

Univerza v Mariboru  
Fakulteta za elektrotehniko, računalništvo in informatiko

Miljenko Križmarić

HEVRISTIČNO GENERIRANJE  
MEDICINSKIH SIMULACIJSKIH  
SCENARIJEV

DOKTORSKA DISERTACIJA

Maribor, marec 2009



Avtor: Miljenko Križmarić

Naslov: Hevristično generiranje medicinskih simulacijskih scenarijev

UDK: [004.94:61]:004.8(043.3)

Število izvodov: 8

Oblikovanje: Miljenko Križmarić

Lektoriranje: Nada Granduč



# Povzetek

## Hevristično generiranje medicinskih simulacijskih scenarijev

UDK:[004.94:61]:004.8(043.3)

*Ključne besede:*

medicinske simulacije, simulatorji, scenariji, strojno učenje, Bayesove verjetnostne mreže, urgentna medicina

*Sodobno izobraževanje zdravstvenih delavcev zahteva uporabo medicinskih simulatorjev, saj medicina postaja zahtevna in kompleksna. Simulatorji potrebujejo scenarije, ki jih izdelujejo zdravniki, vendar je tak pristop subjektiven, ker ima vsak zdravnik svoje lastne izkušnje. Scenarije lahko izboljšamo z uporabo metod strojnega učenja. V doktorskem delu raziščemo in uporabimo Bayesove verjetnostne mreže kot računalniško podprtlo orodje za izdelavo scenarijev. Predstavimo metodologijo CasGEN, ki jo uporabimo na realnem primeru večje podatkovne zbirke s področja urgentne medicine - 737 primerov predbolnišničnega oživljjanja. Rezultate validiramo s pomočjo trifaznega modela zastoja srca pri prekatni fibrilaciji. V doktorskem delu potrdimo ustreznost metodologije CAS-Gen na podlagi študije, ki so jo pozitivno ocenili eksperti s področja medicine. Na tak način potrdimo hipotezo raziskovalnega dela, da je predstavljena metodologija CASGen uporabno orodje za generiranje medicinskih scenarijev.*



# Abstract

## Heuristic generation of medical simulation scenarios

UDK:[004.94:61]:004.8(043.3)

*Keywords:*

medical simulations, simulators, scenarios, machine learning, bayesian probability networks, emergency medicine

Modern education in health care today can not exist without the use of medical simulators, which are state of the art for efficient learning. Simulators use scenarios, which are designed by physician's own experiences and presents a subjective approach by scenario design. In doctoral thesis machine learning methods for building scenarios from real data are presented. In particular we introduce Bayesian probability networks as the primary tool for scenario design. We present a methodology CASGen (Computer Aided Scenario Generation) which uses Bayesian network (BN) and apply it to a real study of emergency medicine, where 737 cases in prehospital resuscitation were collected. The results of CASGen are validated with the three phase model for ventricular fibrillation. We confirm the hypothesis of the research that BN are appropriate method for supporting scenario design. The application and use of CASGen was independently confirmed by experts from medical domain.



# Kazalo

<b>I Opis doktorske disertacije</b>	<b>15</b>
<b>1 Predstavitev raziskovalnega dela</b>	<b>17</b>
1.1 Uvod . . . . .	17
1.2 Opredelitev problema . . . . .	20
1.3 Cilji doktorske disertacije . . . . .	21
1.4 Predpostavke in omejitve . . . . .	21
1.5 Teze doktorske disertacije . . . . .	22
1.6 Izvirni znanstveni prispevki . . . . .	23
1.7 Struktura doktorske disertacije . . . . .	23
<b>II Opis problema in teoretično ozadje</b>	<b>25</b>
<b>2 Simulacije v medicini</b>	<b>27</b>
2.1 Napredne tehnologije simulatorjev in urjenje osebja v medicini . . . . .	27
2.2 Simulacijsko okolje . . . . .	28
2.2.1 Razdelitev simulatorjev . . . . .	31
2.2.2 Simulacije širokoga spektra . . . . .	35
2.2.3 Prednosti uporabe simulatorjev . . . . .	38
2.3 Simulacijski scenariji . . . . .	40
2.3.1 Sekvenčno zasnovani scenariji . . . . .	42

2.3.2	Modelske zasnove scenarijih . . . . .	43
2.4	Simulator bolnika Laerdal SimMan . . . . .	48
2.4.1	Sistemske lastnosti . . . . .	48
2.4.2	Opis komponent . . . . .	50
2.4.3	Programski paket . . . . .	52
2.4.4	Primer scenarija . . . . .	55
<b>3</b>	<b>Teorija verjetnostnih mrež in verjetnostni račun</b>	<b>63</b>
3.1	Verjetnostne mreže . . . . .	63
3.1.1	Grafi in grafični modeli . . . . .	66
3.1.2	Gotovost . . . . .	71
3.1.3	Tok informacij v vzročnih mrežah . . . . .	71
3.1.4	Vzročnost . . . . .	77
3.1.5	Kriterija irelevance . . . . .	79
3.2	Osnovne zakonitosti in koncepti verjetnostnega računa . . . . .	82
3.2.1	Definicija verjetnosti . . . . .	84
3.2.2	Pogojna verjetnost . . . . .	87
3.2.3	Verjetnostne porazdelitve . . . . .	88
3.2.4	Popolna verjetnost . . . . .	89
3.2.5	Osnovni princip in Bayesovo pravilo . . . . .	91
<b>4</b>	<b>Bayesove verjetnostne mreže</b>	<b>93</b>
4.1	Modeliranje Bayesovih verjetnostnih mrež . . . . .	93
4.1.1	Gradnja Bayesove mreže . . . . .	97
4.1.2	Kriteriji za uporabo verjetnostnih mrež . . . . .	98
4.1.3	Identifikacija in tipi spremenljivk . . . . .	99
4.1.4	Gradnja strukture . . . . .	101
4.2	Strojno učenje - učenje Bayesove mreže iz podatkov . . . . .	102

4.2.1	Učenje strukture Bayesove mreže . . . . .	102
4.2.2	Učenje parametrov Bayesove mreže . . . . .	105
4.3	Razširitev formalizma Bayesove mreže v sisteme odločanja . . . . .	108
4.3.1	Diagrami vpliva . . . . .	109
4.4	Uporaba Bayesovih verjetnostnih mrež v medicini . . . . .	116
4.4.1	Podpora pri določanju diagnoz . . . . .	116
4.4.2	Prognostično sklepanje . . . . .	117
4.4.3	Izbira postopka zdravljenja . . . . .	118
4.5	Programska orodja za delo z Bayesovimi mrežami . . . . .	118
4.5.1	GeNIE in SMILE . . . . .	119
4.5.2	BayesiaLab . . . . .	120
4.5.3	Netica . . . . .	120
4.5.4	WEKA . . . . .	120
4.5.5	HUGIN . . . . .	121
<b>III</b>	<b>Izdelava metodologije uporabe verjetnostnih mrež za potrebe simulatorja</b>	<b>123</b>
<b>5</b>	<b>Simulacije kot vzorčno odvisni sistemi dogodkov in stanj</b>	<b>125</b>
5.1	Narava izdelave scenarija za simulator . . . . .	125
5.2	Predstavitev znanja v simulatorju z grafičnim modelom verjetnostnih mrež	127
<b>6</b>	<b>Izdelava metodologije</b>	<b>129</b>
6.1	Metodologija CASGen . . . . .	129
6.2	Arhitektura metodologije CASGen . . . . .	130
6.2.1	Preslikava med predstavitvijo znanja v scenariju in verjetnostnimi mrežami . . . . .	130
6.3	Definicija Metodologije CASGen . . . . .	133

6.4	Analiza problemske domene za scenarij . . . . .	134
6.5	Gradnja strukture Bayesovih mrež . . . . .	140
6.5.1	Ročna gradnja Bayesovih mrež . . . . .	140
6.5.2	Avtomatska gradnja Bayesovih mrež . . . . .	142
6.6	Optimizacija in učenje parametrov . . . . .	143
6.7	Integracija Bayesovih mrež v scenarij . . . . .	143
6.8	Uporaba inference v scenariju . . . . .	143
6.8.1	Težavnost scenarija . . . . .	144
6.9	Zapis podatkov za strojno obdelavo . . . . .	144
6.9.1	Identifikacija relevantnih spremenljivk za podatkovno zbirko . . . . .	145
6.9.2	Reprezentativna vrednost zbranega vzorca . . . . .	146
6.10	U mestitev metodologije CASGen v simulacijsko okolje . . . . .	146
6.11	Reasonov krizni model in metodologija CASGen . . . . .	148
6.12	Nadaljnje delo . . . . .	151
6.12.1	Težavnostne stopnje scenarija . . . . .	151
6.12.2	Gradnja Reasonovega modela . . . . .	152
6.12.3	Fuzija simulatorjev . . . . .	154
6.12.4	Integracija metodologije v METI simulator . . . . .	155
<b>IV</b>	<b>Rezultati</b>	<b>159</b>
<b>7</b>	<b>Validacija CASGen na scenariju predbolnišnične reanimacije</b>	<b>161</b>
7.1	Predstavitev . . . . .	161
7.2	Analiza problema . . . . .	161
7.3	Opis podatkovne zbirke . . . . .	162
7.4	Diskretizacija . . . . .	162
7.5	Kvalitativni del BN . . . . .	164
7.6	Inferenca . . . . .	166

<b>8 Validacija CASGen na scenariju anafilaktične reakcije</b>	<b>177</b>
8.1 Opis problema . . . . .	177
8.2 Analiza problema . . . . .	178
8.3 Ročna gradnja Bayesovih mrež . . . . .	181
8.4 Diagrami vpliva in odločitve . . . . .	183
8.5 Redukcija vozlišč . . . . .	184
8.6 Izdelan scenarij za simulator SimMan . . . . .	186
<b>9 Preverjanje metodologije CASGen</b>	<b>189</b>
9.1 Predstavitev metodologije ekspertom . . . . .	189
9.2 Podano mnenje ekspertov . . . . .	192
<b>10 Sklepne misli in razprava</b>	<b>195</b>



## Del I

# Opis doktorske disertacije



# Poglavlje 1

## Predstavitev raziskovalnega dela

### 1.1 Uvod

Antropično načelo govori, da zakoni fizike omogočajo življenje zaradi našega lastnega obstanka, kjer se sami sprašujemo o življenju in razmišljamo o antropičnem načelu. V svoji skrajni obliki je torej vesolje oblikovano na način, v katerem obstaja življenje. Ljudje se od drugih življenjskih oblik razlikujemo v ustvarjalnosti, radovednosti in načinu razmišljanja, saj smo verjetno edina vrsta v našem osončju, ki raziskuje svoj obstoj in se ga tudi popolnoma zaveda.

Z razvojem pa ljudje posegamo v okolje in ga spreminjamo. Spreminjamo svoj odnos do nas samih in do okolja, v katerem delujemo. Danes se tako že srečujemo z izzivi globalnega segrevanja, kar znanost postavlja pred novo preizkušnjo in predstavlja razvoj novih paradigem, metodologij in tehnologij za pridobivanje energije, ki temeljijo na alternativnih in okolju prijaznejših virih. Del razvoja človeške družbe pa spremišča tudi razvoj medicine. Življenje posameznika se lahko v današnjem kompleksnem svetu hitro znajde v neravnovesju. Dnevno smo izpostavljenim nevarnostim, ki se jih niti ne zavedamo, in kadar smo nehote izpostavljeni kateri izmed njih, nam pri ozdravitvi pomaga medicina.

