334	0.9219	0.9213	0.9337	0.9356
\mathcal{U}_5	0.8450	0.8435	0.8373	0.8479	0.8433	0.8488
\mathcal{U}_6	0.9950	0.9988	0.9963	0.9994	0.9949	1.0000
\mathcal{U}_7	0.8405	0.8435	0.8414	0.8490	0.8446	0.8471
\mathcal{U}_8	0.7878	0.8043	0.7885	0.7920	0.7877	0.8040
\mathcal{U}_9	0.7779	0.8136	0.7764	0.8168	0.7650	0.8223
\mathcal{U}_{10}	0.9460	0.9746	0.9455	0.9665	0.9655	0.9735


Tablica 4.10: Prosječna dimenzionalnost vektora značajki kod osnovnih i inačica omotača s ugrađenim unaprjeđenjem na standardnim skupovima podataka

Skup	FFA		MRABC		MBPSO	
	FFA	ftFS	MRABC	ftFS	MBPSO	ftFS
\mathcal{U}_1	9.48	8.96	9.64	9.20	9.28	8.52
\mathcal{U}_2	19.48	24.20	19.24	20.36	21.12	24.60
\mathcal{U}_3	8.36	10.12	9.32	10.80	8.04	10.40
\mathcal{U}_4	15.20	13.16	15.04	15.20	15.32	12.88
\mathcal{U}_5	44.28	44.92	46.04	46.92	46.36	44.64
\mathcal{U}_6	15.64	12.96	15.32	15.76	14.60	11.32
\mathcal{U}_7	83.04	78.12	84.52	83.28	84.12	82.52
\mathcal{U}_8	70.40	69.32	71.76	72.68	72.84	70.28
\mathcal{U}_9	154.28	137.96	155.80	150.28	154.24	142.12
\mathcal{U}_{10}	7.24	10.08	7.68	9.40	8.28	10.48


Ako se, s druge strane, razmotre situacije u kojima je predloženo rješenje dovelo do uvećanja broja značajki, kao što je to slučaj s \mathcal{U}_{10} ili \mathcal{U}_2 , primjetno je opet uvećanje kvalitete. Ovakvo ponašanje sugerira ostvarivanje cilja zacrtanog kod prijedloga unaprjeđenja, odnosno da ono ne smanjuje broj značajki na račun smanjenja kvalitete, već pokušava pronaći značajke koje su ključne za dani problem. Te značajke posljedično bi trebale dovesti do održanja ili povećanja performansi klasifikacije. Razlike u performansama održane su neovisno o korištenom osnovnom omotaču, izuzev nekolicine skupova kada predloženo unaprjeđenje nije dovelo do poboljšanja rezultata, primjerice \mathcal{U}_5 za FFA. Ipak, takve su situacije rijetke. Što se tiče broja korištenih značajki, kod uporabe algoritma MRABC kao osnovnog omotača, uočljiv je izostanak dodatnog smanjenja dimenzionalnosti, osim za dva skupa najveće dimenzionalnosti koji su uključeni u usporedbu, a to su \mathcal{U}_7 i \mathcal{U}_9 .

Rezultati dani tablicama 4.9 i 4.10 ilustrirani su slikama 4.15, 4.16 i 4.17 za svaku od osnovnih metoda omotača. Na slikama su razlike među ostvarenim rezultatima vidljive, kao i broj rabljenih značajki za svaki od podatkovnih skupova. Kao što je ranije i rečeno, razlike


u kvaliteti zadržane su neovisno o odabiru osnovnog omotača, dok je smanjenje u odnosu na osnovni pristup najslabije izraženo kod metode MRABC. Važno je napomenuti da je umanjeње vidljivo kod podatkovnih skupova najviše dimenzionalnosti.



Slika 4.15: Usporedba performansi klasifikacije na različitim standardnim problemima za FFA i isti algoritam s ugrađenim unaprjeđenjem u smislu (a) mjere F1, (b) broja značajki



Slika 4.16: Usporedba performansi klasifikacije na različitim standardnim problemima za MRABC i isti algoritam s ugrađenim unaprjeđenjem u smislu (a) mjere F1, (b) broja značajki




Slika 4.17: Usporedba performansi klasifikacije na različitim standardnim problemima za MBPSO i isti algoritam s ugrađenim unaprjeđenjem u smislu (a) mjere F1, (b) broja značajki

4.5 Osvrt na predloženu metodu

Odabir značajki koje će se rabiti prilikom klasifikacije uobičajen je, a često i važan korak u pripremi podatkovnog skupa. Njime je moguće djelomično ispraviti probleme koji su se možebitno dogodili prilikom koraka prikupljanja podataka ili izdvajanja značajki. Dva su cilja kod obavljanja ovog koraka prilikom klasifikacijske procedure. Prvi korak je smanjenje dimenzionalnosti problema s namjerom olakšavanja izgradnje klasifikacijskog modela, dok je drugi uklanjanje značajki koje imaju štetno djelovanje na određivanje klase uzorka. Kao drugi izvorni znanstveni doprinos, s navedenim ciljevima u vidu, predložena je unaprijeđena metoda koja se oslanja na praćenje doprinosa pojedinih značajki. Doprinos se pokušava pratiti tijekom pretrage za najboljim podskupom značajki uporabom omotača. Na temelju određivanja doprinosa pokušava se odrediti najvažnije značajke koje su često uključene u dobra, kao i one koje su često uključene u loša rješenja. Predstavljeno je nekoliko uspješnih omotača koji se oslanjaju na različite prirodno inspirirane algoritme, primijenjenih za različite probleme u literaturi. Predložena unaprijeđena metoda ugrađena je u svaki od njih. Usporednom eksperimentalnom analizom i vrednovanjem rezultata klasifikacije na problemu određivanja razine boli, utvrđeno je da predložena unaprijeđena metoda iskazuje povoljna svojstva, u smislu smanjenja broja značajki.

Na podatkovnom skupu bolnih izraza lica predloženo je unaprjeđenje u pravilu dovelo do smanjenja broja korištenih značajki u odnosu na osnovnu korištenu metodu omotača. Navedeno je posebice značajno ako se uzme u obzir činjenica da je predložena metoda mogla učiti isključivo na podacima koje je stvorio i sam koristio osnovni omotač. Također, uporaba opisanog unaprjeđenja u pravilu je očuvala ili čak i unaprijedila performanse klasifikacije. Nadalje, analizom ponašanja predloženog unaprjeđenja na različitim podatkovnim skupovima proizašlim iz drugih domena, utvrđeno je da su povoljna svojstva iskazana na podatkovnom skupu boli očuvana i prenešena na druge probleme. To ukazuje na stabilnost predloženog unaprjeđenja prilikom stvaranja konačnog rješenja. Naime, predložena metoda ponudila je vektore značajki koji su u pravilu ostvarivali bolje rezultate klasifikacije, dok su istovremeno u većini slučajeva ti vektori bili niže dimenzionalnosti. Da bi se dobio bolji uvid u složenost problema odabira značajki, slikom 4.18 prikazan je korišteni broj vrednovanja kvalitete rješenja, u odnosu na broj koji bi bio potreban da bi se svaki mogući podskup značajki vrednovao. Dani odnos prikazan je za probleme koji imaju 15 ili manje značajki. Već je ovdje uočljivo kako porastom broja značajki eksponencijalno raste broj nužnih vrednovanja potrebnih za iscrpnu pretragu. Ako se u obzir uzme da osnovni omotači ostvaruju dobre, a po mjerama kvalitete i slične rezultate, da su razmatrani problemi vrlo visoke dimenzionalnosti (od \mathcal{D}_1 do \mathcal{D}_4 , od \mathcal{U}_7 do \mathcal{U}_9), a da je pri tome predloženo unaprjeđenje u pravilu dovelo do vektora značajki iste ili bolje kvalitete te niže dimenzionalnosti, može se zaključiti da je njegova ugradnja opravdana. Uz to, važno je napomenuti da ugradnja unaprjeđenja ne

utječe na složenost pretrage, s obzirom da praćenje doprinosa značajki ne zahtijeva dodatno vrednovanje, što vrijedi i za konačno dobiveno rješenje. Provedeno eksperimentalno vrednovanje i predstavljeni rezultati sugeriraju da je drugi predloženi izvorni znanstveni doprinos ostvaren.



Slika 4.18: Prikaz odnosa dopuštenog (korištenog) broja vrednovanja kvalitete rješenja u odnosu na broj potreban za iscrpnu pretragu

Predloženi pristup uvelike ovisi o tijeku pretrage i rješenjima koja će generirati osnovni omotač. S obzirom na to, bitno je odabrati pristupe koji nude raznolika rješenja i dobru mogućnost, kako istraživanja prostora pretrage, tako i iskorištavanja pronađenih rješenja. Navedeno se ogleda u ponašanju unaprjeđenja prilikom ugradnje u osnovni ABC te u njegovu inačicu prilagođenu problemima više dimenzionalnosti, MRABC. Kod prvog je unaprjeđenje imalo probleme jer su izmjene napravljene na pojedinim rješenjima vrlo male, a problem koji se rješava bio je više dimenzionalnosti. Kod unaprijeđene inačice, prilagodba koja je uključila značajnije izmjene na rješenjima, dovela je do lakšeg praćenja doprinosa, a samim tim i do uspješnijeg rada predloženog unaprjeđenja. Kao mogućnosti daljnjeg poboljšanja predloženog unaprjeđenja, nameće se sigurno odabir parametara α , β , γ i δ čime se predloženo unaprjeđenje može prilagoditi problemu. Tijekom cijele analize, vrijednost ovih faktora bila je jednaka 1. Uz to, s obzirom da predloženo unaprjeđenje ne ometa pretragu prostora rješenja osnovnog omotača, na kraju pretrage dobivaju se dva rješenja. Prema tome, moguće je uvesti dodatno vrednovanje koje će omogućiti donošenje odluke o tome koji podskup značajki odabrati. Iako se predloženo unaprjeđenje pokazalo boljim, prethodna mogućnost čini se kao zanimljiv smjer daljnjih istraživanja i poboljšanja.

Oblikovanje klasifikacijskog modela radialne neuronske mreže

*"It is a capital mistake to theorize before
one has data."
- sir Arthur Conan Doyle*

GLAVNI element klasifikacijske procedure jest određivanje klase novog uzorka na temelju iskustva. Obavljaju ga algoritmi koji se nazivaju klasifikatorima, a da bi klasifikator mogao donijeti odluku, potrebno je na temelju dostupnih podataka oblikovati i izgraditi klasifikacijski model. Iako se ova dva pojma mogu rabiti kao istoznačnice, a često se to i čini, kada se govori o klasifikatoru misli se na konkretan algoritam, dok klasifikacijski model predstavlja objekt, skup pravila, koji nastaje nakon provođenja treniranja klasifikatora. Uobičajeno je riječ o definiranju funkcije ili skupa funkcija kojima se omogućuje preslikavanje iz prostora značajki u prostor kategorija, to jest klasa. Broj različitih dostupnih klasifikatora vrlo je velik, a isto vrijedi i za postupke izgradnje klasifikacijskih modela, odnosno postupke treniranja klasifikatora. Klasifikatore je moguće podijeliti u skupine prema svojstvima koja ih odlikuju. Tako neki od njih imaju obličje crne kutije gdje nije lako dokučiti pravila prema kojima određuju oznaku klase koju dodjeljuju uzorku (primjerice ANN i SVM pripadaju ovoj skupini). Kod drugih je pak postupak određivanja klase jasan i intuitivan (kao primjerice kod algoritma k NN ili stabala odluke). Cilj ovog poglavlja jest iskoristiti dobra svojstva klasifikatora umjetne radialne neuronske mreže (engl. *radial basis function network*, RBFN) u


svrhu raspoznavanja razina boli. S tim u vidu najprije će biti predstavljen klasifikacijski model radijalne neuronske mreže te će biti prikazani načini oblikovanja ovog modela dostupni u literaturi. Bit će izložen predloženi unaprijeđeni algoritam za potrebe oblikovanja ovog klasifikacijskog modela, zasnovan na algoritmu ABC koji ujedno predstavlja i treći izvorni znanstveni doprinos. Elementi navedenog unaprijeđenja bit će pobliže opisani, a da bi se dobio uvid u ponašanje i utvrdila opravdanost predloženog unaprijeđenja, bit će provedena usporedna eksperimentalna analiza. Ona će se provesti uporabom standardnog podatkovnog skupa bolnih izraza lica, ali i nekoliko problema iz različitih domena. Ponašanje predloženog unaprijeđenog algoritma bit će uspoređeno s nekoliko drugih algoritama korištenih za ove potrebe u literaturi.

5.1 Klasifikacijski model radijalne neuronske mreže

Umjetne neuronske mreže predstavljaju često odabrano moguće rješenje za složene probleme strojnog učenja, bilo da je riječ o klasifikacijskim, regresijskim ili drugim oblicima problema. Neke od njihovih raznovrsnih primjena prikazane su, primjerice, u [113, 114, 115, 116, 117]. Oblikovane su tako da pokušavaju, u određenoj mjeri, emulirati način rada ljudskog mozga, odnosno nakupine povezanih neurona koji međusobnom komunikacijom i utjecajem dolaze do rješenja kompleksnih problema. Postoji velik broj različitih inačica neuronskih mreža koje se međusobno razlikuju po obliku, složenosti, načinu povezivanja među neuronima te u konačnici po postupcima koji se rabe za njihovo oblikovanje [118]. Upravo je učenje zajedničko svim ovim modelima, a u pravilu se svodi na određivanje parametara mreže, koji uključuju broj neurona, vrijednosti težinskih faktora na njihovim sponama i drugih. Za potrebe klasifikacije najčešće se odabire klasa neuronskih mreža koje imaju propagaciju signala prema naprijed (engl. *feed forward neural networks*), a dva glavna predstavnika ove skupine zasigurno su višeslojni perceptron (engl. *multi-layer perceptron*, MLP) i radijalna neuronska mreža. Potonje, prema [119], u kontekstu problema raspoznavanja razina boli imaju neka poželjna svojstva u odnosu na MLP-e, poput jednostavnije strukture te lakšeg i bržeg treniranja. Uz navedeno, prema [120], otpornije su na šum u podacima. S obzirom na opisana poželjna svojstva, ovaj tip ANN-a pronašao je primjenu u brojnim različitim područjima inženjerstva, kao što su predviđanje genetskih odlika [121], predviđanje tečajne stope valuta [122] ili procjena karakteristika fotonaponskih modula [123].

RBFN je uobičajeno organizirana u tri sloja neurona: ulaznog, skrivenog i izlaznog. Izgled standardnog oblika RBFN prikazan je slikom 5.1, pri čemu je d dimenzionalnost problema, h broj čvorova u skrivenom sloju, m broj klasa, a x^i, ϕ_j, w_j^k, y^k , za $i = 1, \dots, d, j = 1, \dots, h, k = 1, \dots, m$ predstavljaju redom ulazne vrijednosti, funkcije jezgre, težinske faktore na sponama i izlazne vrijednosti. Ulazne vrijednosti, pa prema tome i broj ulaznih neurona,

kod klasifikacijskih problema određeni su problemom koji se rješava i njegovom dimenzi-
onalnošću. Isto vrijedi i za broj izlaznih neurona koji ovisi o broju klasa. Znanje u mreži
predstavljaju parametri neurona skrivenog sloja, to jest parametri funkcija jezgara te težin-
ski faktori na sponama neurona skrivenog i izlaznog sloja. Kao funkcije jezgre odabiru se
radijalne funkcije čija je odlika da im se odziv smanjuje ili raste s udaljenošću od centralne
točke. Uobičajen odabir predstavlja Gaussova funkcija (engl. *Gaussian function*), no nije
rijetkost susresti niti drugačije funkcije poput qGaussove, Cauchyjeve i drugih.



Slika 5.1: Uobičajena struktura RBFN klasifikatora

Izlaz iz mreže moguće je odrediti prema

$$y^j = \sum_{k=1}^h \phi_k w_k^j, \quad j = 1, \dots, m, \quad (5.1)$$

gdje je ϕ_k aktivacijska funkcija skrivenog neurona, odnosno jednog čvora skrivenog sloja
mreže, a w_k^j težinski faktor na sponama danog izlaza i skrivenog neurona. Kao što je ranije
spomenuto, najčešći odabir predstavlja Gaussova funkcija dana za skriveni neuron izrazom

$$\phi_k = \exp\left(-\frac{\|x - c_k\|^2}{2\sigma_k^2}\right) = \exp\left(-\frac{\sum_{i=1}^d (x^i - c_k^i)^2}{2\sigma_k^2}\right), \quad (5.2)$$

pri čemu je c_k vektor koji predstavlja lokaciju centra djelovanja funkcije, a σ_k širinu njena
utjecaja.