Moderna uradna medicina postaja vedno zahtevnejša in kompleksnejša. Medicinsko delovno okolje se razvija z izjemno hitrostjo, na plan prihajajo sodobne tehnologije, nova znanja ter spoznanja, ki ponujajo kvalitetnejše zdravljenje, hkrati pa nova okolja in tehnologije tako zahtevajo tudi mnogo znanja in spretnosti. Za suvereno delo zdravstvenih delavcev so zato potrebne dodatne izobraževalne metode, ki se dopolnjujejo s tradicionalnimi modeli poučevanja. S pravilnim in učinkovitim izobraževalnim pristopom lahko

znanje in veščine v taki meri zdravstvenim delavcem tudi zagotovimo in tako omogočimo njihovo kompetentno in učinkovito delo.

Simulacije dobivajo posebno mesto pri študiju medicinskih ved, saj nam v procesu izobraževanja pomagajo boljše razumevanje učne snovi, hkrati pa dopolnjujejo klasične učne pristope in imajo pomembno vlogo v medicini [88]. Takšne simulacije se pojavljajo predvsem v obliki samostojnih računalniških programov ali lutk z vgrajenimi elektromehanskimi sistemi, ki jih računalniško krmilimo. Razen klasičnih enostavnih simulatorjev postopkov zdravstvene nege, fizioloških procesov in medicinskih posegov poznamo tudi simulatorje, ki predstavljajo samega bolnika. Primerni so za že utečeno zaposleno zdravstveno osebje, ki se preko teh simulatorjev spoznava z redkimi in nezaželenimi in problematičnimi kriznimi situacijami na delovnem mestu. Zraven tega imajo bolniki tudi pravico do zasebnosti in profesionalne oskrbe ter vse manj dovoljujejo, da s svojim postopkom zdravljenja pomagajo v učnem procesu, zato imajo študentje in zaposleno zdravstveno osebje manjše možnosti spoznavanja prakse v realnem okolju z bolniki. Specifične zahteve, zahtevne veščine znanja in spretnosti so torej potrebne, vendar v realnem okolju težje dostopne.

Izkušnje in delo v realnem okolju pa lahko omogočimo s komercialno dostopnimi medicinskim simulatorji bolnika [61, 52], ki omogočajo delo z realno medicinsko opremo, kjer ustvarimo okolje, ki je zelo blizu pravim kliničnim razmeram, in na tak način ne vplivamo na bolnike. Na teh simulatorjih se simulirajo bolezenska stanja in zapleti preko računalniške programske opreme in mehatronike. Simulacije potekajo po določenih scenarijih, ki so zasnovani modularno [61] ali sekvenčno [52], obstajajo pa tudi simulatorji, ki so jih posamezno razvile raziskovalne institucije [100].

Kljub kompleksni in skrbno načrtovani medicinski tehnologiji pa pri zdravljenju v medicini pri nastalih zapletih človeška napaka ostaja na prvem mestu. V urgentni in intenzivni medicini je tako mnogo kognitivnega balasta, pomanjkanja timske komunikacije in izgrevanja delavcev, kar lahko vodi do napak, ki so za bolnika lahko usodne. Za simuliranje takšnih razmer dela vodijo trendi k izdelavi vzporednih scenarijev in hkratni uporabi več simulatorjev [50, 101]. Da simulatorje uporabimo v namene izobraževanja, potrebujemo scenarije, ki natančno simulirajo celoten potek vaje. Scenariji so največkrat izdelani s pomočjo zdravnikov ekspertov, ki imajo določene osebne izkušnje. Zato so scenariji po navadi izdelani na podlagi izkušenj določenega zdravnika in tako ne zajemajo splošnih izkušenj in v osnovi ne vključujejo realnih podatkov.

Strojno učenje in podatkovno rudarjenje sta disciplini, ki sta se v računalništvu razvili

s področja umetne inteligence in v zadnjih nekaj letih zaradi velikega zajemanja in shranjevanja elektronskih podatkov pridobile vedno večje zanimanje raziskovalne skupnosti [37]. S pomočjo metod podatkovnega rudarjenja si danes v medicini strokovnjaki že pomagajo pri diagnosticiranju, kar je tudi glavna naloga tako imenovanih računalniško podprtih orodij, ki zdravnikom služijo kot pomoč pri njihovem delu v procesu odločanja [73]. Primerov takih pristopov je mnogo in segajo od podpore pri diagnostiki do različnih terapij, kot so na primer inteligentne metode v umetnem predihavanju [46]. Večina metod podatkovnega rudarjenja in strojnega učenja temelji na tako imenovani hevristiki, kar z drugimi besedami pomeni uporabo nekih spoznanih načel pri reševanju problemov na različnih področjih.

V doktorskem delu združujemo omenjena vidika in za gradnjo scenarijev uporabimo hevristične pristope ter strojno učenje, za kar izdelamo metodologijo, ki služi kot podporno orodje pri gradnji scenarijev za namene izobraževanja v medicini. Hevristični pristopi, ki jih uporabljamo v delu, izhajajo iz Bayesove statistike in zajemajo uporabo verjetnostnih mrež kot hevrističnega podpornega orodja za izdelavo scenarijev. Verjetnostne mreže so naraven model, s katerim namreč lahko učinkovito modeliramo nekatere procese v diagnostiki in jih tako učinkovito uporabimo tudi pri gradnji scenarijev.

Doktorska naloga predstavlja metodologijo CASGen (Computer Aided Scenario Generation), ki temelji na verjetnostnih mrežah. Pri gradnji scenarija prinaša prednosti uporabe realnih podatkov za namene izobraževanja ciljnih skupin ter lažjo upravljanje s scenariji, kar nam omogoča lastnost sklepanja (inference), ki jo imajo verjetnostne mreže. Ker imamo pri izdelavi scenarija opraviti s kompleksnim problemom, ne gre za enostavne in hitre rešitve, temveč je treba pri delu upoštevati veliko zahtev, ki jih pogojujeta obe področji, tako ročna izdelava samega scenarija v programskem okolju simulatorja, kot tudi zahteve in omejitve verjetnostnih mrež. Razvita metodologija CASGen tako združuje oboje in podaja učinkovite postopke za gradnjo hevrističnih scenarijev simulatorja. Uporabo metodologije prikažemo na dveh realnih primerih, kvalitativno pa učinkovitost in uporabo metodologije ocenimo s sodelovanjem in preverjanjem strokovnjakov s področja medicine, ki se ukvarjajo z izdelavo scenarijev iz realnega okolja za potrebe izobraževanja.

## 1.2 Opredelitev problema

Zaradi napak v medicinski oskrbi letno v Združenih državah Amerike umre med 44.000 in 98.000 bolnikov [54]. Te smrtne žrtve presegajo število ljudi, ki umrejo zaradi pomembnejših vzrokov smrti v ZDA, kot so prometne nesreče, rak na prsih in AIDS. Mnoge od teh napak bi lahko preprečili. Za zdravstveni sistem v Sloveniji takih študij in podatkov sicer nimamo, iluzorno pa je pričakovati, da je naš sistem idealen in da se pri nas napake ne pojavljajo. Preprečevanje in zmanjševanje takšnih napak lahko zmanjšamo z ustreznim izobraževanjem in s programom za zaposlene v sistemu zdravstva. Tako jih pripravimo na situacije, kjer obstajajo tveganja napak. Medicinsko izobraževanje z uporabo simulatorjev je zadnjih 10 let naredilo na tem področju velike korake predvsem v ZDA, precej aplikacij je na področju inteligentnih tutorskih sistemov [98, 71, 31, 92].

Proces izvedbe simulacije zahteva razen kakovostnega simulatorja tudi pripravo ustreznih scenarijev, po katerih potekajo vaje. Problemi se pojavljajo v pomanjkanju ustreznih scenarijev, po katerih naj bi deloval simulator, saj se največkrat za izdelavo scenarijev uporabijo eksperti na posameznih medicinskih področjih [15, 16]. Takšno delo je dolgotrajno in v precejšnji meri subjektivno, saj imajo različni zdravniki različne izkušnje, prav tako je prisotna dobro poznana problematika skupnih stičnih točk med zdravniki in inženirji, ki prevzemajo obveznosti do materialne in programske implementacije scenarijev. V tem pogledu je generiranje scenarijev še posebej zahtevno in kompleksno delo.

Današnji novi pristopi v edukaciji težijo k z dokazi podprtih medicini (Evidence Based Medicine) [53]. Še posebej v zadnjem času je čutiti potrebo po orodjih za analizo uskladiščenega znanja, ki se skrbno skladišči v bolnišničnih informacijskih sistemih, ter njegovo uporabo in transformacijo znanja v namene posredovanja učnih vsebin [69, 77, 91, 79]. Pri tem se srečujemo z dejstvom, da zaposleni zdravstveni delavci, ki opravljajo vlogo posredovanja učnih vsebin študentom in specializantom, nimajo dovolj večin potrebnih za sofisticirano analizo podatkov in uporabo znanja, pridobljenega iz teh podatkov, saj se strojno učenje danes v medicini pogosto uporablja le za predikcijske namene in namene diagnostike [72, 51].

Anestezija, intenzivna medicina in urgenca so področja medicine, ki spadajo med bolj problematična. Urgeanca velja tudi v raziskavah med bolj zastopanimi področji [83, 43, 17, 74, 11], saj se v tej domeni medicine sprejemajo hitre in natančne odločitve, ki so ključnega pomena za preživetje bolnika, kjer ima vsaka napaka visoko ceno. Problem,

s katerim se soočajo edukatorji pri izobraževanju, je predvsem, kako učinkovito naučiti zdravstveno osebje, da prepozna problem in ustrezno ukrepa v kriznih primerih, ki se lahko pojavijo med obravnavo bolnika. Pri tem imajo največje težave novozaposleni, saj se zaradi širokega nabora različnega znanja, pridobljenega v rednem izobraževanju, na delovnem mestu ne znajdejo takoj, kar predstavlja precejšen problem. Po drugi strani ima lahko težave tudi že zaposleno osebje, ki večino postopkov dela že rutinsko, težko pa prepozna redke in krizne situacije, ki predstavljajo visoko stopnjo tveganja za bolnika. Zdravstveni delavci se v svojem delovnem okolju srečujejo tudi s kompleksno medicinsko opremo predvsem v operacijskem bloku, v enoti intenzivne nege, na dializi, urgenci in še na mnogih mestih, kjer tehnična znanja načeloma ne spadajo med njihove veščine, vendar sta prav tehnika in tehnologija tisti, ki v veliki meri skrbita za preživetje bolnika.

Simulacije v izobraževanju danes tako predstavljajo pomemben vidik in orodje, pri čemer je še posebej pomembno podajanje znanja iz realnega okolja. Doktorska disertacija v gradnjo scenarijev za simulator prinaša prav slednje, saj uporablja za gradnjo hevristične metode strojnega učenja, kar ne velja za klasično izdelavo scenarijev za simulator.

### 1.3 Cilji doktorske disertacije

Glavni cilj doktorske disertacije je tako raziskati možnost uporabe hevrističnih metod za podporo gradnje medicinskih scenarijev in izdelati metodologijo za računalniško podprtlo gradnjo scenarija za simulator na podlagi hevristike, ki nam jo omogočajo metode strojnega učenja. Rezultat doktorske naloge je tako na podlagi raziskanih možnosti razviti in izdelati metodologijo CASGen (Computer Aided Scenario Generation), ki bi pri gradnji scenarija uporabljala sofisticirane metode strojnega učenja in služila uporabniku kot podporno orodje pri izdelavi scenarija za simulator. Pri tem bi omogočila možnost uporabe realnih podatkov, ki se danes zbirajo v informacijskih sistemih. Tako izdelana metodologija naj bi s tem nadgradila klasično gradnjo scenarija za simulator s podporo metod strojnega učenja, ki se danes v medicini uporablja predvsem za prediktivske namene in namene diagnostike.

### 1.4 Predpostavke in omejitve

Pri raziskavi možnosti metodologije in gradnje hevristično podprtih scenarijev smo se zaradi narave dela in okolja za simulator, ki smo ga imeli na voljo, omejili pri nekaterih

predpostavkah.

1. V doktorskem delu nismo imeli možnosti povezati razvite metodologije CASGen s programskim paketom simulatorja SimMan zaradi patentiranega in zaščitenega programskega uporabniškega vmesnika, ki ga uporablja simulator. Ogrodje CASGen je zato izdelano kot samostojna aplikacija za simulator.
2. Pri izbiri metod strojnega učenja smo se na podlagi narave scenarijev, vsebovane diagnostike in verjetnosti, ki se pojavljajo v scenarijih, odločili za uporabo verjetnostnih mrež, ki temeljijo na Bayesovi statistiki, saj so le-te simbolične metode, ki predstavljajo najprimernejše orodje za izdelavo vzročno-posledičnih relacij in omogočajo nekatere druge lastnosti, ki smo jih uporabili pri gradnji scenarija. Zaradi zapletenosti izdelave scenarija smo se v metodologiji CASGen omejili na diskretne verjetnostne mreže.

## 1.5 Teze doktorske disertacije

V doktorski disertaciji želimo potrditi naslednjo hipotezo in obravnavati naslednje raziskovalno vprašanje:

**Hipoteza** *Bayesove verjetnostne mreže kot metode v strojnem učenju predstavljajo primeren model za podporo gradnje scenarijev za simulator na področju medicine.*

**Raziskovalno vprašanje** *Ali je izdelana metodologija CASGen primerno in uporabno orodje za uporabo Bayesovih mrež pri gradnji scenarijev za strokovnjake s področja medicine, ki se srečujejo z izdelavo scenarijev za izobraževalne namene?*

Hipoteza razširi dosedanjo gradnjo scenarijev za simulator z uporabo verjetnostnih mrež, ki nam omogočajo integracijo realnih podatkovnih zbirk pri izdelavi scenarija in tako nadgradijo klasičen postopek izdelave scenarija. Zraven tega verjetnostne mreže v sam scenarij vnašajo tudi možnost sklepanja (inference), kar še dodatno izboljša izdelan scenarij pri njegovi uporabi v realnem okolju. Raziskovalno vprašanje se nanaša na možnosti uporabe verjetnostnih mrež iz izdelanega orodja CASGen.

Raziskovalno vprašanje smo preverili s pomočjo strokovnjaka iz domene medicine v kvalitativnem smislu, saj kvantitativno preverjanje zaradi empiričnih scenarijev, ki so bili izvedeni s pomočjo izdelane metodologije in jih predstavljamo v doktorski disertaciji,

še ni bilo mogoče. Kvantitativno preverjanje bo mogoče narediti v prihodnje na podlagi uporabe metodologije v naslednjih nekaj letih, ko se bo metodologija v večji meri uporabljala pri izobraževalnih namenih in bo tako mogoče zbrati potrebno število izdelanih scenarijev. V doktorskem delu smo torej raziskovalno vprašanje preverili na podlagi danih možnosti izdelanih empiričnih študij, katerih uporabnost in pravilnost je preveril neodvisni ekspert s področja medicine.

## 1.6 Izvirni znanstveni prispevki

Disertacija uvaja inovativne koncepte, kot so združitev in uporaba verjetnostnih mrež pri izdelavi scenarijev za simulator, ob tem pa uvaja naslednje novosti:

- Definicijo in implementacijo metodologije CASGen, orodja za podporo hevristične gradnje scenarijev za simulator
- Avtomatsko pridobivanje novega znanja iz realnega okolja za potrebe gradnje scenarija
- Integracija verjetnostnega sklepanja v že zgrajen scenarij
- Definicijo in načine uporabe različnih algoritmov za verjetnostne mreže pri gradnji scenarija

## 1.7 Struktura doktorske disertacije

Ideja disertacije temelji na izdelavi hevristično podprtih scenarijev, ki so potrebni za učinkovito izobraževanje s simulacijami pri učnih procesih, zato v prvem poglavju disertacije predstavimo simulatorje v medicini, posebej opišemo simulator SimMan, s katerim razpolagamo na fakulteti, in opišemo gradnike ter izdelavo scenarija pri SimMan simulatorju. V drugem poglavju podamo nekatere teoretične osnove, ki so potrebne za razumevanje verjetnostnih mrež, metode strojnega učenja, na katerih temelji izdelana metodologija v nalogi, in sicer osnovne zakonitosti teorije grafov in verjetnostnega računa. Nadaljujemo z opisom verjetnostnih Bayesovih mrež, kjer posebej opišemo diskretne Bayesove mreže; predstavimo zakonitosti ročne gradnje modela ter podamo množico algoritmov in napotkov za gradnjo Bayesovih mrež iz podatkov ter natančno opišemo

postopek inference, verjetnostnega sklepanja, ki je bistvena lastnost omenjene metode in v gradnjo scenarija prinaša prednosti pri uporabi scenarija v simulacijskem okolju.

Sledi poglavje izdelave metodologije in opisa metodologije CASGen, ki temelji na verjetnostnih mrežah, kar predstavlja tudi rezultat doktorske naloge, katerega uporabo prikažemo v 7. poglavju na dveh realnih študijah s področja medicine. V poglavju 8 opišemo kvalitativno ovrednotenje uporabe metodologije CASGen, izdelal jo je strokovnjak s področja urgentne medicine, ki se ukvarja z izdelavo scenarijev za izobraževalne namene. V zadnjem, devetem poglavju, doktorsko disertacijo povzamemo in sklenemo z diskusijo in nekaj sklepnnimi mislimi ter opišemo raziskovalne smernice in nekaj idej za razvoj v prihodnje.

## **Del II**

**Opis problema in teoretično ozadje**



## Poglavlje 2

# Simulacije v medicini

### 2.1 Napredne tehnologije simulatorjev in urjenje osebja v medicini

Današnja medicinska paradigma deluje po principu določanja diagnoz iz znanih simptomov, anamneze in diagnostičnih rezultatov. Ko je postavljena ena ali več diagnoz, se začne zdravljenje, oziroma različne oblike terapij. Medicinsko delo je glede na obstoječo paradigmo akcijsko orientirana disciplina, ki temelji na sprejemanju odločitev v trenutku, ko se že pojavi bolezen. Zaradi prihajajočih novih tehnologij, kot je na primer molekularno slikanje, se medicini obeta premik paradigm [65, 99]. Z molekularnim slikanjem ugotavljajo namreč nepravilnosti v delovanju molekul in tako je mogoče vnaprej določiti scenarije, v katerih se lahko pojavi bolezen. Premik paradigm je v konceptu preventivnega ukrepanja, še preden nastopijo bolezenski simptomi oziroma sama bolezen. [28, 83, 1].

Tako obstoječe, kot prihajajoče nove tehnologije, zahtevajo nove pristope v izobraževanju in urjenju zdravstvenih delavcev. Nepravilno ukrepanje pri zdravljenju namreč vodi v slab izid zdravljenja ali celo v smrt bolnika. Simulacije, kot del sodobnega izobraževanja ponujajo učinkovito pridobivanje znanja in veščin z glavnim namenom, da se izboljša varnost bolnikov. Simulatorji predstavljajo navideznega bolnika, ki je v interakciji z realno medicinsko opremo. S simulacijami ustvarimo okolje, ki je zelo blizu pravim kliničnim razmeram. Bolezenska stanja ter zapleti se simulirajo preko računalniške programske opreme in elektronskih sistemov.

Do nedavnega je zdravstveno osebje pridobivalo znanje in veščine na laboratorijskih

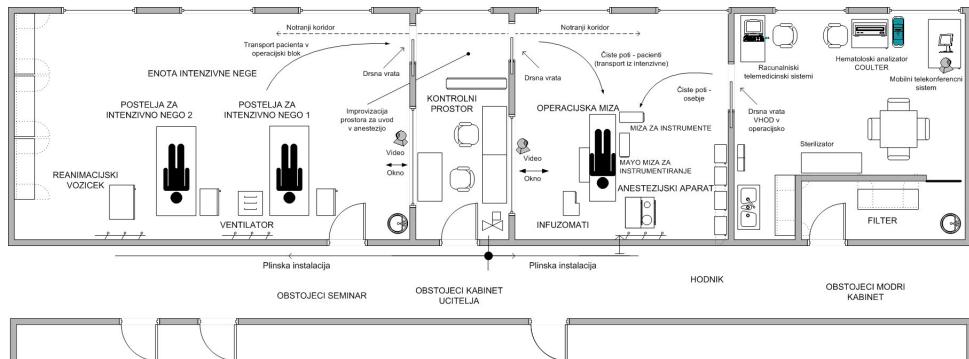
živalih, kadavrih in predvsem na bolnikih. Živali nimajo ustrezne anatomije, zato je pridobivanje realnih veščin težje, so drage in jih ne morejo ponovno uporabljati. Kadavri sicer imajo ustrezno anatomijo, težave pa so prav tako v ceni in tkivo se hitro degradira. Bolniki po drugi strani pričakujejo najvišjo možno kvaliteto v zdravljenju in niso več pripravljeni biti učni predmet. V vseh omenjenih primerih so problematična visoka etična načela, ki veljajo danes [24, 1]. V današnjem času ni več opravičila, da se kirurg uči na bolniku [41]. V učne načrte se zato vpeljujejo simulacije, z namenom izboljšati varnost bolnika, saj zdravstveno osebje s tem pristopom pripravimo na kompleksne situacije, ki nikakor niso redkost v zdravljenju bolnika. Simulacije potekajo v okolju brez tveganja, tako za bolnika kot za zdravstveno osebje, prinašajo pa precej stresa samemu udeležencu [42], ki si ga želi še več. Tehnologija v razvoju simulatorjev je zelo napredovala in tržišče nam nudi navidezne, virtualne simulatorje, kot je na primer specializirani endoskopski simulator [18, 22], kardiološki simulator [66], kirurški simulator [81, 29, 60], urološki simulator [55]. Imamo pa tudi simulatorje, ki so po obliki in funkcijah podobni pravemu bolniku in se uporabljo predvsem na anesteziji [61, 63].

## 2.2 Simulacijsko okolje

Simulacije v medicini vključujejo uporabo simulatorjev, s pomočjo katerih posnemamo realno klinično okolje, kjer je bolnik ali ponesrečenec [62]. Simulacijsko okolje, kjer se izvajajo medicinske simulacije, predstavlja integracijo informacijsko-komunikacijskih tehnologij in realne medicinske opreme v učni proces. Simulacije v takem okolju predstavljajo trenutno naj sodobnejše učne metode, ki povečajo učinkovitost učenja medicinskih ved, kar je pokazano v številnih raziskavah [6, 5, 1, 28].

S simulacijami je mogoče simulirati simultano delo več multidisciplinarnih zdravstvenih timov, ki nastopajo skupaj v kompleksnih procedurah [101, 56], kot je to primer v urjenju posadk v letalstvu [7]. V kriznih situacijah je zelo pomembno, na kakšen način timi in posamezni udeleženci med seboj komunicirajo in kako sinhrono med seboj delujejo v reševanju določenega kliničnega problema, kot je na primer požar [97, 93, 23]. S klasičnimi učnimi pristopi je takšno izobraževanje težko izvesti. Za kvalitetno in ustrezno izvedbo simulacij je treba prostorsko urediti simulacijsko okolje. Na Fakulteti za zdravstvene vede smo delno uredili prostore, kjer potekajo simulacije tako, kot je prikazano na sliki 2.1.