Važno je ovdje napomenuti da je mjera udaljenosti određenog uzorka u odnosu na centar,
prototip, najčešće Euklidska udaljenost, no moguće je rabiti i druge funkcije udaljenosti,
poput primjerice Manhattan ili Mahalanobis udaljenosti. Vrijednost na svakom od izlaza iz
mreže kod klasifikacije predstavlja pripadnost jednoj od klasa, a oznaka klase se dodjeljuje

prema najvećem ostvarenom rezultatu. Naime, kod predstavljanja temeljne istine uzima se da je izlaz iz neurona koji predstavlja stvarnu klasu jednak 1, dok je izlaz svih ostalih neurona jednak 0.

Poseban oblik RBFN-a predstavljaju takozvane normalizirane RBFN [124]. Kod njih se izlaz iz pojedinih skrivenih čvorova normalizira ukupnim izlazom iz svih neurona skrivenog sloja prema

$$\phi_k(x) = \frac{\phi_k(x)}{\sum_{i=1}^h \phi_i(x)}. \quad (5.3)$$

U odnosu na izvorni oblik RBFN-a, normalizirani oblik, prema [125], ima jednostavniju strukturu koja uključuje značajno manji broj potrebnih skrivenih neurona, općenito bolju mogućnost generalizacije te vrlo visoke performanse u klasifikacijskim zadacima.

Kao što je vidljivo iz predstavljenog, ovu mrežu odlikuje relativno visok broj parametara koje je nužno odrediti tijekom oblikovanja klasifikacijskog modela. Problem postaje još složeniji ako se razmatra automatsko oblikovanje, kod kojega broj skrivenih neurona nije unaprijed poznat. Odabir adekvatnog broja skrivenih neurona, prema [118], ovisi o karakteristikama podatkovnog skupa s kojim se radi, što uključuje međusobne odnose između podataka koji pripadaju pojedinoj klasi i utječu na složenost granica odluke. Oblikovanje klasifikacijskog modela radijalne neuronske mreže provodi se u dvije diskretne faze. U prvoj se fazi određuje broj neurona u skrivenom sloju, ukoliko je riječ o automatskom oblikovanju, te se određuju parametri funkcija jezgara. Nakon toga, pristupa se drugoj fazi tijekom koje se određuju vrijednosti težinskih faktora na sponama neurona u skrivenom sloju i onih u izlaznom.

5.2 Načini oblikovanja klasifikacijskog modela radijalne neuronske mreže

Uzevši u obzir dobra svojstva i performanse ovog klasifikacijskog modela, ali i velik broj parametara koji je potrebno odrediti prilikom njegova oblikovanja, ne čudi da je ovaj problem čest fokus znanstvenog interesa. U tu svrhu, predložene su brojne metode u literaturi, pri čemu se prva faza oblikovanja često oslanja na postupke grupiranja podataka ili prirodom inspirirane algoritme za optimizaciju, dok se druga faza oslanja također na prirodom inspirirane algoritme, gradijentni spust (engl. *gradient descent*, GD) ili determinističke metode. Potonje se prvenstveno odnosi na takozvanu metodu uporabe pseudo-inverza (oznaka PINV). Riječ je naime o metodi koja iskorištava činjenicu da se izlaz iz mreže za sve ulazne uzorke može odrediti matricnom jednadžbom $Y = \Phi \cdot W$, pri čemu Φ predstavlja matricu dizajna, odnosno izlaze skrivenih čvorova za svaki ulazni uzorak, W matricu težinskih faktora, a Y izlaze za sve

ulazne uzorke. Ovo je detaljnije prikazano izrazom (5.4), a lako je vidljivo da je vrijednosti težinskih faktora na sponama moguće odrediti analitički prema $W = \Phi^{-1}Y$. S obzirom da Φ u pravilu nije kvadratna matrica, računa se njezin pseudo-inverz, $\Phi^* = (\Phi^T\Phi)^{-1}\Phi^T$, nazvan još i Moore-Penrose inverz. Težinski se faktori tada mogu odrediti kao $W = \Phi^*Y$. S obzirom da navedeni pristup omogućuje analitički način određivanja težinskih faktora, uvelike pri tom smanjujući potrebne računalne resurse u smislu vremena potrebnog za njihovo određivanje, predstavlja učestao odabir za drugu fazu oblikovanja klasifikacijskih modela RBFN-a te je, shodno tome, odabran i za potrebe eksperimentalne analize.

$$\begin{bmatrix} \phi_{11} & \phi_{12} & \dots & \phi_{1h} \\ \phi_{21} & \phi_{22} & \dots & \phi_{2h} \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{n1} & \phi_{n2} & \dots & \phi_{nh} \end{bmatrix} \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1k} \\ w_{21} & w_{22} & \dots & w_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ w_{h1} & w_{h2} & \dots & w_{hk} \end{bmatrix} = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1k} \\ y_{21} & y_{22} & \dots & y_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ y_{n1} & y_{n2} & \dots & y_{nk} \end{bmatrix} \quad (5.4)$$

S obzirom na velik izbor postupaka za oblikovanje klasifikacijskog modela u obje njegove faze, ne čudi dostupnost različitih pristupa u literaturi. Qin et al. u [126] predložili su tako pristup za provođenje prve faze oblikovanja zasnovan na algoritmu inteligencije roja čestica. Svaka čestica u populaciji predstavlja cjelovito rješenje koje sadrži lokacije centara, uz njih vezane širine djelovanja te aktivacijske zastavice koje kontroliraju složenost mreže, odnosno reguliraju broj neurona u skrivenom sloju. Težinski faktori nisu sadržani u rješenju, već se u drugoj fazi dizajna koristi metoda PINV za proračun težinskih faktora. Sličan pristup za prvu fazu, zasnovan na PSO, prikazan je u [127], a korišten za klasifikaciju slika dobitvenih radarom. Centri i širine određuju se tako korištenjem PSO-a, a razlika u odnosu na ranije opisan pristup leži u određivanju težinskih faktora. Navedeno se ovdje postiže korištenjem algoritma povratnog prostiranja (engl. *back-propagation*). Izmjena algoritma PSO koja uključuje uvođenje faktora stezanja (engl. *constriction*) koji kontrolira utjecaj izmjena pojedinog rješenja prilikom pretrage korištena je u [128]. Pristup se pokazao uspješnim, kako na standardnim testnim podatkovnim skupovima, tako i kod klasifikacije signala elektroencefalograma za potrebe kontrole robota uporabom istih signala u stvarnom vremenu. Za izgradnju RBFN-a, osim već spomenutih pristupa zasnovanih na PSO-u, korišteni su i drugi popularni i učinkoviti prirodno nadahnuti algoritmi za optimizaciju. Kurban et al. su u [129] primijenili ABC za potrebe izgradnje modela RBFN u svrhu klasifikacije terena na temelju slika. Predloženi pristup se u usporedbi s GA, gradijentnim spustom (engl. *gradient descent*, GD) i Kalmanovim filtrom pokazao uspješnijim u danom zadatku. U spomenutom pristupu pojedino rješenje sadrži sve parametre mreže, uključujući težinske faktore, no istovremeno je broj neurona ručno mijenjan tako da $h = 1, 2, \dots, 8$. U svrhu predviđanja prometa, isti je klasifikacijski model oblikovan uz pomoć ABC-a u [130]. Horng et al. oslonili su se na noviji algoritam inspiriran ponašanjem krijesnica u [131]. Prema eksperimentalnom vrednovanju, isti se pokazao uspješnijim pri dizajnu RBFN-a od GA, GD-a, PSO-a i ABC-a. Broj neurona

postavljan je ručno, kao u [129], a analiza je provedena na javno dostupnim podatkovnim skupovima s UCI repozitorija. Isti algoritam za oblikovanje RBFN-a odabran je i u [132], gdje RBFN korišten za predviđanje poplava, dok je u [133] RBFN treniran uporabom FFA korišten za predviđanje troška programske podrške. Pristup zasnovan na grupiranju podataka i DE predložen je u [109]. Dio inicijalne populacije generiran je grupiranjem podataka algoritmom k -means, prostor pretrage dinamički se prilagođava tijekom pretrage, a za računanje težinskih faktora koristi se metoda pseudo-inverza. Dublji uvid u ponašanje DE-a prilikom izgradnje RBFN-a, kao i usporedbu iste s drugim prirodom inspiriranim algoritmina (kao što su PSO, ABC i FFA) dali su Bajer et al. u [134]. Određivani su samo parametri skrivenog sloja uz fiksni broj neurona u istome, dok su težine analitički određene metodom pseudo-inverza. Zanimljiv pristup zasnovan na grupiranju podataka korištenjem pčela predstavljen je u [135]. Algoritmom za grupiranje i pažljivim odabirom rješenja na temelju kvalitete particija dobivaju se kandidati za centre. Širine se zatim računaju na temelju smještaja centara, a težinski faktori na sponama korištenjem metode pseudo-inverza. Pristup se pokazao boljim od nekoliko metoda zasnovanih na grupiranju podataka iz literature i to na standardnim podatkovnim skupovima.

5.3 Unaprijeđeni ABC za oblikovanje klasifikacijskog modela RBFN

Glavni ciljevi prilikom automatskog oblikovanja klasifikacijskog modela radijalnih neuronskih mreža predstavljaju u prvom redu visoku razinu kvalitete klasifikacije te, ako je to moguće, održavanje relativno jednostavnog modela u smislu broja parametara koje je za isti potrebno odrediti. Održavanje kompleksnosti modela na niskoj razini je posebice osjetljivo na broj neurona u skrivenom sloju, koji ima snažan utjecaj na broj ostalih parametara. Dodavanjem jednog neurona u skriveni sloj potrebno je odrediti parametre funkcije jezgre te dodatne težinske faktore na sponama tog neurona i onih u izlaznom sloju. Ipak, mreže s većim brojem čvorova u skrivenom sloju neizbježne su kod složenijih problema gdje su granice odluke među klasama složene.

S obzirom da su se metode zasnovane na prirodom inspiriranim algoritmina optimizacije pokazale dobrima za potrebe oblikovanja RBFN-a, njihova daljnja prilagodba mogla bi dovesti bliže ostvarivanju ranije spomenutih ciljeva. Sužavanje prostora pretrage za parametrima klasifikacijskog modela u kasnijim fazama iste može dovesti do detaljnijeg istraživanja prostora oko najboljih rješenja i na taj način olakšati postavljanje parametara na odgovarajuće vrijednosti [109]. Prema tome, navedeno može pretragu usmjeriti na fino podešavanje centara i širina funkcija jezgara. Nadalje, ugradnja ideja iz grupiranja podataka pokazala je dobro ponašanje u, primjerice [109, 135]. S obzirom na način obavljanja pretrage, rela-

tivno nizak broj parametara, ali i dobre rezultate na različitim problemima, algoritam ABC predstavlja dobru početnu točku u svrhu ostvarivanja navedenih ideja. Naime, postoji faza pretrage koja je namijenjena iskorištavanju obećavajućih regija, a također i faza pretrage koja se u potpunosti oslanja na nasumično stvorena rješenja. Stoga se otvara mogućnost stavljanja jačeg naglaska na iskorištavanje u prvoj od dvije navedene faze, kao i mogućnost iskorištavanja rješenja nastalih grupiranjem podataka u drugoj.

5.3.1 Načela rada algoritma umjetne kolonije pčela

Algoritam umjetne kolonije pčela predstavili su u osnovnoj inačici Karaboga et al. u [110]. Riječ je o algoritmu inspiriranom ponašanjem pčela u potrazi za hranom. Razlikuju se u osnovi tri skupine pčela: pčele radilice, pčele istraživači i pčele skauti. Pčela koja posjećuje izvor hrane koji je sama i ranije posjetila naziva se radilicom, pčela koja čeka u košnici i donosi odluku koji će izvor hrane posjetiti u ovisnosti o njegovoj kvaliteti naziva se istraživačem, dok pčela koja istražuje nasumične izvore hrane nosi titulu skauta. Za svaki izvor hrane, koji predstavlja jedno moguće rješenje problema, postoji točno jedna pčela radilica, a broj pčela istraživača jednak je broju pčela radilica. Pčela čiji je izvor hrane istrošen i napušten postaje skaut. Nacrt visoke razine ovog algoritma predstavljen je algoritmom 3. Kao što je vidljivo iz danog algoritma, pretraga prostora rješenja provodi se kroz tri odvojene faze, već prema tipu pčela u populaciji.

Algoritam 3 Skica algoritma ABC

```

1: while Uvjet završetka nije ispunjen do
2:   Radnici istražuju izvore hrane
3:   Istraživači odabiru i istražuju izvore hrane
4:   Skauti traže nove izvore hrane
5: end while

```

Sam algoritam zahtijeva postavljanje triju parametara, a to su: veličina populacije, odnosno broj rješenja unutar populacije PS (broj pčela radilica i istraživača jednak je ovoj vrijednosti), maksimalan dopušten broj ciklusa izmjene $limit$ te parametar NFE_{max} koji određuje broj dopuštenih vrednovanja funkcije cilja. Nakon postavljanja parametara algoritma, rješenja se unutar populacije postavljaju na nasumične početne vrijednosti prema

$$x_i^j = b_{min} + rand(0, 1) \cdot (b_{max} - b_{min}), \quad (5.5)$$

gdje x_i^j predstavlja j -tu komponentu i -tog rješenja unutar populacije, b_{min} i b_{max} su donja i gornja granica, a $rand(0, 1)$ nasumična realna vrijednost iz segmenta $[0, 1]$, odabrana prema uniformnoj razdiobi. Nakon stvaranja članova početne populacije, određuje se njihova kvaliteta u smislu zadane funkcije cilja.

Tijekom prve faze pretrage, svaka pčela radilica stvara novo rješenje izmjenom jedne komponente trenutno posjećenog izvora hrane x_i , a prema

$$v_{i,j}^k = x_i^k + \phi_{i,j,k}(x_i^k - x_j^k), \quad (5.6)$$

pri čemu $v_{i,j}$ predstavlja novo rješenje (kandidata) nastalog na temelju dvaju rješenja unutar populacije x_i i x_j , k komponentu rješenja koja se zamjenjuje, a $\phi_{i,j,k}$ je nasumično odabrana vrijednost iz segmenta $[-1, 1]$. Važno je napomenuti da se j i k biraju nasumično i to kao $j = \text{randint}(1, PS)$, $j \neq i$, i $k = \text{randint}(1, d)$. Ako je novo rješenje bolje od postojećeg (u smislu funkcije cilja), tada ga zamjenjuje. Cilj ove faze je istraživanje prostora pretrage.

U drugoj fazi pretrage pčele istraživači odabiru rješenja prema kvaliteti. Rješenja se odabiru prema vjerojatnosti odabira koja je izravno povezana s njegovom kvalitetom, dakle rješenja veće kvalitete imaju više šanse biti odabrana za daljnju pretragu. Vjerojatnost odabira računa se za svako rješenje populacije kao

$$p_i = \frac{f(x_i)}{\sum_{j=1}^{PS} f(x_j)}, \quad (5.7)$$

pri čemu je $f(x_i)$ vrijednost funkcije cilja za rješenje. Nakon što pčela istraživač odabere rješenje, izmijeni ga prema izrazu (5.6). Ukoliko je kvaliteta novog rješenja veća od postojećeg, ono se zamjenjuje novim. Cilj ove faze je iskorištavanje stečenog znanja i usmjeravanje pretrage na obećavajuće regije prostora pretrage.

Nakon što je svaka pčela istraživač odabrala i pokušala unaprijediti neko od rješenja, provodi se treća faza pretrage. Unutar nje se provjerava je li koje od rješenja iscrpljeno. Iscrpljenost se određuje parametrom algoritma *limit* koji označava maksimalan broj ciklusa tijekom kojih je dopušteno pokušati unaprijediti rješenje. Ako postoje iscrpljena rješenja, napušta ih se u kojem slučaju pčela skaut stvara novo rješenje potpuno nasumično, prema (5.5), te takvo rješenje zamjenjuje napušteno. Cilj ove faze jest održavanje raznolikosti populacije [136].