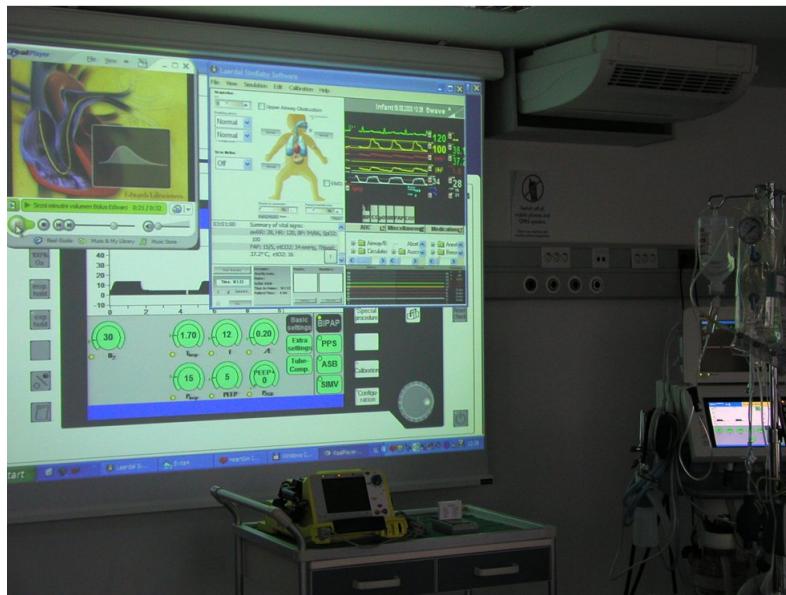
Simulacijski prostor smo razdelili na tri dela. Prvi del predstavlja enoto intenzivne



Slika 2.1: Prostorska ureditev simulacijskega okolja.

nege in terapije, v drugem delu pa se nahaja operacijski blok. Vmes med obema enotama je kontrolni prostor, kjer se nadzira potek simulacij. Nadzorni računalnik je preko serijskega vodila povezan z osrednjo enoto simulatorja. V prostoru intenzivne nege in terapije imamo dva simulatorja, Laerdal SimMan in Laerdal Skillmaster. V tem prostoru je mogoče izvajati simulacije iz domene urgentne medicine in intenzivne nege ter terapije. Kirurški del simulacijskega okolja mora vsebovati celotno infrastrukturo za izvajanje anestezije, ki je največ zastopana v simulacijah [83]. V tem delu so potrebni anestezijski aparat in vsa potrebna oprema za anestezijo. Plinske in električne instalacije morajo biti prilagojene potrebam simulacijskih scenarijev.

Kompleksne diagnostične in terapevtske postopke srečamo največ v domeni anesteziolijke, intenzivne nege in perioperativnega zdravljenja. Za suvereno delo na teh področjih so potrebne dobro načrtovane izobraževalne metode. Brez ustrezno izobraženega kadra ne moremo pričakovati kvalitetnega dela na teh področjih. Pojavljale se bodo napake, nemalokrat tudi z usodnimi posledicami. Pri izobraževanju za delo s kompleksno tehnologijo je dobra izbira, da se v samo okolje s simulatorjem in medicinsko opremo integrira možnost mikrosimulacij. Mikrosimulacije se izvajajo samo na računalniškem zaslonu. Na sliki 2.2 je prikazano simulacijsko okolje na Fakulteti za zdravstvene vede, kjer na projekcijsko platno projiciramo vsebine mikrosimulacij iz računalniškega projektorja. Na platnu so simultano prikazane simulacije ventilatorja Evita 4, SimBaby otroškega simulatorja in videoanimacija vstavljanja Swan Ganzovega katetra. Podobno lahko postavimo računalniški monitor večjih dimenziij čim bliže mestu neposredne simulacije. Na sliki 2.3 je simulator SimMan, ki smo ga pripravili na operacijski poseg v okolju realne medicinske opreme. Na anestezijskem aparatu je monitor, kjer teče multimediji predstavitev iz portala endoskopske kirurgije. Multimediji predstavitve in mikrosimulacije so tako komplementarne osrednjim simulacijam, ki tečejo na simulatorju.



Slika 2.2: Simulacijsko okolje - integracija mikrosimulacija.



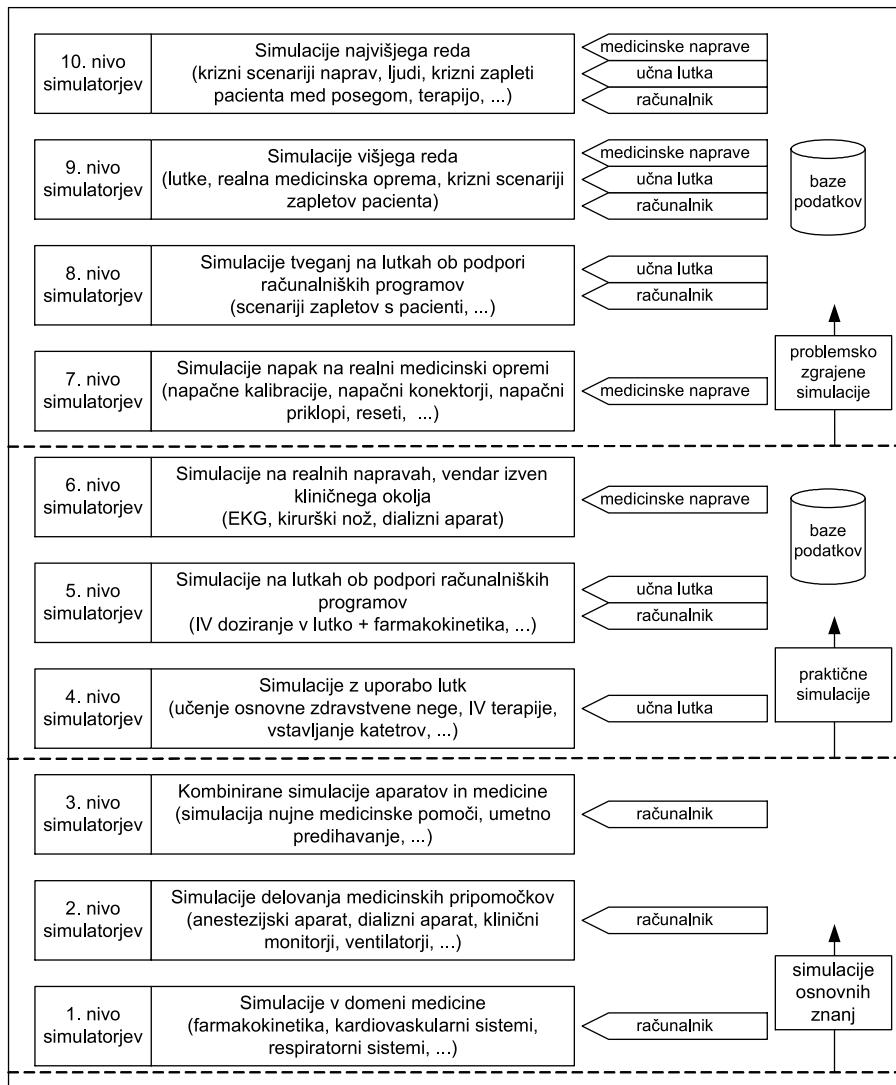
Slika 2.3: Simulacijsko okolje - realna medicinska oprema.

### 2.2.1 Razdelitev simulatorjev

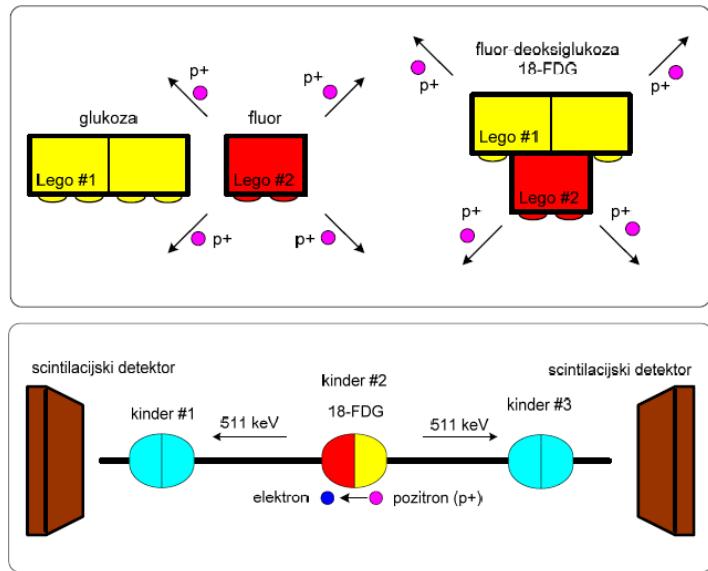
Pri sami izvedbi simulacij obstajajo različni pristopi, ki jih razdelimo glede na kompleksnost posamezne simulacije. Za vsak tip simulacije je treba izbrati ustrezen simulator. Na sliki 2.4 smo predstavili nivojsko razdelitev simulatorjev, glede na njihovo uporabo. Trije najnižji nivoji (1-3) predstavljajo simulacije zasnovane samo na matematičnih modelih fiziologije in patofiziologije, ali na modelih medicinskih aparatov. Za takšno vrsto simulacij, ki jim pravimo tudi mikrosimulacije, potrebujemo le računalnik in ustrezno programsko opremo. Na teh nivojih simuliramo osnovna znanja iz fizioloških in patoloških procesov ob pomoči računalnika, na katerem se izvaja računalniški program v interakciji s študentom. Študent spreminja le določeno omejeno število parametrov, ki nastopajo v simulaciji. Prvi stik študentov z življenjskimi funkcijami bolnika se tako izvaja preko računalniških simulatorjev. Simulacije na treh nivojih se lahko uporabljajo pred večjim številom študentov med predavanji.

Simulacije od četrtega do šestega nivoja (4-6) so že bližje praktičnemu delu na simulatorjih (Practice-Based Simulations) in uporabljajo realnejše modele v obliki lutk. Podatkovne baze na teh nivojih nam služijo na primer za simuliranje napak na medicinski opremi. Bazo lahko polnimo iz ameriškega sistema poročanja o nevarnih dogodkih: FDA MedWatch (FDA Safety Information and Adverse Event Reporting Program). Četrti nivo zajema samo lutke, ki so fizično podobne realnim bolnikom. Kombinacija računalnika in lutke na petem nivoju pomeni, da na primer, ko v lutko apliciramo IV zdravilo, istočasno poženemo simulacijo farmakokinetike na računalniku in opazujemo, kako se spreminja koncentracija zdravila znotraj telesnih tekočinskih prostorov. Takšna simulacija poteka na dveh popolnoma ločenih simulatorjih: na lutki, ki omogoča IV aplikacijo zdravil, in na računalniku, ki modelira farmakokinetične in farmakodinamične modele. Farmakokinetiko je mogoče učiti tudi preko oddaljenega omrežja z uporabo simulatorjev na visokih nivojih [14].

Na šestem nivoju se srečujemo z učenjem za delo z medicinskim napravami, ki postajajo danes vse bolj kompleksne. Pomembno je, da zdravstveni delavci dobro poznajo delovanje inštrumentov in aparatov, za katere skrbijo in tudi odgovarjajo za njihovo brezhibno delovanje. Na tem nivoju se simulirajo medicinski pripomočki, predvsem tisti z višjo kompleksnostjo delovanja (ventilatorji, defibrilatorji, anestezijski aparati, elektrokirurška oprema ...). S takšnim simulacijskim pristopom se študentje lažje naučijo osnovnih znanj, povezanih s funkcioniranjem aparata. Problem, ki se nam pojavi pri izobraževanju na tem nivoju, je, kako simulirati zelo kompleksne aparate, ki so tako dragi,



Slika 2.4: Nivojska razdelitev simulatorjev.