Unaprijeđena inačica osnovnog algoritma, koja omogućuje značajnije izmjene jedinki unutar populacije, što ju čini pogodnom za probleme viših dimenzija, opisana je u [111]. Uvedena je naime stopa izmjene mr koja kontrolira izmjenu pojedine komponente unutar rješenja. Tako se kod stvaranja izmijenjenog rješenja ono umjesto prema izrazu (5.6) stvara prema

$$v_{ij}^k = \begin{cases} x_i^k + SF \cdot (x_i^k - x_j^k), & \text{ako } r_{i,j,k} < mr \\ x_i^k, & \text{inače,} \end{cases} \quad (5.8)$$

gdje je $r_{i,j,k}$ nasumičan broj iz segmenta $[0, 1]$ odabran prema uniformnoj razdiobi, a $0 < mr \leq 1$ stopa izmjene koja utječe na to koliko komponenti rješenja će biti izmijenjeno pri-

likom križanja i predstavlja dodatni parametar algoritma. Postavljanjem visoke vrijednosti mr mijenja se veći broj komponenti rješenja pa se može zaključiti da će navedeno dovesti do brže konvergencije. Uz navedenu izmjenu predložena je i dodatna izmjena u vidu uvođenja faktora skaliranja SF koji bi utjecao na snagu izmjene pojedine komponente rješenja. Ovaj parametar postavlja se na početku pretrage na neku fiksnu vrijednost, ili se alternativno postavlja na 1, a tijekom pretrage smanjuje se ili povećava u ovisnosti o udjelu uspješnih promjena u odnosu na ukupni broj promjena [111]. Nacrt rada algoritma dan je algoritmom 4.

Algoritam 4 Nacrt rada prilagođene inačice algoritma ABC

```

postavi funkciju cilja  $f(x)$ ,  $PS$ ,  $mr$ ,  $limit$ ,  $SF = 1$  i  $NFE_{max}$ ;
postavi  $k_{min}$  i  $k_{max}$ 
inicijaliziraj populaciju prema (5.5)
while  $NFE_{spent} < NFE_{max}$  do
  // Faza pčela radilica
  for  $i := 1 \dots PS$  do
    stvori  $v_{i,j}$  prema (5.8)
    if  $f(v_{i,j}) > f(x_i)$  then
       $x_i := v_{i,j}$ 
       $promjena_i := 0$ 
    else
       $promjena_i := promjena_i + 1$ 
    end if
    Provjeri je li potrošen budžet vrednovanja, ako jest - prekini i zapamti najbolje rješenje
  end for
  izračunaj vjerojatnosti odabira prema (5.7)
  // Faza pčela istraživača [*M1]
   $sel := 1$ ,  $t := 1$ ;
  while  $t \leq PS$  do
     $r := rand(0,1)$ 
    if  $r < p_{sel}$  then
       $t := t + 1$ 
      stvori  $v_{sel,j}$  prema (5.8)
      if  $f(v_{sel,j}) > f(x_{sel})$  then
         $x_{sel} := v_{sel,j}$ 
         $promjena_{sel} := 0$ 
      else
         $promjena_{sel} := promjena_{sel} + 1$ 
      end if
    end if
    Provjeri je li potrošen budžet vrednovanja, ako jest - prekini i zapamti najbolje rješenje
     $sel := sel + 1$ ;  $sel := sel \bmod PS$ 
  end while
  // Faza pčela skauta [*M2]
  for  $j := 1 \dots PS$  do
    if  $promjena_j \geq limit$  then
      stvori  $v_j$  prema (5.5)
       $x_j := v_j$ 
       $promjena_j := 0$ ;
      Provjeri je li potrošen budžet vrednovanja, ako jest - prekini i zapamti najbolje rješenje
    end if
  end for
  Izračunaj SF
end while

```

S ciljem prilagodbe algoritma ABC za potrebe raspoznavanja razina boli, odabrana je kao osnovna inačica ona predstavljena u [111], koja uključuje i stopu izmjene i samopodešavajući faktor skaliranja. Izmjene osnovnog algoritma koncentrirane su u njegovoj drugoj i trećoj fazi, a naznačene s M1 i M2 u algoritmu 4, dok su pobliže opisane u naredna dva potpoglavlja.

5.3.2 Fokusiranje pretrage

Prva predložena izmjena tiče se načina na koji se provodi iskorištavanje obećavajućih točaka, to jest rješenja, unutar prostora pretrage kod pčela istraživača. Naime, u drugoj se fazi pretrage pritisak stavlja na bolja rješenja da bi se pretraga usmjerila ka regijama koje ih okružuju. Ipak, ovaj pritisak ne mora biti dovoljan kod složenih problema i problema izrazito visoke dimenzionalnosti. Rezultat toga može biti sporo napredovanje ili čak zastajanje u pretrazi. S druge pak strane, pretjerano iskorištavanje lako može dovesti do stagnacije pretrage i prerane konvergencije.

S obzirom na broj značajki uključen u problem raspoznavanja razina boli, jasno je da je riječ o problemu izrazito visoke dimenzionalnosti. Kako bi se fokus pretrage stavio na rješenja više kvalitete u smislu funkcije cilja, a u isto vrijeme izbjegao pretjeran pritisak koji bi populaciju rješenja vrlo brzo sveo na niz sličnih rješenja, predlaže se uvođenje dvaju koraka koji bi omogućili navedeno. Prvi od njih je promjena načina izmjene rješenja kod pčela istraživača uvođenjem stope razmjene er i razmjenom dijelova rješenja prema izrazu

$$v_{ij}^k = \begin{cases} x_j^k + SF \cdot (x_j^k - x_i^k), & \text{ako } r_{i,j} < er \\ x_i^k, & \text{inače,} \end{cases} \quad (5.9)$$

gdje x_j predstavlja jedno među trenutno najboljim rješenjima unutar populacije. Odabir tog rješenja provodi se tako da se uzima $j = \text{randint}(1, |N_{bst}|)$, gdje je N_{bst} skup koji predstavlja N trenutno najboljih rješenja unutar populacije. Gornje granice se za er i N postavljaju na početku pretrage na er_{max} i N_{max} te se tijekom pretrage linearno smanjuju do er_{min} , odnosno N_{min} prema

$$\begin{aligned} er &= er_{max} - \frac{NFE_{spent}}{NFE_{max}} \cdot (er_{max} - er_{min}) \\ N &= N_{max} - \frac{NFE_{spent}}{NFE_{max}} \cdot (N_{max} - N_{min}). \end{aligned} \quad (5.10)$$

Ovim smanjivanjem zapravo se osiguravaju značajnije razmjene na početku, dok se u kasnijim fazama pretrage njihova učestalost smanjuje. Broj najboljih rješenja koji se uzima u obzir uvijek je unutar prozora ograničenog s N_{max} i N_{min} , a budući da se gornja granica tog prozora smanjuje napredovanjem pretrage, snažniji se fokus kasnijim fazama postavlja na malen broj najboljih rješenja. Ideja koja stoji iza predloženih izmjena jest osigurati snažnije usmjeravanje procesa pretrage ka boljim rješenjima u populaciji i regijama koje ih okružuju, odnosno osnažiti iskorištavanje. Ipak, korištenjem prozora koji ograničava broj najboljih rješenja koja se uzimaju u obzir prilikom odabira kandidata, kao i smanjivanjem stope razmjene pokušava se izbjeći prerana konvergencija. Predložene izmjene u ovom smislu označene su unutar algoritma 4 oznakom M1, a njihova ugradnja prikazana je algoritmom 5.

Algoritam 5 Izmjena faze pčela istraživača (*M1)

```

// Faza pčela istraživača [*M1]
sel := 1; t := 1;
Izračunaj parametre  $er$  i  $N$  prema 5.10;
while  $t \leq PS$  do
   $r := \text{rand}(0,1)$ ;
  if  $r < p_{sel}$  then
     $t := t + 1$ ;
    Pronađi indekse  $N$  najboljih rješenja,  $N_{bst}$ ;
     $z := \text{randint}(1, N)$ ;
     $j := (N_{bst})_z, j \neq sel$ ;
    Stvori  $v_{sel,j}$  prema 5.9;
    if  $f(v_{sel,j}) > f(x_{sel})$  then
       $x_{sel} := v_{sel,j}$ ;
       $promjena_{sel} := 0$ ;
    else
       $promjena_{sel} := promjena_{sel} + 1$ ;
    end if
  end if
  Provjeri je li potrošen budžet vrednovanja, ako jest - prekini i zapamti najbolje rješenje
   $sel := sel + 1; sel := sel \bmod PS$ ;
end while

```

5.3.3 Korištenje grupiranja podataka

U osnovnom ABC-u, kao i u unaprijeđenim inačicama, treća faza pretrage oslanja se na nasumično stvorena rješenja. Cilj je osigurati raznolikost pretrage uvođenjem u potpunosti nasumično stvorenih rješenja u populaciju. Budući da nasumična rješenja u pravilu imaju vrlo nisku kvalitetu, kod složenih problema visoke dimenzionalnosti upitan je učinak ovog koraka. S obzirom na iskazanu potrebu za snažnijim usmjeravanjem pretrage ka regijama koje obiluju rješenjima visoke kvalitete, upitno je u kojem će smjeru ona odvesti pretragu i koliki će biti stvarni doprinos takvog rješenja, unatoč održavanju raznolikosti. Predlaže se stoga izmjena načina stvaranja novog rješenja unutar treće faze, a ona je zasnovana na grupiranju podataka. Za razliku od drugih pristupa koji se oslanjaju na grupiranja (primjerice [109] i [135]), ne koristi se grupiranje ulaznih uzoraka već grupiranje članova populacije. Razlog odabira populacije, a ne samih podataka leži u činjenici da je kod grupiranja podataka potrebno uložiti veći napor da bi se grupiranjem dobila dobra rješenja, što je posebice izraženo kod problema raspoznavanja razina boli zbog vrlo visoke dimenzionalnosti i složenosti problema. Osim toga, potrebno je i nadalje osnažiti iskorištavanje obećavajućih regija prostora pretrage, što i jest cilj opisanog načina grupiranja. Sličan pristup s ciljem povećavanja stope konvergencije i ujednačavanja razine istraživanja i iskorištavanja ugrađen je u algoritam DE u [137]. Međutim, u navedenom je algoritmu grupiranje obavljano periodno, dok je zamjena obavljana nasumičnim odabirom χ najboljih rješenja među onima nastalim grupiranjem i χ nasumično odabranih rješenja iz populacije.

Grupiranje populacije nije toliko zahtjevno u pogledu potrebnih resursa u odnosu na grupiranje uzoraka, s obzirom da je broj instanci problema uobičajeno značajno veći od veličine populacije ($n \gg PS$). Za provođenje grupiranja odabire se najprije broj centara kao $\chi = \text{randint}(\chi_{min}, \chi_{max})$ te se uporabom algoritma k -means grupiraju rješenja koja postoje

unutar populacije. Za χ_{min} predlaže se korištenje najmanjeg dopuštenog broja centara, to jest dva centra, a za χ_{max} vrijednost \sqrt{PS} , kao što je sugerirano u [137]. Rezultirajućih χ centroida predstavljaju nova moguća rješenja. Učestalost ove izmjene treba biti niska, kako ne bi dovela do prerane konvergencije. Dodatnu pažnju potrebno je iz istih razloga posvetiti rješenju koje će biti zamijenjeno, a predlaže se zamjena onog rješenja u trenutnoj populaciji s najvećim stupnjem istrošenosti, prema broju ciklusa izmjene bez unaprjeđenja. Ovim se načinom izbjegava prevelik pritisak, dok se pretraga ipak pokušava što više usmjeriti ka obećavajućim rješenjima. Predložene izmjene u ovom smislu označene su unutar algoritma 4 oznakom M2, a njihova ugradnja prikazana je algoritmom 6. U njemu, r_c predstavlja vjerojatnost zamjene kojom se može kontrolirati učestalost stvaranja novog rješenja na temelju grupiranja trenutnih. Ovu je vrijednost moguće prilagoditi problemu koji se rješava, a sugerira se korištenje relativno niske vjerojatnosti, s obzirom da bi veće vrijednosti mogle dovesti do vrlo brze konvergencije populacije.

Algoritam 6 Izmjena faze pčela skauta (*M2)

```

r := rand(0,1);
if r < rc then
   $\chi$  := randint( $\chi_{min}$ ,  $\chi_{max}$ );
  uporabom algoritma k-means kreiraj novih  $\chi$  rješenja grupiranjem populacije;
  pronadi najbolje rješenje među novim rješenjima,  $x_{bst}$ ;
  j := indeks(max(promjena));
   $x_j$  :=  $x_{bst}$ ;
end if

```

5.4 Eksperimentalna analiza i rezultati

S ciljem utvrđivanja ponašanja predloženog unaprijeđenog algoritma umjetne kolonije pčela (VRABC), provedeno je njegovo eksperimentalno vrednovanje. Vrednovanje se sastoji od tri dijela. U prvom dijelu razmatrano je ponašanje algoritma VRABC na podatkovnim skupovima koji opisuju razine boli u odnosu na algoritam umjetne kolonije pčela na kojemu je zasnovan. U drugom dijelu predloženi unaprijeđeni algoritam uspoređen je na podatkovnim skupovima koji opisuju razine boli s nekoliko različitih prirodom inspiriranih algoritama korištenih za oblikovanje klasifikacijskog modela RBFN-a korištenih u literaturi. U trećem dijelu eksperimentalne analize razmatrano je ponašanje predloženog algoritma na problemima iz različitih domena. Priprema eksperimenata, postavke parametara te opis testiranja dani su u nastavku, nakon čega su prikazani rezultati analize te je dan osvrt na ostvareno.

5.4.1 Postavke eksperimenta

Da bi se provela prva dva dijela eksperimentalnog vrednovanja, korišteni su podatkovni skupovi koji opisuju razine boli dobiveni u kliničkim uvjetima kao što je opisano u potpoglavlju

4.4.1 te karakteristika danih tablicom 4.1. Za potrebe trećeg dijela eksperimentalnog vrednovanja korišteni su ranije prikazani podatkovni skupovi, vezani uz probleme iz različitih domena, preuzeti s UCI repozitorija [112], a opisani tablicom 4.8 te prilogom A. Značajke u svim podatkovnim skupovima korištenima u analizi svedene su unutar segmenta $[0, 1]$, uporabom normalizacijskog filtra dostupnog u alatu Weka [75]. Za svaki podatkovni skup i svaki algoritam unutar usporedbe provedeno je, kao i u slučaju ranijih eksperimenata, 25 neovisnih izvođenja. Podjela skupova korištenih za vrednovanje bila je jednaka za sve korištene algoritme, a obavljena je metodom izostavljanja, na način kao u [91, 109], uz omjere $0.5 : 0.25 : 0.25$ redom za skup podataka za treniranje S_t , vrednovanje S_v i testiranje S_e . Ponovno je riječ o stratificiranoj podjeli, dakle raspodjela instanci pojedine klase u svakom od podskupova odražava raspodjelu unutar cjelokupnog podatkovnog skupa.

Što se tiče trajanja pretrage, svakom algoritmu dan je budžet od $NFE_{max} = 5 \cdot 10^4$ vrednovanja funkcije cilja. Pretraga je prekinuta čim je taj iznos dostignut. S obzirom na složenost problema, dani iznos veći je nego što je bio slučaj u poglavlju 4, kod potrage za najboljim podskupom značajki, a da bi se omogućilo dovoljno vremena za oblikovanje klasifikacijskog modela. Ipak, vrijednost nije prevelika da bi se trajanje eksperimenta svelo na razumnu razinu. No, i iz provedene preliminarne eksperimentalne analize bilo je uočljivo da niti veći broj dopuštenih vrednovanja nije doveo do razlika u odnosima među rezultatima pojedinih algoritama. Parametri algoritama postavljeni su prema često odabranim vrijednostima iz literature i prema provedenoj preliminarnoj analizi, a dani su u tablici 5.1.

Tablica 5.1: Postavke parametara pri testiranju VRABC


Alg.	Korištene vrijednosti parametara
MRABC	$PS = 30, mr = 0.9, limit = 100$
MRASF	$PS = 30, mr = 0.9, limit = 100$
PSO	$PS = 30, c_1 = c_2 = 1.496, \omega = 0.7298$
CPSO	$PS = 30, \chi = 0.729, \beta_c = rand(1, 4), \beta_s = 4.1 - \beta_c$
FFA	$PS = 30, \alpha = 0.1, \gamma = 1, \beta_0 = 1$
VRABC	$PS = 30, mr = 0.9, er_{max} = 0.5, er_{min} = 0.1, rc = 0.1$

Za sve ugrađene metode, pretraga je vođena na osnovu iznosa srednje kvadratne pogreške (engl. *mean squared error*, MSE) dobivenog na podskupu za vrednovanje, a izračunatog kao

$$MSE = \frac{\sum_{j=1}^n \|y_j - e_j\|}{n \cdot m}, \quad (5.11)$$

gdje je y vektor koji predstavlja stvarni izlaz iz mreže, e vektor koji predstavlja očekivani izlaz iz mreže za j -ti uzorak, n broj korištenih uzoraka, a m broj klasa podatkovnog skupa (broj izlaza iz mreže). Za sve algoritme uključene u usporedbu, rješenja su kodirana na jednak način, što je predstavljeno i slikom 5.2. Riječ je o sustavu kodiranja koji ne uključuje težinske faktore pa su oni zato određeni uporabom metode pseudo-inverza. Ovo ne samo

da olakšava pretragu zbog niže dimenzionalnosti rješenja, već analitički određuje najbolje težinske faktore. Kao što je i predstavljeno, u rješenje su ugrađene aktivacijske zastavice koje govore koristi li se neki centar ili ne, lokacija centra te širina njegova utjecaja. Svaki je algoritam tražio klasifikacijske modele s brojem skrivenih čvorova h između $h_{min} = 2$ i $h_{max} = 20$. Dimenzionalnost svakog rješenja unutar populacije prema tome iznosi $h_{max} \cdot (d + 2)$.



Slika 5.2: Prikaz kodiranog rješenja unutar populacije

Za potrebe usporedbe, ugrađena su dva osnovna pristupa zasnovana na algoritmu umjetne kolonije pčela predstavljena u [111]. Prva inačica označena je s MRABC i predstavlja unaprijeđene ABC-a s ugrađenom stopom izmjene. Druga inačica uz stopu izmjene uključuje i samoprilagodljivi faktor skaliranja te nosi oznaku MRASF. Obje ove inačice sadrže unaprijeđenja za lakši rad s velikim brojem parametara koji opisuju problem. Uz ove osnovne pristupe za potrebe analize korišteno je i nekoliko drugih algoritama dostupnih u literaturi. Pristup zasnovan na PSO predstavljen u [126], označen je s PSO, dok onaj predstavljen u [128] koji koristi faktor stezanja nosi oznaku CPSO. Uz navedene, ugrađena je inačica algoritma krijesnica korištena za ove potrebe u [131], a dana joj je oznaka FFA.

5.4.2 Ponašanje VRABC-a na podatkovnom skupu boli

Prvi dio dobivenih rezultata opisuje ponašanje predloženog unaprijeđenog algoritma na podatkovnim skupovima vezanim uz razine boli. Radi preglednijeg prikaza, analiza ponašanja na podatkovnim skupovima bolnih izraza lica podijeljena je na dva dijela, usporedbu s izvornim algoritmima te usporedbu s drugim algoritmima iz literature.

Usporedba s osnovnim pristupom


Rezultati uspješnosti klasifikacije predloženog unaprijeđenog algoritma VRABC u odnosu na MRABC i MRASF prikazani su tablicom 5.2 u obliku prosječnih vrijednosti različitih pokazatelja kvalitete. Moguće je uočiti da se osnovne inačice ovog algoritma vrlo teško nose s danim problemom i u pravilu nude mreže koje imaju slabe performanse, dok predložena unaprijeđena inačica ne iskazuje iste probleme, ima bolje ponašanje te ostvaruje najbolje rezultate. Zamjetno je pritom kod usporedbe dvaju osnovnih algoritama da ugradnja automatske izmjene faktora skaliranja u MRASF-u doprinosi unaprijeđenju kvalitete, no čini se ne u dovoljnoj mjeri. S druge strane, neovisno o skupu podataka koji je razmatran, predloženi algoritam VRABC doveo je do najviše kvalitete klasifikacije po svim mjerama kvalitete. To sugerira da su ugrađene mjere opravdane i da su one razlog boljih ostvarenih rezultata.

Osnovni pristupi, iako prema [111] prilagođeni problemima s visokim brojem parametara, a među koje spada i razmatrani problem raspoznavanja razina boli, ipak u konačnici ne uspijevaju doći do rješenja usporedive kvalitete u odnosu na predloženi algoritam. Naime, s obzirom na izrazito visoku dimenzionalnost problema, točnije 9820 elemenata u pojedinom rješenju, pronalazak rješenja dobrih karakteristika predstavlja vrlo težak zadatak. Kao što je ranije predloženo radi ostvarivanja ciljeva drugog predloženog izvornog znanstvenog doprinosa, pretragu treba snažnije usmjeravati prema rješenjima više kvalitete. Za razliku od predloženog rješenja, dobiveni rezultati pokazuju da osnovne inačice algoritma ABC to ne uspijevaju učiniti u dovoljnoj mjeri.

Tablica 5.2: Postignuta prosječna kvaliteta klasifikacije i broj skrivenih čvorova uporabom algoritama MRABC, MRASF i VRABC prema različitim mjerama kvalitete

Skup	\mathcal{D}_0			\mathcal{D}_1			\mathcal{D}_2			\mathcal{D}_3		
	MRABC	MRASF	VRABC	MRABC	MRASF	VRABC	MRABC	MRASF	VRABC	MRABC	MRASF	VRABC
Acc	0.5644	0.6166	0.7622	0.6034	0.6366	0.7389	0.5487	0.5832	0.6919	0.5697	0.5903	0.7474
FM _{sr}	0.5668	0.6204	0.7668	0.5995	0.6342	0.7376	0.5394	0.5711	0.6896	0.5675	0.5892	0.7491
Pre	0.5695	0.6203	0.7623	0.5993	0.6323	0.7354	0.5409	0.5743	0.6879	0.5702	0.5897	0.7488
Pre	0.5643	0.6206	0.7714	0.5997	0.6362	0.7398	0.5380	0.5681	0.6914	0.5650	0.5887	0.7494
κ	0.3485	0.4251	0.6427	0.4027	0.4524	0.6068	0.3189	0.3707	0.5362	0.3534	0.3835	0.6212
h	13.88	13.24	14.68	15.28	12.32	16.56	14.36	13.68	15.96	14.50	12.96	14.96


Detaljniji uvid u ponašanje pretrage, kao i razlog tome zašto VRABC ostvaruje najbolji rezultat, može se potražiti u konvergencijskim grafovima, prikazanima slikom 5.3. Oni pokazuju medijan MSE najboljeg rješenja unutar populacije u određenim točkama tijekom pretrage, za svih 25 neovisnih izvođenja.




Slika 5.3: Kvaliteta najboljeg rješenja tijekom pretrage za MRABC, MRABC_ASF i VRABC na (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

Vidljivo je iz dane slike da uvedena unaprijeđenja uvelike utječu na pretragu. Iako je ponašanje pretrage u njenim vrlo ranim stadijima slično kao i kod osnovnih algoritama, nakon određenog perioda VRABC pokazuje rast kvalitete najboljeg rješenja. Ovo proizlazi upravo iz stavljanja fokusa na najbolja rješenja dostupna unutar populacije, odnosno naglašavanja iskorištavanja obećavajućih točaka prostora pretrage. S obzirom da je riječ o multimodalnom problemu koji ima brojne lokalne optimume, stalan rast kvalitete pri tome sugerira da uvedeni selekcijski pritisak koji iznudiuje korištenje najboljih rješenja uspijeva u najvećoj mjeri iskoristiti ovaj lokalni optimum. Zastajanje pretrage i nemogućnost iskorištavanja je poteškoća uočena kod algoritma MRABC, dok MRASF ipak uspijeva održati pretragu, no ona napreduje značajno sporije nego je to slučaj s predloženim unaprijeđenim algoritmom.

Informacije o stabilnosti algoritma, odnosno o razdiobi rezultata dostupne su u dijagramima pravokutnika koji su dani slikom 5.4. Navedenom slikom prikazani su dijagrami pravokutnika ostvarenih rezultata u smislu mjere F1, svih neovisnih izvođenja algoritama. Moguće je primijetiti da je za sve korištene podatkovne skupove VRABC ostvario značajno bolje performanse i to prema svim pokazateljima. Posebice zanimljiv je podatak da je za dio skupova najniže ostvareno rješenje predloženim algoritmom bolje od najvišeg ostvarenog os-



Slika 5.4: Usporedba performansi klasifikacije uporabom osnovnih algoritama i predloženog unaprijeđenog algoritma u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3



Slika 5.5: Usporedba broja skrivenih čvorova uporabom osnovnih algoritama i predloženog unaprijeđenog algoritma za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 (c) \mathcal{D}_2 i (d) \mathcal{D}_3

novnim algoritmima. Vidno manji rasponi među najboljim i najlošijim ostvarenim rješenjem ukazuju na to da je algoritam VRABC u stanju stalno pružati dobre performanse što nadalje ukazuje na stabilnost predloženog algoritma. Što se tiče kompleksnosti mreža koje su pronašli pojedini algoritmi, ta je informacija dostupna u dijagramima pravokutnika na slici 5.5. Mahom je riječ o vrlo bliskom broju čvorova kod svih pristupa. U slučaju kada bi postojala značajnija razlika, valjalo bi se zapitati o ostvarenim rješenjima. Međutim, blago viša složenost u svakom se slučaju može smatrati opravdanom zbog osjetno bolje konačno ostvarene kvalitete klasifikacije.

Usporedba s pristupima iz literature

Nakon usporedbe predloženog algoritma VRABC s algoritmima na kojima je zasnovan, pristupilo se analizi njegova ponašanja u odnosu na druge postupke dostupne u literaturi. Usporedni rezultati na skupovima boli dani su tablicom 5.3. Predstavljeni rezultati sugeriraju vrlo visoku učinkovitost predloženog algoritma u odnosu na ostale uključene u usporedbu, neovisno o razmatranom skupu podataka. Razlika u kvaliteti izražena je, naime, na svim podatkovnim skupovima i ide u korist predloženog algoritma. Uočljivo je pri tome da su

postupci oblikovanja zasnovani na algoritmu PSO u stanju ponuditi mreže koje iskazuju značajno povoljnija svojstva glede kvalitete klasifikacije u odnosu na osnovne algoritme zasnovane na ABC-u te su stoga konkurentniji VRABC-u. Navedeno proizlazi iz načina na koji PSO provodi pretragu, usmjeravajući nova rješenja uvijek dijelom i prema trenutnom najboljem rješenju. Ipak, čak i u usporedbi s navedenim algoritmima, vidljivo je da je VRABC uspio ostvariti najbolje rezultate. S obzirom na ranije postignute rezultate, a uzevši u obzir i one ostvarene u usporedbi s konkurentskim pristupima iz literature, može se doći do zaključka da predložena unaprjeđenja tjeraju pretragu prema rješenjima koja predstavljaju radijalne mreže najboljih performansi. Posebice je to uočljivo kod usporedbe s algoritmom FFA koji dijeli probleme algoritama zasnovanih na ABC-u.


Tablica 5.3: Postignuta kvaliteta klasifikacije i broj skrivenih čvorova uporabom algoritama CPSO, PSO, FFA, VRABC prema različitim mjerama kvalitete

Skup	\mathcal{D}_0				\mathcal{D}_1				\mathcal{D}_2				\mathcal{D}_3			
	CPSO	PSO	FFA	VRABC	CPSO	PSO	FFA	VRABC	CPSO	PSO	FFA	VRABC	CPSO	PSO	FFA	VRABC
Acc	0.7181	0.7247	0.5862	0.7622	0.6526	0.7111	0.5943	0.7389	0.6552	0.6585	0.5658	0.6919	0.7111	0.7229	0.5543	0.7474
FMSr	0.7224	0.7284	0.5868	0.7668	0.6449	0.7103	0.5904	0.7376	0.6509	0.6530	0.5520	0.6896	0.7131	0.7245	0.5511	0.7491
Pre	0.7192	0.7255	0.5912	0.7623	0.6479	0.7075	0.5897	0.7354	0.6498	0.6529	0.5559	0.6879	0.7128	0.7245	0.5533	0.7488
Pre	0.7258	0.7313	0.5825	0.7714	0.6432	0.7132	0.5913	0.7398	0.6521	0.6531	0.5484	0.6914	0.7135	0.7246	0.5490	0.7494
κ	0.5766	0.5864	0.3806	0.6427	0.4764	0.5649	0.3888	0.6068	0.4806	0.4857	0.3436	0.5362	0.5666	0.5842	0.3295	0.6212
h	12.76	13.28	11.52	14.68	14.48	13.48	11.96	16.56	14.16	13.24	11.40	15.96	13.32	13.28	11.16	14.96

Kao i ranije, bolji dojam o tijeku pretrage može se steći na temelju konvergencijskih grafova danih slikom 5.6. Moguće je zamijetiti da u svim slučajevima predloženi algoritam ostvaruje najpovoljniju stopu/brzinu konvergencije. Zanimljivo je pritom razmotriti njegovo ponašanje tijekom pretrage.

Iako na početku pretrage uobičajeno PSO i CPSO iskazuju bolje ponašanje, usmjeravanjem pretrage na bolja rješenja predloženi algoritam u kasnijoj fazi ne samo da nadoknađuje prednost koju su ostvarili algoritmi uključeni u usporedbu, već i ostvaruje vidnu prednost. Također je važno uočiti da VRABC ni u jednom od slučajeva nije iskazao stagnaciju prilikom pretrage, što je kod drugih, konkurentnih, pristupa ponekad bio slučaj, primjerice ponašanje CPSO-a na \mathcal{D}_1 .


Za stjecanje potpunog dojma o razdiobi ostvarenih rezultata, moguće je razmotriti dijagrame pravokutnika dane slikom 5.7, nastale na temelju mjere F1 svih neovisnih izvršavanja svakog od algoritama. Njima su potvrđeni, ali i detaljnije prikazani rezultati dani tablicom 5.3. Lakše je na temelju njih uočiti prednost VRABC-a. On je na svim podatkovnim skupovima ostvario najbolje rezultate u smislu medijana mjere F1. Uz navedeno, moguće je uočiti da su svi ekvivalentni pokazatelji među dijagramima pravokutnika performansi algoritama uključenih u eksperimentalnu analizu bolji za predloženi algoritam. Prema pruženim informacijama, moguće je doći do zaključka da predloženi algoritam VRABC pronalazi parametre mreža koji dovode do bolje kvalitete klasifikacije, a posebice važno, uspijeva to činiti s visokom mjerom stabilnosti koja se ogleda u medijanu mjere F1. Zamjetno je da je on stalno na



Slika 5.6: Ponašanje najboljeg rješenja prilikom pretrage za PSO, CPSO, FFA i VRABC na (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

vrlo visokoj razini te da ne iskazuju oscilacije koje su uočljive kod drugih algoritama.

Slikom 5.8 prikazani su dijagrami pravokutnika za broj čvorova u skrivenom sloju mreže. Vidljivo je da je broj čvorova u skrivenom sloju blizak za sve postupke uključene u usporedbu, a riječ je uglavnom o razlici od jednog do dva skrivena čvora više koje je koristio VRABC. Ova mala razlika, u kontekstu boljitka koje predloženi algoritam donosi u pogledu performansi, beznačajna je. Štoviše, u nekim slučajevima drugi su algoritmi pronalazili i veće mreže od predloženog algoritma, a rasponi vrijednosti između najmanje i najveće oblikovane radialne mreže vidno su veći nego kod predloženog algoritma. Ovo je posebice važno radi činjenice da je korišten isti podatkovni skup, a jedina razlika je u odabranim subjektima i njihovim uključenim slikama. Prema tome, može se zaključiti da VRABC uspijeva pronaći odgovarajući broj skrivenih čvorova konzistentno i prilagoditi parametre mreže problemu koji se rješava. Oscilacije koje iskazuju konkurentni algoritmi sugeriraju da oni ipak nisu u stanju pronaći odgovarajući broj centara. Dodatno, ukoliko se za istim ukaže potreba, moguće je prilagoditi i funkciju cilja da uključuje kažnjavanje mreža s većim brojem aktivnih centara, odnosno čvorova u skrivenom sloju, kao što je primjerice učinjeno u [109].




Slika 5.7: Usporedba performansi uporabom algoritama iz literature i predloženog unaprijeđenog algoritma u smislu mjere F1 za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

5.4.3 Ponašanje VRABC-a na standardnim skupovima podataka

Iskazano ponašanje na problemu raspoznavanja razina boli sugerira korist od predloženog unaprijeđenog algoritma kod problema visoke dimenzionalnosti. Dodatna analiza provedena je uporabom standardnih podatkovnih skupova, koji opisuju probleme iz različitih domena. Ovi podatkovni skupovi preuzeti su s repozitorija za strojno učenje sveučilišta Irvine u Kaliforniji [112]. Karakteristike podatkovnih skupova dane su tablicom 4.8. Analiza je provedena na jednak način kao i kod podatkovnog skupa razina boli, a u usporedbu su uključeni svi algoritmi korišteni u usporednoj analizi u prethodnim potpoglavljima.

Detaljni uvid u rezultate omogućen je tablicom 5.4, u smislu mjere F1, dok su tablicom 5.5 dani brojevi čvorova u skrivenom sloju oblikovanih mreža. Grafički su odnosi među algoritmima prikazani slikom 5.9, za mjeru F1, i slikom 5.10, za broj čvorova u skrivenom sloju, gdje su razlike lako uočljive.