Slika 2.5: Enostavna simulacija PET/CT diagnostične modalitete.

da jih ne moremo postaviti v simulacijsko okolje. Primer takega aparata je funkcionalna diagnostična slikovna metoda nuklearne medicine PET, kjer se cena aparata giblje v nekaj milijonih evrov. Učenje za takšno obliko aparatov izvajamo s pomočjo improvisiranih učnih pripomočkov. Na sliki 2.5 je prikazano, kako smo z navadnimi lego kockami izdelali pripomoček za učenje mehanizmov pozitronske emisijske tomografije (PET) v nuklearni medicini. Hiter razvoj strojne in programske medicinske opreme pomeni, da medicinski pripomočki postajajo vse bolj zahtevni za uporabo. Delodajalec večinoma ne omogoča kontinuiranega izobraževanja zdravstvenih delavcev v domeni upravljanja medicinske opreme, zakonodaja pa tega tudi posebej ne zahteva [25]. Vsakdanje delo zdravstvenih delavcev razen poznavanja medicinske stroke tudi poznavanje tehničnega vidika elektronskih sistemov in instrumentov. Prodajalci medicinske opreme učijo zdravstveni kader upravljanja z medicinskimi pripomočki, vendar imajo ti zastopniki različne stopnje izobrazbe in znanja, nemalokrat tudi daleč od področja, ki ga zastopajo in katerega opremo prodajajo. Delavci v zdravstvu se naučijo, kdaj in kako pritisnejo na kak gumb, pri tem pa se pozablja, da je potrebno tudi razumevanje, kaj se zgodi v aparatu, ko se gumb pritisne, in kako bo to vplivalo na bolnika. Uradnega preverjanja znanja ni in ostaja odprto vprašanje, ali je bil prenos znanja uspešen. Ali je vsem resnično jasno, kako aparat deluje, kakšne posledice lahko ima nestrokovno ravnanje in kakšne posledice so lahko za bolnika in osebje, ki je večino delovnega časa v stiku s temi aparati. Pogosto srečamo



Slika 2.6: Generični anestezijijski aparat.

navodila za uporabo, ki so slabo napisana (prevedena) in premalo razumljiva. Mno-  
gokrat jih prevajajo prevajalci, ki niso iz zdravstvenega področja. Pojavlja se dvom, ali je  
takšen transfer znanja od prodajalca na zdravstveno osebje dovolj kvaliteten. Zdravstveni  
delavci v operativni dejavnosti potrebujejo za suvereno delo na svojem področju več let  
učenja in pridobivanja znanja. Zaradi kompleksnosti posameznih aparatov izvajamo te  
simulacije v dveh delih, kar bomo pokazali na naslednjih primerih simulacij za delo z  
anestezijijskim aparatom. Slika 2.6 prikazuje generični anestezijijski aparat, kjer so zelo  
dobro vidne osnovne komponente aparata, kot je anestezijijski dihalni sistem (ADS) in  
mešalna stopnja za mešanje kisika in dušikovega oksidula. Na tem aparatu izvedemo v  
prvi fazi učenja, osnovne simulacije delovanja anestezijijskega aparata, drugi del simulacij  
pa se izvaja na sodobnem anestzijskem apatu, prikazanem na sliki 2.7. Simulatorji  
na višjih nivojih (7-10) nam ponudijo največ znanja. S temi simulatorji se nam odpirajo  
možnosti učenja na problemsko orientiranih simulacijah (Problem-Based Simulations).  
Oprema za takšne simulacije je cenovno draga, vendar so rezultati učenja z njo zelo  
obetavni. Takšne simulatorje smo poimenovali visokonivojski simulatorji ali simulatorji  
bolnika širokega spektra (angl.: Full Scale Patient Simulators, Hands-on Simulators).  
Vsakdo, ki dela v okolju, kjer se pogosto dogajajo krizni akutni dogodki, doživlja pre-  
cejšnjo količino skrbi in strahu, kako se bo obnesel v situaciji, ko je ogroženo življenje  
bolnika. Kako se tim ali posameznik obnese v teh primerih, je odvisno od več faktorjev:



Slika 2.7: Urjenje na sodobnem anesteziskem sistemu.

znanja, izkušenj, interakcije v timu in od vodje tima. Vse te razmere se dajo simulirati z visokonivojskimi simulatorji. Za pristope problemskega učenja uporabljamo simulator Laerdal SimMan, prikazan na sliki 2.8. Ti simulatorji so primerni za že zaposleno in utečeno zdravstveno osebje, ki se tako spoznava z redkimi, a kriznimi situacijami.

### 2.2.2 Simulacije širokega spektra

Za uspešno izvedbo problemsko zasnovanih simulacij moramo imeti v mislih ustrezno načrtovanje na različnih nivojih [19], še preden izvajamo simulacije. Ni dovolj, da imamo najboljšo simulacijsko opremo, ampak moramo upoštevati dodatne zahteve, če hočemo študente ustrezno naučiti kompleksno snov. V kontekstu simulacij širokega spektra (full-scale patient simulation) moramo ločiti 4 različne načrtovalne stopnje:

- *načrtovanje strojne opreme,*
- načrtovanje programske opreme,
- načrtovanje učnega načrta (kurikuluma),
- načrtovanje izvedbe vaj.

Načrtovanje strojne opreme je v domeni proizvajalca simulatorja. V tej fazi poskuša proizvajalec izdelati simulator tako, da je vizualno in funkcionalno čim bolj podoben



Slika 2.8: Visokonivojski simulator Laerdal SimMan.

bolniku. Uporablja se lutke (angl.: mannequin), v katere se vgradijo mehanični in elektronski sistemi. Strojna oprema generira električne in mehanske odzive bolnika, tako fiziološke kot patološke. Te simulatorje smo v prejšnjem poglavju imenovali visokonivojski simulatorji.

Načrtovanje programske opreme je prav tako v domeni proizvajalca simulatorja. Izdela se uporabniški vmesnik, kjer se lahko spremeljajo in nastavljajo različne fiziološke spremenljivke, ki jih simulira simulator [103]. V programski opremi so farmakološki matematični modeli za izračun distribucije in učinkov posameznih zdravil. Programska oprema skrbi za komunikacijske protokole, kodno strukturo in programski jezik.

Breme načrtovanja učnega načrta prevzema nase uporabnik simulatorja. V učnem načrtu se mora določiti, katere so ciljne skupine, saj se raven zahtevnosti spreminja glede na različne udeležence simulacij. Jasno moramo določiti, kaj hočemo udeležence naučiti, in glede na to izdelati scenarije. V načrtovanju učnega načrta moramo pripraviti prav tako metodologijo preverjanja znanja.

Zadnja faza v simulacijah popolnega spektra je načrtovanje same izvedbe v obliki simulacije. V tej fazi se določi število udeležencev, ki je po navadi majhna skupina (6-8 udeležencev), če želimo izvajati zelo zahtevne scenarije. Prav tako se določi vsa potrebna oprema v obliki medicinskih pripomočkov, ki so potrebni pri simulaciji. Podjetje METI (Medical Education Technology) proizvaja trenutno najbolj izpopolnjen simulator na



Slika 2.9: Simator bolnika METI HPS.

tržišču. Simulator bolnika METI HPS [61] je simulator širokega spektra (Full Scale Simulator). Zelo nam realno simulira človeške fiziološke in patofiziološke procese. Sestavni deli simulatorja so lutka v velikosti človeka, elektronski pnevmatski sistemi in nadzorni programski paket z računalnikom 2.9. Podjetje METI proizvaja pet različic simulatorjev bolnika in tako zadovolji različne potrebe uporabnikov:

- METI HPS - Human Patient Simulator,
- METI ECS - Emergency Care Simulator,
- METI BabySim - simulator dojenčka,
- METI PediaSim - simulator otroka,
- METI i-Stan - brezžični simulator.

HPS je najbolj izpopolnjen simulator iz družine in bomo v nadalnjem tekstu večinoma opisovali njegove funkcije. ECS je simulator, namenjen za specifične simulacije v nujni medicinski pomoči. Simulator dojenčka BabySim predstavlja dojenčka starega med 3-6 mesecev. Pediatrični simulator otroka PediaSim ima podobne funkcije kot HPS, le da vizualno predstavlja otroka, starega 6 let. Novost, ki jo ponuja podjetje METI je brezžični simulator i-Stan, ki ima vse potrebne komponente, integrirane v lutki. Povezava z nadzornim računalnikom je brezžična in je prav tako kot vse ostale verzije simulatorjev zasnovan modelsko, kar bomo razložili v naslednjih poglavjih.

Pri visokonivojskih simulacijah je mogoče uporabljati realne klinične monitorje različnih proizvajalcev, kjer se prikazujejo neinvazivni krvni tlak (NIBP), invazivni krvni tlak, minutni iztis srca (CO), nasičenost krvi s kisikom (SpO<sub>2</sub>), pulz, EKG in telesna temperatura. Uporaba realne medicinske opreme je pomemben faktor med simulacijo, saj na ta način še bolj približamo simulacijsko okolje pravim razmeram. Pazljivi moramo biti



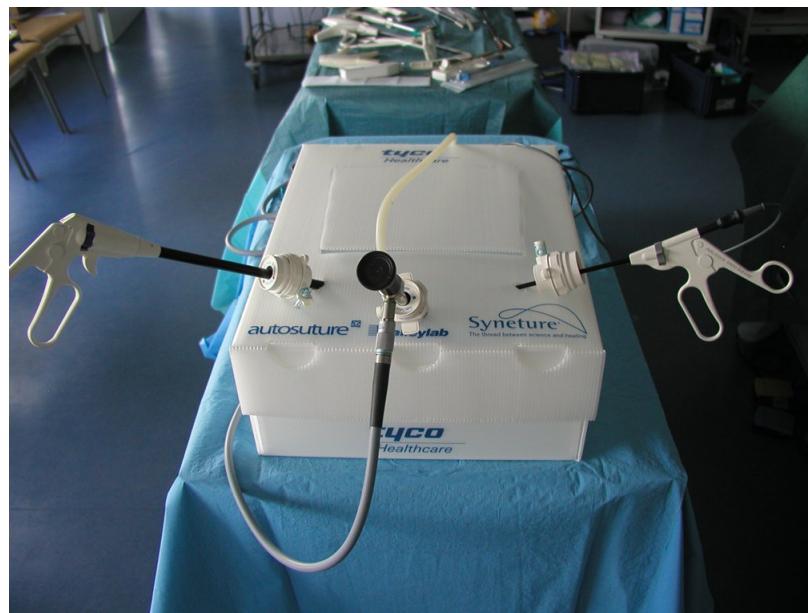
Slika 2.10: Simulator anestezije SimMan - uporaba v endoskopijah.

na potencialne napake na simulatorju, ki lahko posledično vodijo v neustrezno edukacijo [3].

Pri sami izvedbi simulacij širokega spektra so lahko prisotni timi različnih strok, kot na primer anesteziologi in kirurgi. Takšno okolje smo prikazali na sliki 2.10. Problem, ki se pri tem pojavi, je, da na tržišču ni tako kompleksnega simulatorja, ki bi zadovoljil hkratne potrebe tako kirurgov kot anesteziologov. V takih primerih lahko izvedemo fuzijo simulatorjev in istočasno uporabljamo dva popolnoma različna simulatorja. Prvi simulator je klasični simulator bolnika, prikazan na sliki 2.10, drugi simulator pa je endoskopski simulator, prikazan na sliki 2.11. Na tem področju fuzije simulatorjev je odprtih mnogo možnosti za nadaljnje raziskave.

### 2.2.3 Prednosti uporabe simulatorjev

Tehnologija se v medicinskem delovnem okolju razvija in izpopolnjuje zelo hitro in intenzivno. Razen tehnološkega razvoja napreduje tudi znanje, povezano z zdravljenjem bolnika, diagnostiko in razumevanjem človeške fiziologije ter patologije. Takšno hitro razvijajoče se okolje seveda zahteva tudi dodatne izobraževalne metode že v času šolanja, za kompetentno prihodnje delo zdravstvenega osebja. Prednost uporabe simulatorjev za že zaposleno zdravstveno osebje pa je, da na takem mestu znanje obnavlja, ga nad-



Slika 2.11: Simulator endoskopskih posegov.

grajuje in predvsem simulira krizne scenarije. Simulacije imajo prednost pred klasičnimi izobraževalnimi metodami v času študija medicinskih ved, saj nam pomagajo bolje razumevati učne snovi. Ne smemo pozabiti največje prednosti, da s simulacijami ne moremo povzročiti škode.

Pri problemsko zasnovanih simulacijah morajo študentje iz problema izluščiti znanje, ki ga potem uporabljajo v praksi. Na sliki 2.12 je prikazano, kako s problemskim pristopom skušamo pojasniti Bernouliljev pojav in Venturi učinek. Prikazana je levitacija žogice nad sistemom za dovajanje zdravil - inhalatorjem. Razumevanje delovanja inhalatorjev je ključnega pomena pri njihovi varni uporabi. Prednost omenjene simulacije je, da se preko nje tudi da razložiti in povezati z različno opremo, kot so Venturi maske in aspiratorji, ki predstavljajo največ uporabljane medicinske pripomočke.

Simulacije zagotavljajo v primerjavi s tradicionalnim izobraževanjem realni trening v komunikacijskih veščinah, vodenju v kriznih razmerah, interakcijo različnih timov in opazovanje študentov, kako so vešči pri delu na simulatorju. Prednosti simulacij so naslednje:

- boljši izidi zdravljenja bolnikov in zmanjšanje napak in smrti,
- medicinsko osebje je bolj pripravljeno na redke ozioroma nenavadne primere,



Slika 2.12: Levitacija žogice med simulacijo delovanja inhalatorja.

- zaradi ustreznega treninga je zdravstveni kader sposoben povečati število kompleksnih rizičnih posegov,
- zdravstveno osebje ima več izkušenj in spretnosti pri rutinskih opravilih,
- v zdravstvenih organizacijah se zmanjšajo neželeni škodljivi dogodki,
- povečanje kvalitete življenja,
- zmanjšanje stroškov v zdravljenju,
- zavarovalnicam se zmanjšajo stroški zaradi potencialnih tožb v primeru napak osoba,
- študentje dobijo fleksibilni študijski načrt, poveča se razumevanje in ni škode za bolnike,
- več zdravih delovnih ljudi predstavlja dobitek za celotno družbo.

### 2.3 Simulacijski scenariji

Scenariji so navodila, po katerih deluje simulator med izvajanjem urjenja. Odražajo bolnikovo stanje, ki se spreminja s časom ali glede na posege zdravstvenega osebja. V



Slika 2.13: Mikrosimulacija - Laerdal MicroSim.

njih morajo biti predvideni vsi zapleti in mora biti dan odgovor na vsako intervencijo, ki jo udeleženci simulacij izvedejo. Zato predstavlja gradnja scenarijev kompleksen in dolgotrajen proces. Simulatorji na nižjih nivojih, kot je na primer MicroSim, imajo scenarije narejene tako, da se potrebna komunikacija izvaja z uporabnikom samo preko računalniškega zaslona. Prikaz simulatorja MicroSim je na sliki 2.13.

Laerdalov MicroSim simulator je primeren za učenje študentov v domačem okolju saj si študentje sami usmerjajo učenje, tako da si izbirajo želene scenarije. MicroSim obsega tri različne verzije:

- prehospitalna obravnava,
- hospitalna obravnava,
- scenariji za vojsko.

Prehospitalna obravnava vključuje scenarije s področja nujne medicinske pomoči. Posamezni moduli vključujejo:

- dihalne poti in dihanje,
- bolečina v prsih,
- srčni zastoj 1,

- srčni zastoj 2,
- srčna aritmija 1 (tahikardija),
- srčna aritmija 2 (bradikardija),
- metabolični zapleti,
- zastrupitve.

Vsek od teh 8 modulov vsebuje po 5 scenarijev. Težava pri izdelavi simulacij v prehospitalni obravnavi je nenehno obnavljanje smernic. Smernice v nujni medicinski pomoči se obnavljajo vsaka 4 leta, zato ima proizvajalec programske opreme zaradi kratkega časovnega obdobja težave pri implementaciji le-teh. Simulator MicroSim ima na primer še vedno razmerje med masažo in vpihi 15:2, medtem ko nove smernice nalagajo novo razmerje 30:2. Ta dejstva je treba imeti v mislih pri nabavi simulatorja ali pa raziskati, kako izvajati simulacijo, kljub nekaterim napačnim protokolom, kar predstavlja izziv pri načrtovanju simulacij.

Večina simulacijskih scenarijev v anesteziologiji, urgentni medicini in intenzivni medicini potrebuje mehanizme, pri katerih simulator reagira na različne terapije in posege. Kariovaskularni in respiratorni sistem se spreminja glede na aplikacije tekočin, pljučna mehanika se spreminja pri umetni ventilaciji, vsi sistemi pa reagirajo na aplicirana zdravila. Obstajata dva različna pristopa za generiranje teh reakcij simulatorja: modelski in sekvenčni.

### 2.3.1 Sekvenčno zasnovani scenariji

Sekvenčni pristop je v obliki scenarijev, kjer z množico ukazov simulator postavimo v ustrezeno stanje. Pomik iz enega stanja v drugo se izvede, ko so izpolnjeni pogoji, ki so določeni v scenariju. Scenariji vsebujejo stanja in intervencije, da simulirajo bolnikov fiziološki odgovor. Takšni simulatorji delujejo po principu »IF THEN« stavkov, saj se, ko je izpolnjen določen pogoj scenarij pomakne v novo stanje. Prednost take oblike zapisa je popolnoma eksplíciten in nedvoumen potek scenarija. Vrstni red dogodkov sledi časovni sekvenci, zapisani v skriptah. Na primer, laringoskopija, trahealna intubacija in aortno klemanje.

Slaba stran sekvenčno zasnovanih scenarijev je, da ne morejo predvideti vseh možnih opcij, ki jih izvede udeleženec tečaja. Težava se pojavi prav tako pri aplikaciji zdravil, kjer

ni mogoče simulirati večkratnih zaporednih bolusov, ki jih na primer aplicira udeleženec. Težava je tudi, kako razvrstiti kardiovaskularne in respiratorne odgovore na te posege.

Laerdel SimMan simulator nudi možnost integracije dokumentiranih scenarijev na področju zdravstvene nege v kurikulum. Dvajset scenarijev je pripravljenih za učenje osnovnih in naprednih znanj. V scenarijih je vključeno zajemanje vitalnih znakov in obravnave življenjsko ogrožajočih komplikacij.

Ker v svetu narašča število terorističnih napadov, je Laerdal v sodelovanju z University of Miami's Gordon Center for Research in Medical Education pripravil 25 scenarijev za simulator SimMan na 5 modulih: živčni strupi, eksplozije improviziranih naprav, radiološki strupi, zastrupitve s cianidom in mehurjevcji.

Komercialni scenariji za ACLS (Advances Cardio Life Support) na simulatorju Sim-Man obsegajo 31 scenarijev podprtih z dokumentacijo, ki spremišča tečaj. Pazljivost je potrebna zaradi dejstva, da je del scenarijev povezan ameriškim AHA smernicam (American Heart Association), ki se nekoliko razlikujejo od evropskih ERC smernic (European Resuscitation Council).

### 2.3.2 Modelske zasnovane scenariji

Pri modelsko zasnovanih scenarijih se fiziološka in patofiziološka stanja modelirajo glede na matematične enačbe, ki opisujejo procese kardiovaskularnega, respiratornega in nevrološkega sistema. Primer takega modelsko zasnovanega simulatorja je METI HPS, ki ga bomo v nadaljevanju opisali. Simulator se odziva na zdravila, saj ima vgrajene farmakokinetične in farmakodinamične modele. Ti matematični modeli uvrščajo simulator v sam svetovni vrh komercialno dostopnih simulatorjev. Simulatorjeva blokovna shema je prikazana na sliki 2.14.

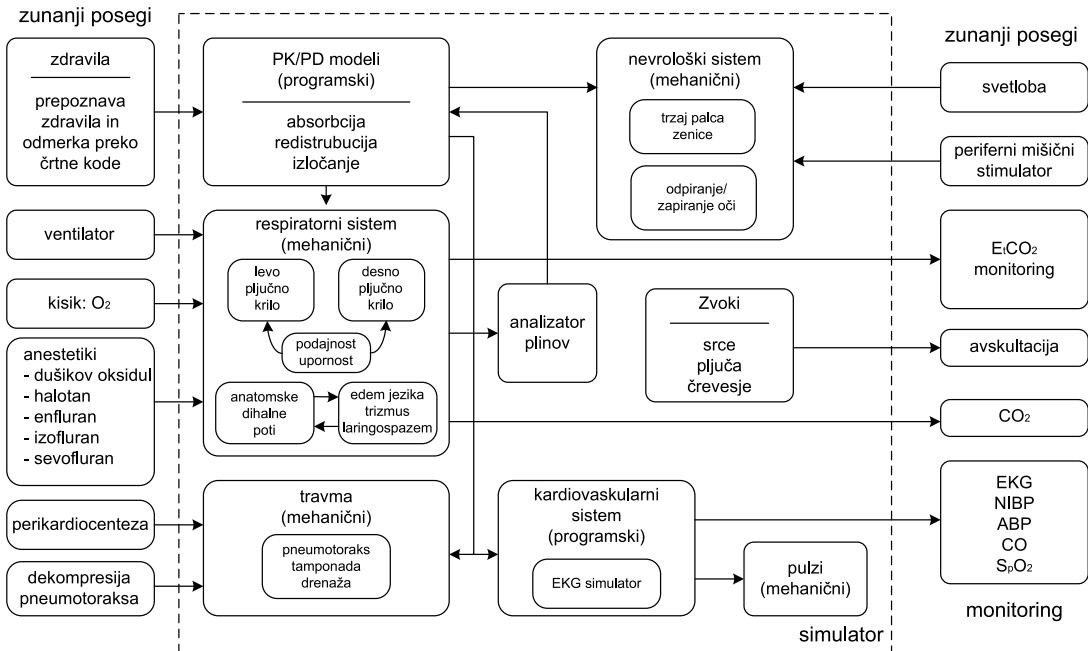
Simulator se avtomatsko odziva na neustrezno medikamentno terapijo. Prekoračitve odmerkov in premajhni odmerki zdravil so ustrezno modelirani in simulator reagira tako, da se njegovo stanje spreminja, glede na dano zdravilo in odmerek. Življenjski znaki simuliranega bolnika se spreminjajo glede na modele in glede na intervencije študentov, ki se izobražujejo na simulatorju. Simulator fizično diha kisik in proizvaja pri izdihu ogljikov dioksid. V anesteziji porablja in izloča vdihani dušikov oksidul ali halotan, enfluran, izofluran in sevofluran v skladu s principi farmakokinetike: absorbcije, redistribucije in izločanja. Koncentracije lahkoklapnih anestetikov, kisika in dušika v anestezijski dihalni

mešanici, lahko merimo s klasičnim anesteziskim aparatom. Če uporabljam simulator v intenzivni negi in terapiji, lahko z ventilatorjem merimo deleže plinov v izdihanem zraku.