Iz prikazanih rezultata primjetno je da je predloženi unaprijeđeni algoritam u većini slučajeva, odnosno na većini podatkovnih skupova, ostvario bolje rezultate od konkurentnih pristupa. Posebice je ova prednost izražena kod podatkovnih skupova više dimenzionalnosti,



Slika 5.8: Usporedba broja skrivenih čvorova uporabom algoritama iz literature i predloženog unaprijeđenog algoritma za (a) \mathcal{D}_0 , (b) \mathcal{D}_1 , (c) \mathcal{D}_2 i (d) \mathcal{D}_3

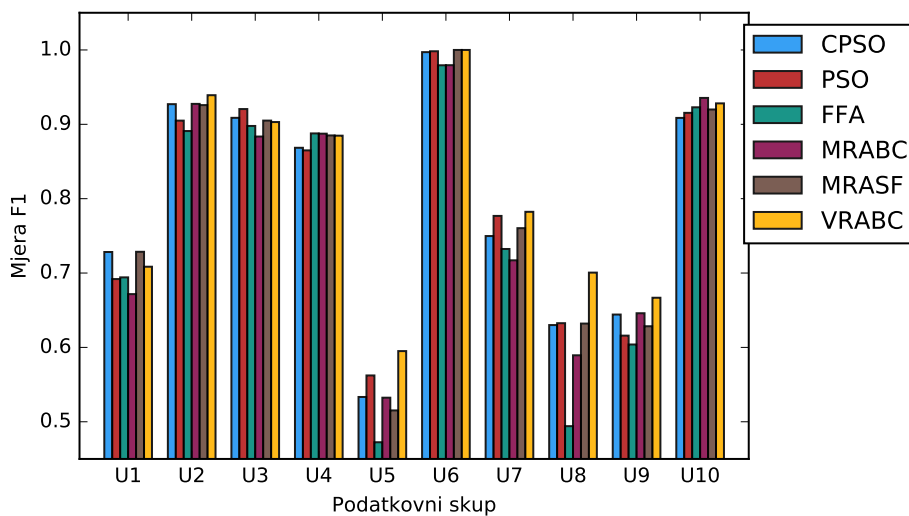
Tablica 5.4: Performanse osnovnih i inačica omotača s ugrađenim unaprijeđenjem na standardnim skupovima podataka

	CPSO	PSO	FFA	MRABC	MRASF	VRABC
\mathcal{U}_1	0.7283	0.6919	0.6942	0.6717	0.7286	0.7085
\mathcal{U}_2	0.9271	0.9050	0.8910	0.9275	0.9258	0.9392
\mathcal{U}_3	0.9087	0.9205	0.8978	0.8835	0.9050	0.9030
\mathcal{U}_4	0.8684	0.8649	0.8878	0.8874	0.8850	0.8847
\mathcal{U}_5	0.5333	0.5623	0.4725	0.5324	0.5152	0.5950
\mathcal{U}_6	0.9971	0.9982	0.9794	0.9795	1.0000	1.0000
\mathcal{U}_7	0.7497	0.7768	0.7323	0.7171	0.7603	0.7823
\mathcal{U}_8	0.6300	0.6325	0.4941	0.5894	0.6320	0.7006
\mathcal{U}_9	0.6442	0.6158	0.6039	0.6459	0.6284	0.6668
\mathcal{U}_{10}	0.9086	0.9154	0.9229	0.9355	0.9199	0.9282


što je i očekivano s obzirom na ranije rezultate ostvarene na podatkovnim skupovima razina boli. Budući da VRABC usmjerava pretragu ka boljim rješenjima, on tako omogućuje finiju pretragu obećavajućeg prostora oko njih. Ovo je, čini se, nužno da bi se unaprijedila kvaliteta klasifikacije za probleme visoke dimenzionalnosti. S druge pak strane, na problemima niže dimenzionalnosti VRABC nije toliko uspješan, ali ovdje istovremeno nije moguće govoriti niti o istaknutoj prednosti nekog od ostalih algoritama korištenih u eksperimentalnoj analizi. Naime, njihovo ponašanje i rezultati variraju u ovisnosti o problemu pa tako postoje podatkovni skupovi za koje svaki od konkurenata ostvaruje najpovoljnije rezultate. Nave-

Tablica 5.5: Usporedba broja skrivenih čvorova u mrežama predloženog algoritma VRABC i ostalih algoritama iz usporedbe

	CPSO	PSO	FFA	MRABC	MRASF	VRABC
\mathcal{U}_1	14.28	13.80	8.96	10.36	9.60	12.68
\mathcal{U}_2	17.28	15.76	12.12	16.76	14.04	18.04
\mathcal{U}_3	17.68	17.64	12.36	17.68	15.92	18.68
\mathcal{U}_4	14.56	14.52	11.00	12.64	13.44	14.96
\mathcal{U}_5	16.64	17.16	13.56	17.16	16.44	18.68
\mathcal{U}_6	15.16	15.24	10.48	15.32	13.04	15.00
\mathcal{U}_7	14.12	13.68	10.64	13.00	13.48	14.80
\mathcal{U}_8	15.20	15.64	13.24	16.96	15.00	18.48
\mathcal{U}_9	11.92	12.96	10.32	11.76	12.24	12.72
\mathcal{U}_{10}	14.72	14.84	10.00	13.00	12.56	14.76



Slika 5.9: Usporedba performansi uporabom predloženog unaprijeđenog algoritma i ostalih algoritama za skupove $\mathcal{U}_1, \mathcal{U}_2, \dots, \mathcal{U}_{10}$ u smislu mjere F1



Slika 5.10: Usporedba broja čvorova u skrivenom sloju mreže uporabom predloženog unaprijeđenog algoritma i ostalih algoritama za skupove $\mathcal{U}_1, \mathcal{U}_2, \dots, \mathcal{U}_{10}$

deno ukazuje da je riječ o vrlo konkurentnim algoritmima, što se možda, na prvi pogled, ne bi moglo zaključiti prema rezultatima na problemu raspoznavanja razina boli. Što se tiče dimenzionalnosti mreža koje su pronađene, primjetno je da u prosjeku najmanje mreže pronalazi algoritam FFA, dok mreže s najviše čvorova u skrivenom sloju pronalazi predloženi algoritam, VRABC. Razlika u broju skrivenih čvorova između VRABC-a i ostalih algoritama u usporedbi je vrlo malena, a s obzirom na unaprjeđenje kvalitete raspoznavanja, u svakom su slučaju dodatni uključeni čvorovi opravdani. Posebice je to izraženo kod problema visoke dimenzionalnosti, poput $\mathcal{U}_7, \mathcal{U}_8$ i \mathcal{U}_9 .

5.5 Osvrt na predloženi algoritam

Oblikovanje klasifikacijskog modela predstavlja najvažniji korak u klasifikacijskoj proceduri. Izbor odgovarajućih parametara ima snažan utjecaj na krajnji rezultat i na mogućnost klasifikatora da donese ispravne odluke o klasi uzorka. Prva vodilja kod oblikovanja klasifikacijskog modela RBFN-a jest kvaliteta rezultata, a uz navedeno je potrebno težiti i modelima niže složenosti. S navedenim ciljevima u vidu predložen je algoritam za oblikovanje klasifikacijskog modela radijalne neuronske mreže zasnovan na algoritmu umjetne kolonije pčela. Unaprjeđenje algoritma predstavlja izmjena pretrage, odnosno njenog dijela koji se tiče iskorištavanja obećavajućih točaka unutar prostora pretrage. Uveden je prozor koji diktira odabir jednog između nekoliko najboljih rješenja te stopa razmjene koja kontrolira udio izmjene rješenja, kao i uvođenje relativno kvalitetnih rješenja u populaciju. Time je napravljen pokušaj da se pretraga usmjeri ka dobrim rješenjima i u njihovoj okolini pokuša pronaći ono najbolje. Predstavljeno je nekoliko prirodno inspiriranih algoritama, korištenih u literaturi upravo za oblikovanje klasifikacijskog modela RBFN-a, te je predloženi unaprijeđeni algoritam uspoređen s njima u svrhu istraživanja njegovih mogućih prednosti i eventualnih nedostataka.

Na podatkovnim skupovima koji se tiču raspoznavanja razina boli, predloženi unaprijeđeni algoritam je u pravilu pronalazio najbolje mreže u smislu kvalitete klasifikacije. Uz to, uspijevaio je ostvarivati dobre rezultate neovisno o izboru subjekata, što sugerira da bi i kod drugačije podjele osnovnog skupa trebao iskazati slično ponašanje. U odnosu na osnovne pristupe na kojima je utemeljen, ponudio je značajno bolju kvalitetu pretrage, što se očitovalo u konvergencijskim grafovima gdje se ne uočava stagnacija ili prekid napredovanja pretrage. Ova pretraga dovela je do značajno boljih konačnih rezultata klasifikacije u odnosu na osnovne pristupe. U usporedbi s drugim pristupima dostupnim u literaturi, predloženi unaprijeđeni algoritam zadržao je sva dobra svojstva kao i ranije. Naime, iako su se neki od pristupa pokazali uistinu konkurentnima, posebice oni zasnovani na algoritmu PSO, predloženi je algoritam ostvario u većini slučajeva najbolje rezultate. Iako je tijekom pretrage u njenim ranijim stadijima išao u prilog pristupima iz literature, VRABC je uspio

usmjeravanjem na bolja rješenja i vođenjem pretrage prema istima dostići, a u konačnici bez iznimke i prestići, kvalitetu rješenja u smislu funkcije cilja svih pristupa iz usporedbe, što svakako podupire predložene izmjene.

Broj čvorova u skrivenom sloju mreže bio je blizak za sve algoritme uključene u usporednu analizu. Razlika se među njima ogledala u jednom ili dva skrivena čvora više kod VRABC-a. S obzirom na unaprjeđenje kvalitete raspoznavanja, navedena razlika nije presudno bitna. Uvođenje dodatnih čvorova očigledno je dovelo do pospješivanja klasifikacije. Također, dubljim uvidom u strukturu rezultata koji se tiču dimenzija mreže, uočava se zanimljiv trend. Predloženi unaprijeđeni algoritam je kod problema raspoznavanja boli uglavnom pronalazio mreže iste ili vrlo slične veličine, bez obzira na početnu populaciju rješenja i bez obzira na podatkovni skup. Ovo ipak nije bio slučaj kod konkurentnih pristupa, što se očitovalo zamjetno većim rasponom broja čvorova u skrivenom sloju po pojedinim izvođenjima eksperimenta. Sve navedeno sugerira da je VRABC bio u stanju pronaći mrežu odgovarajuće složenosti te ju prilagoditi problemu. Bitno se također osvrnuti i na broj parametara koji su kontrolirali pretragu kod VRABC-a. Iako u odnosu na osnovni algoritam VRABC zahtijeva postavljanje većeg broja parametara, većina njih definirana je u rasponima vrijednosti što osjetno ublažava potrebu za određivanjem njihovih vrijednosti. Sveukupni rezultati eksperimentalnog vrednovanja navode tako na zaključak da je treći predloženi izvorni znanstveni doprinos uspješno ostvaren.

U daljnjem istraživanju bilo bi dobro usredotočiti se na parametre koji određuju izmjenu rješenja prilikom iskorištavanja obećavajućih regija. Iako neki prijedlozi dani na temelju eksperimentalne analize, ove vrijednosti dobro je prilagoditi problemu koji se rješava. Za to je ostavljen i prostor unutar algoritma, s obzirom da će kod nekih problema pretjerano iskorištavanje vrlo vjerojatno dovesti do prerane konvergencije. Također, uvođenje rješenja nastalih grupiranjem moguće je nadalje prilagoditi. U predloženom unaprijeđenom algoritmu, rješenja koja su iskazala najviši stupanj istrošenosti, zamijenjivana su s malom vjerojatnošću. Ovaj korak moguće je prilagoditi potrebi, primjerice zamjenom samo najboljeg ili najlošijeg rješenje. Međutim, moguće je i na neki drugi način osigurati da pretraga napreduje prema obećavajućim točkama prostora.

Zaključak

*"Some people worry that artificial intelligence will make us feel inferior, but then, anybody in his right mind should have an inferiority complex every time he looks at a flower.
- Alan Kay*

RASPOZNAVANJE uzoraka zadaća je s kojom se čovjek svakodnevno suočava, a gotovo neprimjetno ju obavlja iskorištavajući urođenu sposobnost smještanja stvari u kategorije. Kada se isti zadatak povjeri računalu, odnosno kakvom računalnom sustavu, tada je potrebno uložiti znatno više truda i pripreme da bi se on uspješno riješio. Iako je riječ o jednom od osnovnih zadataka s kojima se moguće susresti u medicini, raspoznavanje boli uz pomoć računalnih sustava i dalje predstavlja otvoren problem, upravo iz ranije spomenutih razloga. S obzirom da je riječ o problemu iz područja klasifikacije, rješavanje ovog problema uglavnom se pokušava postići različitim postupcima strojnog učenja. Da bi se provela klasifikacijska procedura, najprije se izdvajaju značajke iz izvornih podataka. Kao dobar izvor podataka pokazale su se slike lica, kako u srodnim područjima poput raspoznavanja emocija, tako i kod problema raspoznavanja razina boli. Riječ je o vrlo informativnom modalitetu podataka, s obzirom da se bol, baš kao i emocije, najlakše očituje u pomacima mišićnih skupina lica. Budući da se razina boli kod pacijenata danas određuje na temelju upitnika ili samoizvješćivanja, gdje se manja važnost pridaje promatranju bolnih ponašanja, ne čudi

postojanje zamjerki vezanih uz subjektivnost procjene. Valja pri tome stalno imati na umu da je riječ o vrlo složenom fenomenu. Uvođenje podrške u obliku računalnog sustava zasnovanog na postupcima strojnog učenja omogućilo bi lakšu, bržu, objektivniju i sigurniju procjenu razine boli.

U ovoj disertaciji, imajući u vidu brojne poteškoće s kojima se moguće susresti prilikom rješavanja problema raspoznavanja razina boli, predloženi su zahvati koji ulaze u pojedine korake klasifikacijske procedure. Oni imaju za cilj unaprjeđivanje koraka u koje su ugrađeni, s namjerom da se u konačnici pospješi raspoznavanje razina boli na temelju slika bolnih izraza lica. Tako su predloženi postupak izdvajanja značajki, metoda odabira značajki te algoritam za oblikovanje klasifikacijskog modela.

Postupak izdvajanja značajki iz izvornih podataka predstavlja, nakon prikupljanja samih podataka, prvi važan korak klasifikacijske procedure. Kao prvi izvorni znanstveni doprinos predložen je i razvijen postupak izdvajanja značajki upravo iz slika lica koje prikazuju bolne izraze. Predloženi postupak oslanja se na pozitivna svojstva shearlet transformacije te na osnovu njenih koeficijenata kreira vektore značajki kojima opisuje bolan izraz lica. Analiza mogućnosti raspoznavanja razina boli uporabom vektora značajki, dobivenih razvijenim postupkom, provedena je na standardnom skupu podataka iz literature, bazi slika bolnih izraza lica UNBC-McMasters prikupljenoj u kliničkom okruženju. S ciljem usporedbe, na temelju izvornih slika kreirani su podatkovni skupovi, kako predloženim postupkom, tako i uporabom nekoliko postupaka iz literature namijenjenih navedenoj potrebi. Analiza je provedena metodom izostavljanja subjekta, a uporabom nekoliko pouzdanih i u literaturi često korištenih algoritama za klasifikaciju s različitim svojstvima. U većini slučajeva, vektori značajki dobiveni razvijenim postupkom izdvajanja značajki doveli su do boljih performansi prilikom klasifikacije. Uzevši u obzir dimenzionalnost vektora značajki koja je znatno niža u usporedbi s postupcima bliskim po performansama, moguće je zaključiti da je korištenje predloženog postupka opravdano i dovodi do unaprjeđenja raspoznavanja razina boli čime je prvi izvorni znanstveni doprinos ostvaren.