Tako za levo kot za desno pljučno krilo lahko posamezno simuliramo upornost, podajnost pljuč in podajnost prsnega koša. Simulator se na umetno ventilacijo odziva simetrično ali asimetrično, kot odgovor na unilateralne ali bilateralne spremembe v podajnosti oziroma upornosti dihalnih poti. Pravilna ali nepravilna intubacija se odraža na pljučni sistem s pljučnimi zvoki in z gibanjem prsnega koša. Patofiziološka stanja, kot je tenzijski pnevmotoraks, ki se ne obravnavajo pravočasno in ustrezno, se patološko kažejo v parametrih, povezanih z respiratornim sistemom. Ventilator pri predihavanju občuti ob sebi bolnika z realnimi enkratnimi volumni, s pretoki in tlaki. Prjni koš se sinhronizirano dviga in spušča glede na fiziološko ali patološko stanje pljuč. Pljučni sistem reagira na intravenska zdravila in je odvisen od odmerka, pri tem pa inštruktorju ni treba izvajati nobene intervencije na nadzorni konzoli.

Plini v arterijski krvi, pH in alveolarni plini se avtomatsko spreminjajo glede na patologijo in so prikazani na inštruktorskem monitorju. Ogljikov dioksid na koncu izdiha ( $\text{EtCO}_2$ ) je odvisen od predihavanja in ga lahko merimo s kapnografom in kapnogramom. Med seboj se lahko v simulatorju prepleta spontano dihanje in kontrolirano oziroma asistirano predihavanje glede na fiziološke odgovore. Na primer, lahko se simulira, kako se bolnik "tepe" z ventilatorjem v primeru, da je priključen na ventilator s kontrolirano ventilacijo in spontano diha. Respiratorični sistem je zmožen prožiti ventilator v načinu asistirane ventilacije, zato se zlahka simulira realno odvajanje od ventilatorja. Zenice simulatorja reagirajo na svetlobo, oči pa se odpirajo/zapirajo v skladu s fiziološkimi procesi bolnika. Avtomatski sistem prepozna preko črtne kodo zdravilo, ki ga mislimo aplicirati v bolusu, in kot posledico aplikacije dobimo fiziološki odgovor na zdravilo v odvisnosti od koncentracije le-tega. Za monitoring nevromišične blokade se uporablja periferni mišični stimulator, ki stimulira trzaje palca. Desna roka na simulatorju vsebuje mesto, kjer se priklopijo elektrode perifernega stimulatorja živcev. Simulator HPS avtomatsko razpozna vzorec, ali gre za enojni trzaj, tetanus ali TOF - Train of Four. Glede na tip vzorca dražljaja in glede na raven nevromišične blokade ter tipom nevromišične blokade (depolarizirajoča, nedepolarizirajoča) simulator avtomatsko generira trzaj palca.

V travmi se simulator največ uporablja za simulacijo pnevmotoraksa, torakalne drenaže in perikardiocenteze. Te intervencije sprožijo ustrezne spremembe, glede na prejšnje zdravstveno stanje bolnika. Oči so reaktivne in zenice reagirajo na svetlobo na ta način, da se postavijo na nastavljen premer v mejah od 2 mm do 9 mm. Oči se odpirajo spon-



Slika 2.14: Modelska zasnova METI HPS simulatorja

tano ali ostajajo zaprte. Ko so oči zaprte, študent zaradi ocene nevrološkega statusa ročno odpre oči.

Igelna perikardiocenteza pomaga odpraviti patološko kardialno tamponado srca. Če je igla ustrezno zabodena, priteče perikardialni fluid in izboljša se hemodinamika, kot so polnитеv, minutni srčni iztis in krvni tlak. Če iglo zabodemo predaleč in pridemo s konico v desni prekat, opazimo občutno povečanje količine fluida. EKG v prekordialnem odvodu omogoča monitoring poškodbenega vzorca zaradi iritacije srca, če je igla priključena na ta EKG odvod. Dekompresija tenzijskega pnevmotoraksa se izvaja v srednji klavikularni liniji v drugem interkostalnem prostoru. Pravilen poseg sproži naglo dekompresijo, ki ji sledi uhajanje zraka in posledično izboljšanje pljučne mehanike in izmenjave plinov.

Hemodinamski odgovor na aritmije srca je fiziološko natančno modeliran. Premalo kisika v srčni mišici ozira oziroma ishemija miokarda avtomatsko sprožita ustrezne srčne ritme zaradi hipoksemije. Glede na ritem srca se spreminjajo ali izginejo karotidni, brahialni, femoralni, poplitealni in pedalni pulzi. Pulz se ne tipa, ko sistolični arterijski tlak pada pod določeno mejo. V primeru travme se pulzi posamično nastavljajo na specifičnih ekstremitetah. Model invazivnega hemodinamskega monitoringa zagotavlja sposobnost merjenja in monitoringa različnih tlakov: tlak v levem in desnem ventriklu, centralni venski tlak, arterijski tlaki v radialni arteriji, tlak v pljučni arteriji, zagozditveni tlak v

pljučni arteriji in termodilucijski minutni iztis srca.

Za merjenje minutnega iztisa srca se uporablja Swan-Ganzov kateter z merilno metodo termodilucije. Zagozditveni tlak je mogoče meriti v pljučni arteriji z napihovanjem balona. Vstop v srčno mišico je skozi desno jugularno veno. Minutni iztis srca (CO) se prikazuje na emulacijskem monitorju in se spreminja v skladu z fiziologijo kardiovaskularnega sistema. Vstavljanje Swan Ganzovega katetra je simulirano z ustreznimi oblikami sprememb tlakov. Kardiovaskularni odziv je na IV zdravila in inhalacijske anestetike in je odvisen od odmerka in zdravila brez potreb intervencije inštruktorja.

Simulator ima scenarije posameznih kliničnih zapletov zgrajenih po navodilih evropskega združenja intenzivne medicine ESICM - The European Society of Intensive Care Medicine, kjer je modelirano več scenarijev v paketu PACT (Patient-centered Acute Care Training).

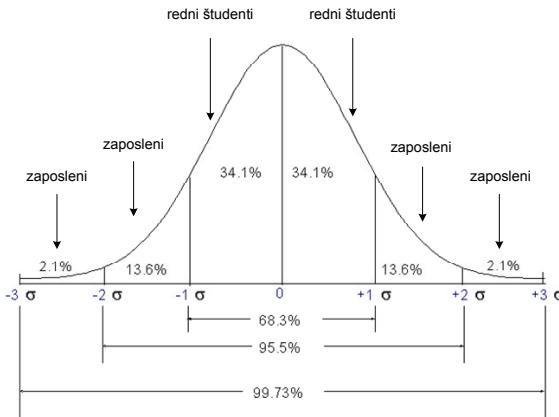
### Rutinski in krizni scenariji

Redni študenti večinoma nimajo nobenih večjih delovnih izkušenj v kliničnem okolju. Med študijem se srečujejo z ogromno količino informacij, povezanih z zdravili, s posegi, terapijami in z različnimi diagnostičnimi postopki. Množica informacij je tako velika, da je njihovo znanje slabo v trenutku, ko začnejo delati v kliničnem okolju. Uporaba zdravil in srečevanje z določenimi patološkimi stanji bolnika lahko razdelimo po gaussovi normalni porazdelitvi. Centralna lekarna nam na primer da podatke o porabi zdravil, medtem ko nam bolnišnični informacijski sistemi ponujajo informacije o količini diagnostičnih in terapevtskih postopkov.

Ideja je, da rednim študentom v zadnjih letnikih izobraževanja ponudimo simulacije postopkov, ki jih bodo zelo pogosto srečevali. Na sliki 2.15 smo predstavili to zamisel, po kateri bi redne študente učili stvari, ki spadajo znotraj enkratnega standardnega odstopanja.

Formalnega učenja kriznih situacij je malo. Izkušeno zdravstveno osebje nemalokrat presenetijo dogodki, ki niso specifični. Kako se ti dogodki končajo, je težko govoriti, saj pri nas ni vzpostavljena podatkovna baza neželenih škodljivih dogodkov. S simulacijami kriznih situacij pripravimo zaposleno osebje za take primere. Redni študentje bi s takimi simulacijami dobili preveč balasta in bi izgubili rdečo nit, potrebno za reševanje vsakdanjih postopkov v obravnavi bolnika.

Ideja gradnje scenarijev je predstavljena z zelo poenostavljenim modelom iz klasične statistike, kjer zaposlenemu osebju ponujamo simulacije postopkov, ki padajo v bočne

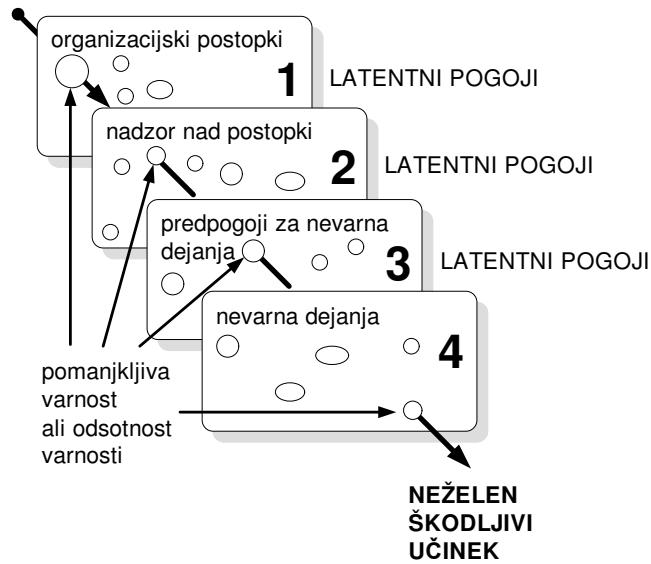


Slika 2.15: Ideja izdelave scenarijev za redne študente in že zaposleno zdravstveno osebje.

pasove gaussove krivulje z dvakratnim do trikratnim standardnim odstopanjem. Poudariti je treba, da je koncept z gaussovo krivuljo samo zelo groba idejna zasnova, ki pa se je pri generirjanju scenarijev moramo lotiti na drug način. Scenariji so namreč sestavljeni tako, da simulator prehaja iz enega stanja v drugo stanje, ki se navezuje na prejšnje stanje, zato moramo upoštevati pogojne verjetnosti.

Neželeni škodljivi učinki so dogodki, ki lahko privedejo do smrti bolnika, invalidnosti ali podaljšanja bolnišničnega zdravljenja. Nastanek neželenega škodljivega učinka nam prikazuje slika 2.15. Na sliki je Reasonov model nastanka neželenega škodljivega učinka, kjer so varovalna področja, ki varujejo pred nevarnostjo označena z lupinami. Vsaka lupina ima pomanjkljivosti prikazane z luknjami. Neželen dogodek se zgodi, ko se luknje tako poravnajo, da nastane trajektorija, ki privede do nevarnosti. Krizne simulacije nam pomagajo simulirati takšne razmere.