Uključivanje značajki intuitivnim pristupom, prema kojem više podataka istovremeno znači i bolju konačnu diskriminaciju među uzorcima različitih klasa, nije rijedak slučaj kod rješavanja klasifikacijskih problema. S obzirom da je često nemoguće unaprijed znati koje će značajke dovesti do najboljih performansi, a također je moguće uključiti značajke koje će performanse narušiti ili na njih neće imati nikakva utjecaja, nerijetko se kao korak predobrane koriste različite metode odabira značajki. Kao drugi izvorni znanstveni doprinos u ovoj doktorskoj disertaciji predložena je upravo jedna takva metoda, ftFS, zasnovana na praćenju doprinosa pojedinačnih značajki. Naime, uočeno je da pretraga za najboljim podskupom značajki uporabom omotača, procijeni velik broj različitih podskupova pokušavajući pronaći onaj najpovoljniji. Namjera je iskoristiti informacije sadržane u svim rješenjima, čak

i onima koja se odbacuju, o tome koje se značajke često pojavljuju uključene ili isključene u podskupovima visoke i niske kvalitete. Predložena metoda uzima u obzir tijekom pretrage te bilježi značajke koje iskazuju opisano ponašanje. U konačnici, odabiru se i odbacuju značajke prema učestalosti pojave ili izostanka u podskupovima koji su doveli do visoke, odnosno niske kvalitete raspoznavanja. Radi utvrđivanja opravdanosti metode ftFS, provedena je eksperimentalna analiza na ranije opisanom skupu podataka tijekom koje je predloženo unaprjeđenje ugrađeno u nekoliko različitih omotača iz literature. Konkretno, metoda ftFS ugrađena je u tri prirodno inspirirana algoritma prilagođena za postupak odabira značajki te dvije osnovne inačice. Uvidom u rezultate, uočeno je da značajke koje odabire ftFS u pravilu održavaju i unaprjeđuju kvalitetu klasifikacije, a postižu to korištenjem osjetno nižeg broja značajki od konkurentskih pristupa. S obzirom da ftFS ne zahtijeva dodatna vrednovanja funkcije cilja te ni u kom obliku ne narušava proces pretrage osnovnog algoritma, može se zaključiti da je riječ o pogodnom i opravdanom unaprjeđenju. Dodatna analiza, provedena na problemima iz različitih domena, sugerira da predloženo rješenje, ne samo ostvaruje u većini slučajeva najbolje rezultate, već ne stavlja pretjeran pritisak na odbacivanje značajki. Ovo se očituje u tome što su kod dijela podatkovnih skupova ostvarene bolje performanse uz veći broj korištenih značajki u odnosu na druge metode. Prema tome, vektori značajki niže dimenzionalnosti ne ostvaruju se nauštrb kvalitete klasifikacije. S obzirom na navedeno, drugi predloženi izvorni doprinos može se smatrati ostvarenim.

Odabir i treniranje klasifikatora, odnosno oblikovanje klasifikacijskog modela, predstavljaju ključan korak klasifikacijske procedure. S obzirom da RBFN predstavlja pouzdan i čest izbor za potrebe klasifikacije, predložen je u sklopu ove doktorske disertacije, kao treći izvorni znanstveni doprinos, algoritam za oblikovanje klasifikacijskog modela radijalne neuronske mreže, VRABC. Riječ je o algoritmu razvijenom na osnovu algoritma ABC, dodatno prilagođenom za problem raspoznavanja razina boli. Spomenute prilagodbe uključuju snažnije usmjeravanje pretrage ka obećavajućim točkama unutar prostora pretrage, a uz to i promjenu načina stvaranja rješenja koje se uvodi u populaciju. Usmjeravanje pretrage ostvareno je u drugoj fazi algoritma ABC, gdje za razliku od osnovnog pristupa, izmijenjena rješenja nastaju na osnovu odabranog rješenja iz populacije i nasumično odabranog rješenja među nekoliko najboljih. Broj razmatranih najboljih rješenja, kao i intenzitet promjena, smanjuju se linearno kako pretraga napreduje. Cilj ovog smanjenja je omogućiti snažnije iskorištavanje, bez pretjeranog narušavanja istraživanja, povećavajući time izgleda za pronalazak boljih rješenja u kasnijim fazama pretrage. Izmjena načina stvaranja novih rješenja koja se uvode u populaciju, ostvarena je u trećoj fazi algoritma ABC. Za razliku od u potpunosti nasumičnih rješenja kakva se stvaraju u osnovnom algoritmu, predložena izmjena koristi grupiranje svih rješenja u populaciji uporabom algoritma k -means. Tako stvorena rješenja u pravilu imaju značajno višu kvalitetu, u smislu funkcije cilja, od onih nasumično stvorenih. Zamjenom onih rješenja koja unutar populacije najdulje nisu iskazala napredak, pokušava se izbjeći

stagniranje pretrage uz njeno daljnje fokusiranje na točke prostora pretrage predstavljene najboljim rješenjima. Ostvareni rezultati na opisanom podatkovnom skupu bolnih izraza lica ukazuju na opravdanost predloženih izmjena. Algoritam VRABC ostvario je najbolje rezultate između svih uključenih u eksperimentalnu analizu. Usporedbom na problemima iz drugih domena, a uzimajući u obzir i rezultate ostvarene na podatkovnom skupu razina boli, razvidno je da algoritam VRABC iskazuje najbolje ponašanje na podatkovnim skupovima visoke dimenzionalnosti, kakav sasvim sigurno jest i podatkovni skup za raspoznavanje razina boli. Na osnovu provedene eksperimentalne analize te dobivenih i prikazanih rezultata, moguće je doći do zaključka da je treći predloženi izvorni znanstveni doprinos i ostvaren.

Prema opisanom, predloženi su i ostvareni postupak za izdvajanje značajki zasnovan na shearlet transformaciji, metoda za odabir značajki praćenjem njihova doprinosa te unaprijeđeni algoritam za oblikovanje klasifikacijskog modela radijalne neuronske mreže. Da bi se računalno raspoznavanje boli još više približilo uporabi u svakodnevnoj kliničkoj praksi, istraživanje je moguće nastaviti u smjeru koji je zadan u ovoj doktorskoj disertaciji. Cilj je u prvom redu unaprijediti kvalitetu raspoznavanja, a jedan od mogućih koraka jest i prikupljanje dodatnih podataka. Korištenje podataka drugih modaliteta predstavlja jednu od glavnih mogućnosti unaprijeđenja, posebice naglašenu u kontekstu primjene neinvazivnih senzora. Kod izdvajanja značajki moguće se osloniti i na postupke dubinske analize podataka te integracijom značajki dobivenih na nenadziran način provesti fuziju na razini podataka. S obzirom na rastuću popularnost uporabe dubinskog učenja za različite probleme, izgledno je da bi navedeno pospješilo raspoznavanje razina boli. Što se tiče klasifikacijskih modela i klasifikatora koji bi mogli biti korišteni, fuzija na razini odluke pokazuje se dobrim izborom kod složenih problema. Različiti ansambli klasifikatora omogućuju nadomještanje nedostataka pojedinačnih klasifikatora. U tom se pogledu može iskoristiti klasifikacijski model radijalne neuronske mreže oblikovan predloženim unaprijeđenim algoritmom umjetne kolonije pčela kao jedan od dijelova većeg klasifikacijskog sustava. Također, dobro ponašanje koje je spomenuti algoritam ostvario prilikom oblikovanja RBFN-a moguće je potencijalno iskoristiti i za izgradnju drugačijih klasifikacijskih modela, što svakako predstavlja jedan od mogućih smjerova daljnjeg istraživanja. U konačnici, raspoznavanje razina boli je problem koji traži značajan trud i povezivanje napora, kako računalnih znanosti, tako i medicine pa i drugih područja, poput primjerice psihologije. Iako je riječ o vrlo zahtjevnom zadatku, oslanjanje na postupke strojnog učenja, njihovo unaprijeđivanje te prilagodba predstavlja dobar smjer istraživanja i sasvim sigurno će dovesti korak bliže njegovu rješavanju.

Literatura

- [1] R. Ahmed, M. El Sayed, S. A. Gadsden, J. Tjong, i S. Habibi, “Automotive internal-combustion-engine fault detection and classification using artificial neural network techniques,” *IEEE Transactions on Vehicular Technology*, sv. 64, br. 1, str. 21–33, 2015.
- [2] X. Jiang i J. Lai, “Sparse and dense hybrid representation via dictionary decomposition for face recognition,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, sv. 37, br. 5, str. 1067–1079, 2015.
- [3] B. Zheng, S. W. Myint, P. S. Thenkabail, i R. M. Aggarwal, “A support vector machine to identify irrigated crop types using time-series landsat ndvi data,” *International Journal of Applied Earth Observation and Geoinformation*, sv. 34, str. 103–112, 2015.
- [4] M. S. Hossain i G. Muhammad, “Cloud-assisted speech and face recognition framework for health monitoring,” *Mobile Networks and Applications*, sv. 20, br. 3, str. 391–399, 2015.
- [5] S. Zhou, J. Shi, J. Zhu, Y. Cai, i R. Wang, “Shearlet-based texture feature extraction for classification of breast tumor in ultrasound image,” *Biomedical Signal Processing and Control*, sv. 8, br. 6, str. 688–696, 2013.
- [6] G. Valenza, C. Gentili, A. Lanata, i E. P. Scilingo, “Mood recognition in bipolar patients through the psyche platform: Preliminary evaluations and perspectives,” *Artificial Intelligence in Medicine*, sv. 57, br. 1, str. 49–58, 2013.
- [7] L. A. Colvin, *ABC of Pain*. John Wiley & Sons, 2012.
- [8] K. M. Prkachin, “Pain behaviour is not unitary,” *Behavioral and Brain Sciences*, sv. 9, br. 4, str. 754–755, Feb 2010.
- [9] S. Theodoridis i K. Koutroumbas, *Pattern Recognition, Fourth Edition*, 4 izd. Academic Press, 2008.

- [10] R. O. Duda, P. E. Hart, i D. G. Stork, *Pattern classification*. John Wiley & Sons, 2012.
- [11] R. W. Picard i R. Picard, *Affective computing*. MIT press Cambridge, 1997, sv. 252.
- [12] A. Luneski, E. Konstantinidis, i P. D. Bamidis, “Affective medicine a review of affective computing efforts in medical informatics,” *Methods of Information in Medicine*, sv. 49, br. 3, str. 207–218, 2010.
- [13] A. Luneski, P. D. Bamidis, i M. Hitoglou-Antoniadou, “Affective computing and medical informatics: State of the art in emotion-aware medical applications.” u *MIE*, ser. *Studies in Health Technology and Informatics*, S. K. Andersen, G. O. Klein, S. Schulz, i J. Aarts, Ur., sv. 136, str. 517–522, 2008.
- [14] S. Alghowinem, R. Goecke, M. Wagner, G. Parker, i M. Breakspear, “Eye movement analysis for depression detection,” u *Image Processing, 2013 20th IEEE International Conference on*, str. 4220–4224, 2013.
- [15] J. Joshi, A. Dhall, R. Goecke, i J. Cohn, “Relative body parts movement for automatic depression analysis,” u *Proceedings of the Humaine Association Conference on Affective Computing and Intelligent Interaction*, str. 492–497, 2013.
- [16] T. Kostoulas, I. Mporas, O. Kocsis, T. Ganchev, N. Katsaounos, J. J. Santamaria, S. Jimenez-Murcia, F. Fernandez-Aranda, i N. Fakotakis, “Affective speech interface in serious games for supporting therapy of mental disorders,” *Expert Systems with Applications*, sv. 39, br. 12, str. 11 072 – 11 079, 2012.
- [17] D. Tsiopela i A. Jimoyiannis, “Pre-vocational skills laboratory: Development and investigation of a web-based environment for students with autism,” *Procedia Computer Science*, sv. 27, str. 207 – 217, 2014, 5th International Conference on Software Development and Technologies for Enhancing Accessibility and Fighting Info-exclusion.
- [18] A. Sano i R. W. Picard, “Stress recognition using wearable sensors and mobile phones,” *Humaine Association Conference on Affective Computing and Intelligent Interaction*, str. 671–676, 2013.
- [19] J. Chen, B. Hu, N. Li, C. Mao, i P. Moore, “A multimodal emotion-focused e-health monitoring support system,” u *Proceedings of the 7th International Conference on Complex, Intelligent, and Software Intensive Systems*, str. 505–510, 2013.
- [20] H. Merskey i N. Bogduk, *Classification of Chronic Pain: Descriptions of Chronic Pain Syndromes and Definitions of Pain Terms*. IASP Press, 1994.

- [21] S. Mardy, Y. Miura, F. Endo, I. Matsuda, i Y. Indo, "Congenital insensitivity to pain with anhidrosis (CIPA): effect of TRKA (NTRK1) missense mutations on autophosphorylation of the receptor tyrosine kinase for nerve growth factor," *Human molecular genetics*, sv. 10, br. 3, str. 179–188, 2001.
- [22] F. J. Keefe i S. Smith, "The assessment of pain behavior: Implications for applied psychophysiology and future research directions," *Applied Psychophysiology and Biofeedback*, sv. 27, br. 2, str. 117–127, 2002.
- [23] K. A. Puntillo, A. B. Morris, C. L. Thompson, J. Stanik-Hutt, C. A. White, i L. R. Wild, "Pain behaviors observed during six common procedures: results from thunder project ii," *Critical care medicine*, sv. 32, br. 2, str. 421–427, 2004.
- [24] A. E. Dubin i A. Patapoutian, "Nociceptors: the sensors of the pain pathway," *The Journal of clinical investigation*, sv. 120, br. 11, str. 3760–3772, 2010.
- [25] T. R. P. M. Group, "Understanding nociceptive & neuropathic pain," <http://www.helpforpain.com/arch2000dec.htm>, pristupljeno: 2016-09-10.
- [26] R. Melzack, "Pain and the neuromatrix in the brain," *Journal of dental education*, sv. 65, br. 12, str. 1378–1382, 2001.
- [27] P. Rainville, "Brain mechanisms of pain affect and pain modulation," *Current opinion in neurobiology*, sv. 12, br. 2, str. 195–204, 2002.
- [28] D. C. Turk i R. Melzack, *Handbook of pain assessment*. Guilford Press, 2011.
- [29] B. Kulkarni, D. Bentley, R. Elliott, P. J. Julyan, E. Boger, A. Watson, Y. Boyle, W. El-Dereby, i A. K. P. Jones, "Arthritic pain is processed in brain areas concerned with emotions and fear," *Arthritis & Rheumatism*, sv. 56, br. 4, str. 1345–1354, 2007.
- [30] B. Zorić i G. Martinović, "Classification methods in affective computing for pain assessment," *International Journal of Pattern Recognition and Artificial Intelligence*, 2016, in Press.
- [31] P. Ekman i E. L. Rosenberg, *What the face reveals: Basic and applied studies of spontaneous expression using the Facial Action Coding System (FACS)*. Oxford University Press, USA, 1997.
- [32] K. M. Prkachin i P. E. Solomon, "The structure, reliability and validity of pain expression: Evidence from patients with shoulder pain," *Pain*, sv. 139, br. 2, str. 267–274, 2008.
- [33] P. Werner, A. Al-Hamadi, R. Niese, S. Walter, S. Gruss, i H. C. Traue, "Towards pain monitoring: Facial expression, head pose, a new database, an automatic system and

- remaining challenges,” u Proceedings of the British Machine Vision Conference, str. 119–1, 2013.
- [34] C. Florea, L. Florea, R. Butnaru, A. Bandrabur, i C. Vertan, “Pain intensity estimation by a self-taught selection of histograms of topographical features,” *Image and Vision Computing*, sv. 56, str. 13 – 27, 2016.
- [35] P. Lucey, J. F. Cohn, K. M. Prkachin, P. E. Solomon, i I. Matthews, “Painful data: The unbc-mcmaster shoulder pain expression archive database,” u Proceedings of the International Conference on Automatic Face & Gesture Recognition and Workshops, str. 57–64, 2011.
- [36] S. Walter, S. Gruss, H. Ehleiter, J. Tan, H. C. Traue, P. Werner, A. Al-Hamadi, S. Crawcour, A. O. Andrade, i G. Moreira da Silva, “The BioVid heat pain database data for the advancement and systematic validation of an automated pain recognition system,” u Proceedings of the International Conference on Cybernetics, str. 128–131, 2013.
- [37] S. Brahnam, C.-F. Chuang, F. Y. Shih, i M. R. Slack, “SVM classification of neonatal facial images of pain,” u *Fuzzy Logic and Applications*. Springer, 2005, str. 121–128.
- [38] S. Koelstra, C. Muhl, M. Soleymani, J.-S. Lee, A. Yazdani, T. Ebrahimi, T. Pun, A. Nijholt, i I. Patras, “DEAP: A database for emotion analysis using physiological signals,” *IEEE Transactions on Affective Computing*, sv. 3, br. 1, str. 18–31, 2012.
- [39] T. Banziger i K. Scherer, “Using actor portrayals to systematically study multimodal emotion expression: The GEMEP corpus,” u *Affective Computing and Intelligent Interaction*, ser. Lecture Notes in Computer Science, A. Paiva, R. Prada, i R. Picard, Ur. Springer Berlin Heidelberg, 2007, sv. 4738, str. 476–487.
- [40] S. M. Mavadati, M. H. Mahoor, K. Bartlett, P. Trinh, i J. F. Cohn, “DISFA: A spontaneous facial action intensity database,” *IEEE Transactions on Affective Computing*, sv. 4, br. 2, str. 151–160, 2013.
- [41] P. Lucey, J. Cohn, T. Kanade, J. Saragih, Z. Ambadar, i I. Matthews, “The extended cohn-kanade dataset (CK+): A complete dataset for action unit and emotion-specified expression,” u Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, str. 94–101, June 2010.
- [42] S. Petridis, B. Martinez, i M. Pantic, “The MAHNOB laughter database,” *Image and Vision Computing Journal*, sv. 31, br. 2, str. 186–202, February 2013.

- [43] M. Soleymani, J. Lichtenauer, T. Pun, i M. Pantic, "A multimodal database for affect recognition and implicit tagging," *IEEE Transactions on Affective Computing*, sv. 3, str. 42–55, April 2012, issue 1.
- [44] G. Mckeown, M. F. Valstar, R. Cowie, M. Pantic, i M. Schroeder, "The semaine database: Annotated multimodal records of emotionally coloured conversations between a person and a limited agent," *IEEE Transactions on Affective Computing*, sv. 3, str. 5–17, April 2012, issue 1.
- [45] S. Wang, Z. Liu, Z. Wang, G. Wu, P. Shen, S. He, i X. Wang, "Analyses of a multimodal spontaneous facial expression database," *IEEE Transactions on Affective Computing*, sv. 4, br. 1, str. 34–46, 2013.
- [46] Z. Hammal i J. F. Cohn, "Automatic detection of pain intensity," u *Proceedings of the 14th ACM International Conference on Multimodal Interaction*, str. 47–52, 2012.
- [47] S. Kaltwang, O. Rudovic, i M. Pantic, "Continuous pain intensity estimation from facial expressions," u *Proceedings of the International Symposium on Visual Computing*, str. 368–377, 2012.
- [48] P. Lucey, J. Cohn, S. Lucey, S. Sridharan, i K. M. Prkachin, "Automatically detecting action units from faces of pain: Comparing shape and appearance features," u *In proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, str. 12–18, 2009.
- [49] M. Sokolova i G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing & Management*, sv. 45, br. 4, str. 427–437, 2009.
- [50] P. Flach, *Machine learning: the art and science of algorithms that make sense of data*. Cambridge University Press, 2012.
- [51] R. E. Bellman, *Adaptive control processes: a guided tour*. Princeton university press, 2015.
- [52] G. Hughes, "On the mean accuracy of statistical pattern recognizers," *IEEE Transactions on Information Theory*, sv. 14, br. 1, str. 55–63, 1968.
- [53] S. Brahnam, L. Nanni, i R. S. Sexton, "Neonatal facial pain detection using NNSOA and LSVM," u *Proceedings of the 2009 International Conference on Image Processing, Computer Vision, and Pattern Recognition*, str. 352–357, 2008.
- [54] P. Lucey, J. Cohn, S. Lucey, I. Matthews, S. Sridharan, i K. M. Prkachin, "Automatically detecting pain using facial actions," u *Proceedings of the 3rd International*

- Conference on Affective Computing and Intelligent Interaction and Workshops, str. 1–8, 2009.
- [55] P. Lucey, J. F. Cohn, I. Matthews, S. Lucey, S. Sridharan, J. Howlett, i K. M. Prkachin, “Automatically detecting pain in video through facial action units,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, sv. 41, br. 3, str. 664–674, 2011.
- [56] A. B. Ashraf, S. Lucey, J. F. Cohn, T. Chen, Z. Ambadar, K. M. Prkachin, i P. E. Solomon, “The painful face—pain expression recognition using active appearance models,” *Image and vision computing*, sv. 27, br. 12, str. 1788–1796, 2009.
- [57] P. Lucey, J. F. Cohn, K. M. Prkachin, P. E. Solomon, S. Chew, i I. Matthews, “Painful monitoring: Automatic pain monitoring using the UNBC-McMaster shoulder pain expression archive database,” *Image and Vision Computing*, sv. 30, br. 3, str. 197–205, 2012.
- [58] R. A. Khan, A. Meyer, H. Konik, i S. Bouakaz, “Pain detection through shape and appearance features,” u 2013 IEEE International Conference on Multimedia and Expo (ICME), str. 1–6, 2013.
- [59] C. Florea, L. Florea, i C. Vertan, “Learning pain from emotion: transferred hot data representation for pain intensity estimation,” u *Proceedings of the European Conference on Computer Vision*, str. 778–790, 2014.
- [60] N. Rathee i D. Ganotra, “A novel approach for pain intensity detection based on facial feature deformations,” *Journal of Visual Communication and Image Representation*, sv. 33, str. 247 – 254, 2015.
- [61] R. Irani, K. Nasrollahi, i T. B. Moeslund, “Pain recognition using spatiotemporal oriented energy of facial muscles,” u *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, str. 80–87, 2015.
- [62] R. Irani, K. Nasrollahi, M. O. Simon, C. A. Corneanu, S. Escalera, C. Bahnsen, D. H. Lundtoft, T. B. Moeslund, T. L. Pedersen, M.-L. Klitgaard *et al.*, “Spatiotemporal analysis of rgb-dt facial images for multimodal pain level recognition,” u *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, str. 88–95, 2015.
- [63] H. Pedersen, “Learning appearance features for pain detection using the unbc-mcmaster shoulder pain expression archive database,” u *Proceedings of the International Conference on Computer Vision Systems*, str. 128–136, 2015.

- [64] G. Kutyniok i D. Labate, “Introduction to shearlets,” u *Shearlets*. Springer, 2012, str. 1–38.
- [65] D. Labate, W.-Q. Lim, G. Kutyniok, i G. Weiss, “Sparse multidimensional representation using shearlets,” u *Optics & Photonics 2005*, str. 59 140U–59 140U, 2005.
- [66] G. R. Easley i D. Labate, “Image processing using shearlets,” u *Shearlets*. Springer, 2012, str. 283–325.
- [67] Y. Qu, X. Mu, L. Gao, i Z. Liu, “Facial expression recognition based on shearlet transform,” u *Advances in Future Computer and Control Systems*. Springer, 2012, str. 559–565.
- [68] W.-Q. Lim, “The discrete shearlet transform: A new directional transform and compactly supported shearlet frames,” *IEEE Transactions on Image Processing*, sv. 19, br. 5, str. 1166–1180, 2010.
- [69] G. Easley, D. Labate, i W.-Q. Lim, “Sparse directional image representations using the discrete shearlet transform,” *Applied and Computational Harmonic Analysis*, sv. 25, br. 1, str. 25–46, 2008.
- [70] G. Kutyniok, W.-Q. Lim, i R. Reisenhofer, “Shearlab 3D: Faithful digital shearlet transforms based on compactly supported shearlets,” *ACM Transactions on Mathematical Software (TOMS)*, sv. 42, br. 1, str. 5, 2016.
- [71] S. Häuser i G. Steidl, “Fast finite shearlet transform,” arXiv preprint arXiv:1202.1773, 2012.
- [72] Y. Naresh i H. Nagendraswamy, “Classification of medicinal plants: An approach using d LBP with symbolic representation,” *Neurocomputing*, sv. 173, Part 3, str. 1789 – 1797, 2016.
- [73] T. Ojala, M. Pietikainen, i T. Maenpaa, “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns,” *IEEE Transactions on pattern analysis and machine intelligence*, sv. 24, br. 7, str. 971–987, 2002.
- [74] G. Bradski, “The opencv library,” *Doctor Dobbs Journal*, sv. 25, br. 11, str. 120–126, 2000.
- [75] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, i I. H. Witten, “The weka data mining software: an update,” *ACM SIGKDD explorations newsletter*, sv. 11, br. 1, str. 10–18, 2009.
- [76] M. N. Murty i V. S. Devi, *Pattern recognition: An algorithmic approach*. Springer Science & Business Media, 2011.

- [77] G. H. John i P. Langley, “Estimating continuous distributions in bayesian classifiers,” u Proceedings of the 11th conference on Uncertainty in artificial intelligence, str. 338–345, 1995.
- [78] N. Friedman, D. Geiger, i M. Goldszmidt, “Bayesian network classifiers,” Machine learning, sv. 29, br. 2-3, str. 131–163, 1997.
- [79] T. Cover i P. Hart, “Nearest neighbor pattern classification,” IEEE transactions on information theory, sv. 13, br. 1, str. 21–27, 1967.
- [80] L. Jiang, Z. Cai, D. Wang, i S. Jiang, “Survey of improving k-nearest-neighbor for classification.” u Proceedings of the 4th International Conference on Fuzzy Systems and Knowledge Discovery, str. 679–683, 2007.
- [81] J. R. Quinlan, “Induction of decision trees,” Machine learning, sv. 1, br. 1, str. 81–106, 1986.
- [82] L. Breiman, “Random forests,” Machine learning, sv. 45, br. 1, str. 5–32, 2001.
- [83] C. G. Weng i J. Poon, “A new evaluation measure for imbalanced datasets,” u Proceedings of the 7th Australasian Data Mining Conference, str. 27–32, 2008.
- [84] D. A. Cieslak, T. R. Hoens, N. V. Chawla, i W. P. Kegelmeyer, “Hellinger distance decision trees are robust and skew-insensitive,” Data Mining and Knowledge Discovery, sv. 24, br. 1, str. 136–158, 2012.
- [85] M. Dash i H. Liu, “Feature selection for classification,” Intelligent Data Analysis, sv. 1, str. 131–156, 1997.
- [86] L. C. Molina, L. Belanche, i À. Nebot, “Feature selection algorithms: a survey and experimental evaluation,” u Proceedings of the International Conference on Data Mining ICDM, str. 306–313, 2002.
- [87] G. Chandrashekar i F. Sahin, “A survey on feature selection methods,” Computers & Electrical Engineering, sv. 40, br. 1, str. 16–28, 2014.
- [88] Y. Chen, Y. Li, X.-Q. Cheng, i L. Guo, “Survey and taxonomy of feature selection algorithms in intrusion detection system,” u Information security and cryptology, str. 153–167, 2006.
- [89] N. Sánchez-Marono, A. Alonso-Betanzos, i M. Tombilla-Sanromán, “Filter methods for feature selection—a comparative study,” u Proceedings of the International Conference on Intelligent Data Engineering and Automated Learning, str. 178–187, 2007.

- [90] C. Freeman, D. Kulić, i O. Basir, “An evaluation of classifier-specific filter measure performance for feature selection,” *Pattern Recognition*, sv. 48, br. 5, str. 1812–1826, 2015.
- [91] G. Martinoyić, D. Bajer, i B. Zorić, “A differential evolution approach to dimensionality reduction for classification needs,” *International Journal of Applied Mathematics and Computer Science*, sv. 24, br. 1, str. 111–122, 2014.
- [92] G. Wang, M. Jian, i S. Yang, “IGF-bagging: Information gain based feature selection for bagging,” *International Journal of Innovative Computing, Information and Control*, sv. 7, br. 11, str. 6247–6259, 2011.
- [93] J. Kittler *et al.*, “Feature set search algorithms,” *Pattern recognition and signal processing*, str. 41–60, 1978.
- [94] P. Pudil, J. Novovičová, i J. Kittler, “Floating search methods in feature selection,” *Pattern Recognition Letters*, sv. 15, br. 11, str. 1119 – 1125, 1994.
- [95] R. Y. Nakamura, L. A. Pereira, K. Costa, D. Rodrigues, J. P. Papa, i X.-S. Yang, “BBA: a binary bat algorithm for feature selection,” u *Proceedings of the Graphics, Patterns and Images (SIBGRAPI)*, str. 291–297, 2012.
- [96] E. Emary, H. M. Zawbaa, K. K. A. Ghany, A. E. Hassanien, i B. Parv, “Firefly optimization algorithm for feature selection,” u *Proceedings of the 7th Balkan Conference on Informatics*, str. 26:1–26:7, 2015.
- [97] Y. Zhang, S. Wang, P. Phillips, i G. Ji, “Binary PSO with mutation operator for feature selection using decision tree applied to spam detection,” *Knowledge-Based Systems*, sv. 64, str. 22–31, 2014.
- [98] R. Forsati, A. Moayedikia, R. Jensen, M. Shamsfard, i M. R. Meybodi, “Enriched ant colony optimization and its application in feature selection,” *Neurocomputing*, sv. 142, str. 354–371, 2014.
- [99] A. Moayedikia, R. Jensen, U. K. Wiil, i R. Forsati, “Weighted bee colony algorithm for discrete optimization problems with application to feature selection,” *Engineering Applications of Artificial Intelligence*, sv. 44, str. 153–167, 2015.
- [100] M. Schiezero i H. Pedrini, “Data feature selection based on artificial bee colony algorithm,” *EURASIP Journal on Image and Video Processing*, sv. 2013, br. 1, str. 1–8, 2013.

- [101] M. S. Uzer, N. Yilmaz, i O. Inan, “Feature selection method based on artificial bee colony algorithm and support vector machines for medical datasets classification,” *The Scientific World Journal*, sv. 2013, 2013.
- [102] E. Hancer, B. Xue, D. Karaboga, i M. Zhang, “A binary ABC algorithm based on advanced similarity scheme for feature selection,” *Applied Soft Computing*, sv. 36, str. 334–348, 2015.
- [103] M. L. Raymer, W. F. Punch, E. D. Goodman, L. A. Kuhn, i A. K. Jain, “Dimensionality reduction using genetic algorithms,” *IEEE Transactions on Evolutionary Computation*, sv. 4, br. 2, str. 164–171, 2000.
- [104] M. M. Kabir, M. Shahjahan, i K. Murase, “A new local search based hybrid genetic algorithm for feature selection,” *Neurocomputing*, sv. 74, br. 17, str. 2914–2928, 2011.
- [105] S. Oreski i G. Oreski, “Genetic algorithm-based heuristic for feature selection in credit risk assessment,” *Expert systems with applications*, sv. 41, br. 4, str. 2052–2064, 2014.
- [106] A. Khan i A. R. Baig, “Multi-objective feature subset selection using non-dominated sorting genetic algorithm,” *Journal of applied research and technology*, sv. 13, br. 1, str. 145–159, 2015.
- [107] P. Yang, W. Liu, B. B. Zhou, S. Chawla, i A. Y. Zomaya, “Ensemble-based wrapper methods for feature selection and class imbalance learning,” u *Advances in Knowledge Discovery and Data Mining*. Springer, 2013, str. 544–555.
- [108] L. Wang, H. Ni, R. Yang, V. Pappu, M. B. Fenn, i P. M. Pardalos, “Feature selection based on meta-heuristics for biomedicine,” *Optimization Methods and Software*, sv. 29, br. 4, str. 703–719, 2014.
- [109] D. Bajer, B. Zorić, i G. Martinović, “Automatic design of radial basis function networks through enhanced differential evolution,” u *Proceedings of the International Conference on Hybrid Artificial Intelligence Systems*, str. 244–256, 2015.
- [110] D. Karaboga i B. Basturk, “A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm,” *Journal of global optimization*, sv. 39, br. 3, str. 459–471, 2007.
- [111] B. Akay i D. Karaboga, “A modified artificial bee colony algorithm for real-parameter optimization,” *Information Sciences*, sv. 192, str. 120–142, 2012.
- [112] M. Lichman, “UCI machine learning repository,” <http://archive.ics.uci.edu/ml>, 2013, pristupljeno: 2016-04-27.

- [113] A. Chojaczyk, A. Teixeira, L. Neves, J. Cardoso, i C. G. Soares, “Review and application of artificial neural networks models in reliability analysis of steel structures,” *Structural Safety*, sv. 52, str. 78 – 89, 2015.
- [114] J. B. Ali, N. Fnaiech, L. Saidi, B. Chebel-Morello, i F. Fnaiech, “Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals,” *Applied Acoustics*, sv. 89, str. 16–27, 2015.
- [115] S. S. Tirumala i A. Narayanan, “Attribute selection and classification of prostate cancer gene expression data using artificial neural networks,” u *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, str. 26–34, 2016.
- [116] R. T. Cabeza, E. B. Vicedo, A. Prieto-Moreno, i V. M. Vega, “Fault diagnosis with missing data based on hopfield neural networks,” u *Mathematical Modeling and Computational Intelligence in Engineering Applications*. Springer, 2016, str. 37–46.
- [117] C. Maione, B. L. Batista, A. D. Campiglia, F. B. Jr, i R. M. Barbosa, “Classification of geographic origin of rice by data mining and inductively coupled plasma mass spectrometry,” *Computers and Electronics in Agriculture*, sv. 121, str. 101 – 107, 2016.
- [118] C. M. Bishop, *Neural networks for pattern recognition*. Oxford university press, 1995.
- [119] K.-L. Du i M. Swamy, *Neural networks and statistical learning*. Springer Science & Business Media, 2013.
- [120] H. Yu, T. Xie, S. Paszczyński, i B. M. Wilamowski, “Advantages of radial basis function networks for dynamic system design,” *IEEE Transactions on Industrial Electronics*, sv. 58, br. 12, str. 5438–5450, 2011.
- [121] J. M. González-Camacho, G. de los Campos, P. Pérez, D. Gianola, J. E. Cairns, G. Mahuku, R. Babu, i J. Crossa, “Genome-enabled prediction of genetic values using radial basis function neural networks,” *Theoretical and Applied Genetics*, sv. 125, br. 4, str. 759–771, 2012.
- [122] G. Sermpinis, K. Theofilatos, A. Karathanasopoulos, E. F. Georgopoulos, i C. Dunis, “Forecasting foreign exchange rates with adaptive neural networks using radial-basis functions and particle swarm optimization,” *European Journal of Operational Research*, sv. 225, br. 3, str. 528 – 540, 2013.
- [123] F. Bonanno, G. Capizzi, G. Graditi, C. Napoli, i G. Tina, “A radial basis function neural network based approach for the electrical characteristics estimation of a photovoltaic module,” *Applied Energy*, sv. 97, str. 956 – 961, 2012.

- [124] J. Moody i C. J. Darken, “Fast learning in networks of locally-tuned processing units,” *Neural computation*, sv. 1, br. 2, str. 281–294, 1989.
- [125] G. Bugmann, “Normalized gaussian radial basis function networks,” *Neurocomputing*, sv. 20, br. 1, str. 97–110, 1998.
- [126] Z. Qin, J. Chen, Y. Liu, i J. Lu, “Evolving rbf neural networks for pattern classification,” u *Proceedings of the International Conference on Computational and Information Science*, str. 957–964, 2005.
- [127] T. Ince, S. Kiranyaz, i M. Gabbouj, “Evolutionary RBF classifier for polarimetric sar images,” *Expert Systems with Applications*, sv. 39, br. 5, str. 4710–4717, 2012.
- [128] E. Cinar i F. Sahin, “New classification techniques for electroencephalogram (EEG) signals and a real-time EEG control of a robot,” *Neural Computing and Applications*, sv. 22, br. 1, str. 29–39, 2013.
- [129] T. Kurban i E. Beşdok, “A comparison of RBF neural network training algorithms for inertial sensor based terrain classification,” *Sensors*, sv. 9, br. 8, str. 6312–6329, 2009.
- [130] W. Yu, L. Liu, i W. Zhang, “Traffic prediction method based on RBF neural network with improved artificial bee colony algorithm,” u *Intelligent Networks and Intelligent Systems (ICINIS)*, 2015 8th International Conference on, str. 141–144, 2015.
- [131] M.-H. Horng, Y.-X. Lee, M.-C. Lee, i R.-J. Liou, “Firefly metaheuristic algorithm for training the radial basis function network for data classification and disease diagnosis,” *Theory and new applications of swarm intelligence*, sv. 4, br. 7, str. 115–132, 2012.
- [132] S. A. Soleymani, S. Goudarzi, M. H. Anisi, W. H. Hassan, M. Y. I. Idris, S. Shamshirband, N. M. Noor, i I. Ahmedy, “A novel method to water level prediction using RBF and FFA,” *Water Resources Management*, sv. 30, br. 9, str. 3265–3283, 2016.
- [133] A. Kaushik, D. K. Tayal, K. Yadav, i A. Kaur, “Integrating firefly algorithm in artificial neural network models for accurate software cost predictions,” *Journal of Software Evolution and Process*, 2016.
- [134] D. Bajer, B. Zorić, i G. Martinović, “Effectiveness of differential evolution in training radial basis function networks for classification,” u *Proceedings of the International Conference on Smart Systems and Technologies (SST)*, str. 179–184, 2016.
- [135] D. P. F. Cruz, R. D. Maia, L. A. da Silva, i L. N. de Castro, “BeeRBF: A bee-inspired data clustering approach to design RBF neural network classifiers,” *Neurocomputing*, sv. 172, str. 427–437, 2016.

-
- [136] D. Karaboga i B. Basturk, “Artificial bee colony (ABC) optimization algorithm for solving constrained optimization problems,” u International Fuzzy Systems Association World Congress, str. 789–798, 2007.
- [137] Z. Cai, W. Gong, C. X. Ling, i H. Zhang, “A clustering-based differential evolution for global optimization,” Applied Soft Computing, sv. 11, br. 1, str. 1363–1379, 2011.

Sažetak

U ovoj disertaciji razmatran je problem raspoznavanja razina boli na osnovu slike lica. Riječ je o složenom problemu iz domene raspoznavanja uzoraka, a za čije se rješavanje uobičajeno rabe postupci strojnog učenja namijenjeni nadziranoj klasifikaciji. S obzirom da se klasifikacijska procedura provodi u nekoliko koraka, u sklopu ove disertacije predložene su ideje koje je moguće ugraditi u pojedine korake te tako pospješiti razinu raspoznavanja boli. Predstavljeni su tako postupak izdvajanja značajki zasnovan na shearlet transformaciji, metoda odabira značajki praćenjem njihova pojedinačnog doprinosa te unaprijeđeni algoritam za oblikovanje klasifikacijskog modela radijalne neuronske mreže, zasnovan na algoritmu umjetne kolonije pčela. Svaki od prijedloga eksperimentalno je vrednovan na podacima dostupnim iz kliničkog okruženja, a njegovo ponašanje je uspoređeno s drugim pristupima dostupnima u literaturi. Rezultati analize sugeriraju da postupak izdvajanja značajki dovodi do boljeg raspoznavanja razina boli prilikom uporabe različitih klasifikatora, a čini to uz relativno nizak broj značajki. Nadalje, metoda odabira značajki omogućuje pronalazak podskupova značajki niže dimenzionalnosti uz održavanje kvalitete raspoznavanja ili njenog uvećavanja. Konačno, unaprijeđeni algoritam za oblikovanje radijalnih neuronskih mreža uspijeva pronaći mreže koje prema svojim performansama nadilaze one oblikovane konkurentskim algoritmima iz literature.

Ključne riječi: *izdvajanje značajki, klasifikacija, oblikovanje klasifikacijskog modela, odabir značajki, raspoznavanje razina boli*

Abstract

Enhanced pain level recognition methods based on facial images

In this doctoral dissertation the problem of pain level recognition based on facial images is considered. As it represents a complex problem from the domain of pattern recognition, various machine learning approaches are commonly utilised in an attempt to solve it. Considering the fact that the classification procedure involves several steps, as a part of this dissertation several ideas are proposed that can be implemented in individual steps, thusly improving the pain level recognition. A feature extraction procedure which is based on the shearlet transform, a method for feature selection through individual contribution tracking and an algorithm for radial basis network classification model design that is based on the artificial bee colony algorithm are presented and implemented. Each of these proposals has been experimentally evaluated on data coming from a clinical environment, and its behaviour compared with alternative approaches employed in the literature for the same tasks. The results of the conducted analysis suggest that the feature extraction procedure leads to better pain level recognition using several classifiers, while achieving the aforementioned using a comparingly lower number of features. Further more, the method for feature selection provides feature subsets that are comparingly of lower dimensionality while maintaining or improving the classification quality. Finally, the enhanced algorithm proposed for the radial basis network design outputs networks that give favourable results regarding classification performance when compared with the networks designed by other algorithms utilised in the experimental analysis.

Keywords: *feature extraction, classification, classification model design, feature selection, pain level recognition*

Životopis

Bruno Zorić rođen je 12.3.1987. godine u Đakovu. Ondje završava osnovnu i srednju školu nakon čega ostvaruje pravo izravnog upisa na Elektrotehnički fakultet Osijek. Akademski naziv prvostupnik inženjer računarstva stiže na istoj instituciji 2008., a akademski naziv magistar inženjer računarstva 2011. godine. Tijekom studija nagrađen je državnim, a kasnije i županijskom stipendijom za nadarene studente. Uz fakultet polazi i završava CISCO akademiju mrežnih tehnologija. Od 1.7.2011. zaposlen je kao znanstveni novak u suradničkom zvanju asistenta na Elektrotehničkom fakultetu Osijek u sklopu znanstvenog projekta MZOS RH, pod nazivom "Postupci raspoređivanja u samoodrživim raspodijeljenim računalnim sustavima", voditelja prof.dr.sc. Gorana Martinovića. Sudjelovao je na projektu Europske unije u sklopu IPA-IV komponente pod nazivom "U korak s globalnim trendovima za usklađenost s aktivnom politikom tržišta rada". Održava nastavu iz niza kolegija na stručnom, preddiplomskom i diplomskom studiju računarstva, sudjeluje kao sumentor na završnim i diplomskim radovima, a održao je i edukaciju pod nazivom "Razvoj mobilnih aplikacija" u sklopu programa cjeloživotnog obrazovanja. Autor je i suautor nekoliko znanstvenih radova u znanstvenim časopisima i zbornicima međunarodnih skupova. Glavna područja znanstvenog interesa i istraživanja su nadzirano strojno učenje, klasifikacija uzoraka te njihova primjena u medicini. Aktivno se koristi engleskim i njemačkim jezikom.

Podatkovni skupovi s UCI repozitorija

- [\mathcal{U}_1] **Climate:** Podatkovni skup *Climate* sadrži zapise o provedenim simulacijama i njihovom rušenju o ovisnosti o odabranim parametrima. Izvorno je korišten kako bi se predvidjela vjerojatnost rušenja simulacije na osnovu 18 postavljenih parametara. Riječ je o problemu binarne klasifikacije, gdje klasa kazuje je li došlo do rušenja ili ne.
- [\mathcal{U}_2] **Dermatology:** Podatkovni skup *Dermatology* koprišten je za potrebe diferencijalne dijagnoze različitih kožnih bolesti poput psorijaze, dermatitisa i sl. Skup sadrži ukupno 34 značajki, 366 instanci te 6 klasa koje označavaju određenu bolest. S obzirom da postoje instance koje sadrže podatke koji nedostaju, te instance su uklonjene prije korištenja skupa.
- [\mathcal{U}_3] **ImageSeg:** Podatkovni skup *ImageSeg* sadržava podatke o slikama koje prikazuju različitom materijalu prikazanom na slici. Svaka instanca predstavlja regiju od 3×3 piksela, koja je opisana s 19 atributa. U podatkovnom skupu postoji 7 klasa koje označavaju što je na slici (cigla, nebo, zelenilo, beton, prozor, staza, trava). Za potrebe analize korišten je samo dio svih dostupnih podataka označen s "*segmentation.data*" gdje je sadržano po 30 instanci za svaku klasu.
- [\mathcal{U}_4] **Ionosphere:** Podatkovni skup *Ionosphere* korišten je za klasifikaciju povratnih signala radara iz ionosfere. Korišten je za potrebe prikupljanja podataka sustav sa 16 antena visoke frekvencije, a svaka instanca opisana je s 34 atributa (dva atributa po pulsu). Prisutne su samo dvije klase

što ovaj problem čini problemom binarne klasifikacije, gdje klasa "dobar" predstavlja postojanje neke strukture u ionosferi, a klasa "loš" predstavlja prolazak signala kroz ionosferu.

[\mathcal{U}_5] **Libras movement:** Podatkovni skup *Libras movement* opisuje pokrete ruke prilikom korištenja brazilskog znakovnog jezika. Postoji u ovom skupu petnaest različitih pokreta, svaki od kojih je predstavljen jednom klasom. Podaci su prikupljeni na osnovu video-sekvenci pokreta ruke. Svaka instanca opisana je s 90 atributa koji predstavljaju dvodimenzionalnu krivulju koju je ruka napravila kroz vrijeme (koordinate 45 točaka u dvodimenzionalnom prostoru).

[\mathcal{U}_6] **Mesothelioma:** Podatkovni skup *Mesothelioma* opisuje zloćudne tumore mezoteliome. Sadrži podatke o 324 pacijenta gdje je svaka instanca opisana s 34 značajke, između ostalih dan je broj bijelih krvnih zrnaca, sedimentacija, glukoza i dr. Cilj je na temelju danih podataka dijagnosticirati postojanje tumora, što ovaj problem čini problemom binarne klasifikacije.

[\mathcal{U}_7] **MuskV1:** Podatkovni skup *MuskV1* opisuje različite molekule od kojih neke pripadaju skupini mošusa (korištenog, primjerice, kod kreiranja parfema), a druge ne. Cilj je na temelju karakteristika molekule predvidjeti radi li se o mošusu ili ne, te je stoga očito riječ o binarnoj klasifikaciji. Svaka je instanca unutar skupa opisana sa 166 značajki, dok podatkovni skup sadrži ukupno 476 instanci.

[\mathcal{U}_8] **Urban Land Cover:** Podatkovni skup *Urban Land Cover* sadrži informacije za klasifikaciju slika terena nastalih iz zraka. Razlikuje se 9 različitih tipova terena, drveće, travu, zemlju, beton, asfalt, građevine, automobile, bazene i sjene. Skup je nastao nasumičnim poduzorkovanjem slika, a sadrži 168 instanci opisanih sa 148 atributa.

[\mathcal{U}_9] **LSVT Voice Rehabilitation:** Podatkovni skup *LSV Voice Rehabilitation* sadrži podatke o rehabilitaciji pacijenata pogođenih Parkinsonovom bolešću. Korištenjem računalnog sustava za praćenje pacijenta i pomoć u rehabilitaciji, pokušava se odrediti izgovaraju li pacijenti na odgovarajuć način određene samoglasnike. Naime, glasnoća govora i karakteristike izgovora često su narušeni kod ljudi koji pate od Parkinsonove bolesti. Pozitivna klasa u ovom kontekstu označava izgovaranje kakvo bi dopustio liječnik, dok negativna klasa označava one izgovore za koje liječnik ne bi dopustio da se nastave.

[\mathcal{U}_{10}] **Wine:**

Podatkovni skup *Wine* sadrži podatke nastale analizom kemijskog sastava vina. Uzorci su dobiveni iz tri različita vinograda, a upravo je prema porijeklu određena klasa uzorka. Svaka instanca opisana je s 13 značajki, a ukupno je dostupno 178 instanci.

Implementacijski detalji

Programsko rješenje: Za analizu i vrednovanje svakog od predloženih izvornih znanstvenih doprinosa razvijena je testna okolina korištenjem programskog jezika C# i uporabom integriranog razvojnog okruženja Microsoft Visual Studio. Za potrebe ugradnje testne okoline za prvi predloženi izvorni znanstveni doprinos korišteni su još i Weka alat za rudarenje podataka, odnosno njegov otvoreni kod koji korišten unutar .Net okvira uporabom IKVM.NET Java implementacije. Za lakši rad s digitalnim slikama i njihovom obradom korištena je biblioteka OpenCV, a za potrebe provođenja shearlet transformacije korištena je biblioteka FFST. Za potrebe testne okoline za vrednovanje trećeg izvornog znanstvenog doprinosa korištena je biblioteka Accord.NET za potrebe računanja Moore-Penrose pseudoinverza za potrebe određivanja težinskih faktora na sponama skrivenog i izlaznog sloja RBFN-a. Poveznice na korištene alate i biblioteke dane su tablicom B.1.

Tablica B.1: Poveznice na korištene biblioteke i alate

Naziv	Poveznica
OpenCV	http://opencv.org/
Weka	http://www.cs.waikato.ac.nz/ml/weka/
IKVM.NET	https://www.ikvm.net/
FFST	http://www.mathematik.uni-kl.de/imagepro/software/ffst/
Accord.NET	http://accord-framework.net/

Korišteno sklopovlje: Za provođenje eksperimentalnog dijela korištena su tri računala čije su karakteristike predstavljene tablicom B.2. S obzirom da vremena izvođenja nisu vrednovana, provođenje eksperimenata raspoređeno je opisana računala kako bi se skratilo njihovo ukupno trajanje.

Tablica B.2: Karakteristike sklopovlja korištenog za potrebe računalne analize

Oznaka	OS	Procesor	Radna memorija
PC1	Windows 8.1	Intel Core i5-4200M @ 2.50GHz	6GB
PC2	Windows 7	Intel Pentium e5800 @ 3.20GHz	8GB
PC3	Windows 10	Intel Core i5-6200U @ 2.30GHz	8GB