Krizno zasnovane simulacije zahtevajo ustrezne in predvsem pravočasne oziroma hitre odločitve. Pri načrtovanju kriznih simulacij upoštevamo, da se udeleženci odzivajo predvsem na spremenljivke, ki jih izmerijo klinični monitorji [35]. Klinični monitorji imajo vgrajene alarme, ki opozarjajo osebje na nevarnosti. Na sliki 2.17 je prikazana geneza alarmca, ki nastane na kliničnem monitorju. Spremembe v bolnikovem stanju lahko vodijo v kritična stanja, ki ogrožajo življenje. Kljub temu da homeostaza skrbi s fiziološkimi procesi za vzdrževanje stanja organizma v ustreznih okvirovih, so pri kritično bolnem bolniku ti mehanizmi okvarjeni. Škodljivi dogodek (1) se začne, ko določene fiziološke spremenljivke odstopajo od kritičnih vrednosti. Tedaj se sproži alarm na kliničnem monitorju, ki nas opozarja, da nekaj ni v redu. Zdravstveni delavec mora identificirati alarm čim prej. Na



Slika 2.16: Ideja uporabe Reasonovega modela za gradnjo scenarijev v kriznih simulacijah.

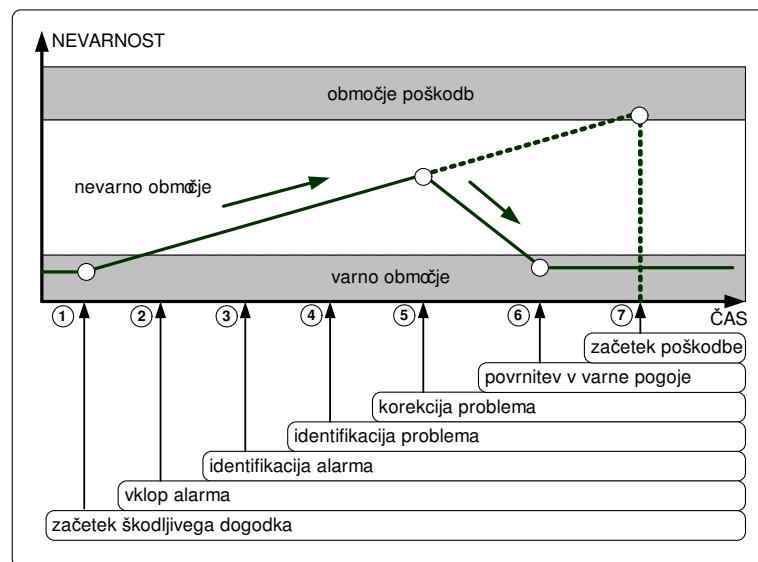
sliki je ta čas označen časovno z intervalom med (2) in (3). Ni dovolj, da alarm identificiramo, ampak ga moramo razumeti kot problem, zaradi katerega se je alarm sprožil. Ta faza je na sliki označena z oznako (4). Problem se mora nato korigirati oziroma odpraviti, kar je označeno s simbolom (5). Če smo problem uspešno odpravili, se škodljivi dogodek povrne iz nevarnega območja v varno(6). Če se problem ne odpravi, prihajamo v območje poškodb: (7). Intervale v tem nastanku alarma lahko modeliramo z ustrezno sestavljenim scenarijem za krizne razmere.

## 2.4 Simulator bolnika Laerdal SimMan

### 2.4.1 Sistemske lastnosti

SimMan je simulator, ki omogoča urjenje za različna področja, vendar je v osnovi namenjen simulacijam v domeni anestezije. Simulirajo se zapleti v kardiovaskularnem sistemu, respiratornem sistemu in zapleti z dihalnimi potmi. Vzpostavitev in zaščita dihalnih poti sta predstavljeni z naslednjimi sistemskimi lastnostmi:

- predihavanje z dihalnim balonom,



Slika 2.17: Ideja uporabe geneze alarmra za gradnjo scenarijev v kriznih simulacijah.

- uporaba ustno žrelnega in nosno žrelnega tubusa,
- vstavljanje kombitubusa,
- vstavljanje laringealne maske,
- vstavljanje i-gela,
- trahealna intubacija,
- retrogradna intubacija,
- intubacija z endoskopom,
- igelna konikotomija,
- kirurška konikotomija,
- trans trahealna ventilacija,
- bronhoskopija,
- CO<sub>2</sub> v izdihanem zraku,
- spontano dihanje in spremenljiva frekvenca dihanja,

- trizmus, edem jezika, faringealna obstrukcija in laringospazem,
- zmanjšana gibljivost vratnih vretenc,
- zmanjšana upornost dihanja,
- pnevmotoraks,
- dekompresija želodca,
- torakalna drenaža.

Simulator ima na desni roki možnost vstavljanja intravenskih kanil. Ima mesta za subkutano in intramuskularno aplikacijo zdravil. Pulzi se tipajo na levi roki (radialno in brahialno). Bilateralni pulzi so na femoralni in karotidni arteriji. Pulzi so sinhronizirani z EKG signalom, njihova jakost je odvisna od vrednosti sistolnega tlaka. Pri padanju tlaka najprej izginejo na radialni arteriji, nato na brahialni, sledi femoralna in nazadnje pulz izgine na arteriji karotis. Kardiovaskularni sistem je sestavljen:

- EKG knjižnica z 200 različnih srčnih ritmov,
- EKG artifakti med masažo srca,
- defibrilacija,
- električna kardiverzija,
- zunanjega elektrostimulacije.

Pri kardiopulmonalnem oživljanju imamo možnost preverjanja po protokolu ABC, simulator lahko ventiliramo in masiramo prsni koš. Krvni tlak se izmeri avtomatsko na simuliranem monitorju ali z realnim merilcem tlaka Riva Rocci, kjer je avskultacija sinhronizirana z EKG signalom oziroma s pulzom. Sistolični in diastolični tlak se nastavita posamezno. Avskultacija je mogoča na srcu, pljučih in črevesju.

#### 2.4.2 Opis komponent

Glavne komponente simulatorja SimMan so naslednje:

- lutka,

- kompresor,
- nadzorni računalnik,
- krmilna elektronika: Link Box,
- emulator kliničnega monitorja.

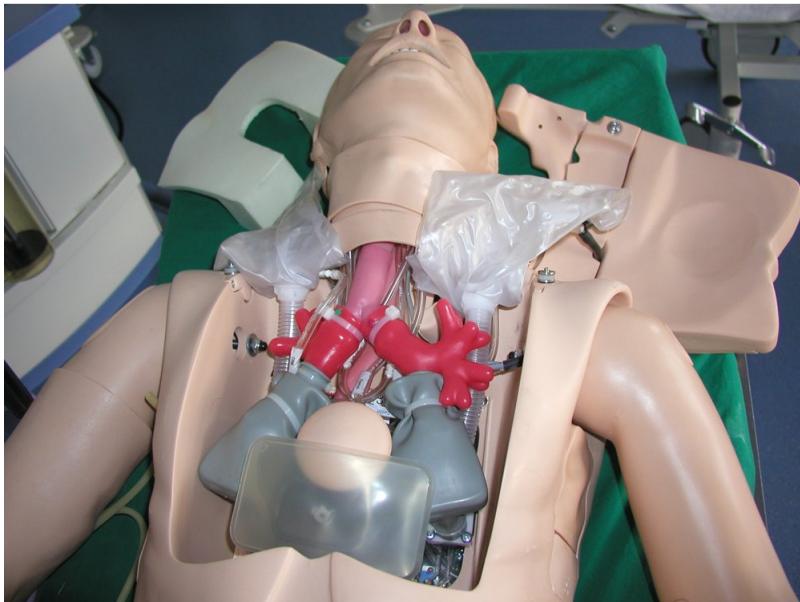
Komponente so med seboj povezane električno in pnevmatsko preko cevi. Nadzorni računalnik je povezan na komponento, imenovano Link Box, kjer je glavni krmilnik. Iz Link Boxa vodijo povezave do lutke: cevka za merjenje krvnega tlaka, pulzni oksimeter in podatkovno vodilo, preko katerega se izvajajo funkcije. Link Box komponenta napaja lutko, skrbi za daljinsko komunikacijo z dvema daljinskima upravljalcema. Komponenta predstavlja avdio vhod, tako da lutka na zvočniku omogoča verbalno komunikacijo. Link Box oddaja QRS ton in v njem so generatorji EKG signalov. Nanj je priključen emulator kliničnega monitorja, ki prikazuje simulirane vitalne funkcije. Link Box generira pulze in detektira defibrilacijo oziroma vrednost električnega toka zunanje elektrostimulacije. Generirajo se vsi toni za avskultacijo.

Kompresor služi za pogon meha spontanega dihanja, za pnevmatski pulz arterije karotis in zaplete dihalnih poti (trizmus, zmanjšana gibljivost vratnih vretenc, faringealna obstrukcija, edem jezika). Preko kompresorja se dodaja tudi komprimiran ogljikov dioksid, ki simulira izdihani zrak med ekspirijem.

Na sliki 2.18 so prikazane komponente v notranjosti toraksa. Bronhialno drevo ima realno strukturo. Če se trahealni tubus vstavi pregloboko, konča v desnem bronhu. Poseben meh simulira dvigovanje prsnega koša

V delu abdomna so elektromagnetni ventili, ki krmilijo naslednje sisteme:

- spontano dihanje,
- CO<sub>2</sub> v izdihanem zraku,
- podajnost desnega pljučnega krila,
- podajnost levega pljučnega krila,
- pnevmotoraks,
- laringospazem,



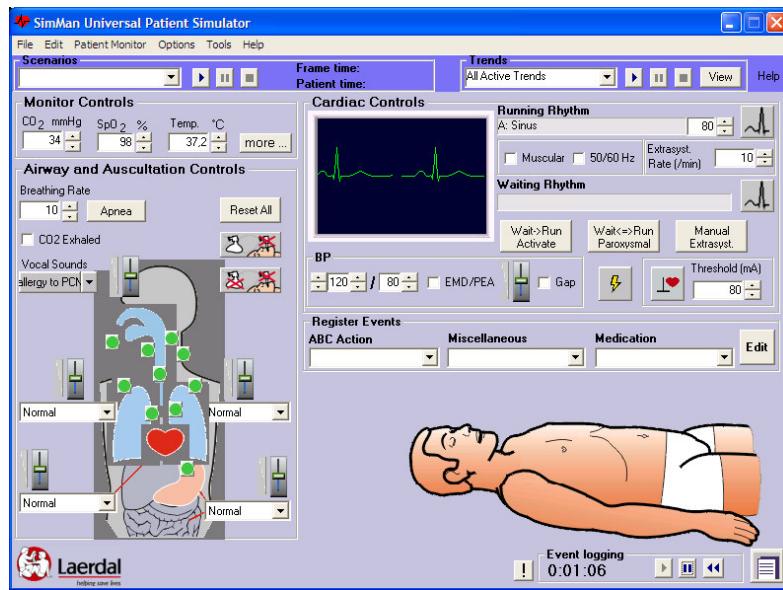
Slika 2.18: Komponente v prsnem delu simulatorja.

- faringealna obstrukcija,
- edem jezika,
- trizmus,
- zmanjšana gibljivost vratnih vretenc,
- dekompresija želodca,
- pulz na karotidi.

#### 2.4.3 Programski paket

Simulator SimMan nadziramo preko osnovnega okna grafičnega vmesnika, prikazanega na sliki 2.18. Med potekom programiranega scenarija lahko na tem vmesniku vse funkcije ročno nastavljam. Nastavlja se funkcije, povezane z dihanjem, EKG signali, avskultacijski zvoki in ostali parametri, ki so že bili opisani v predhodnih poglavjih. Programske funkcije omogočajo ogromno različnih možnosti upravljanja, mi pa se bomo v nadaljevanju omejili samo na tiste funkcije, ki so povezane z izdelavo scenarija.

Na sliki 2.19 je prikazan del uporabniškega grafičnega vmesnika, na katerem kontroliramo dihalne funkcije. Na levi zgornji strani se nastavi frekvenca dihanja (Breathing



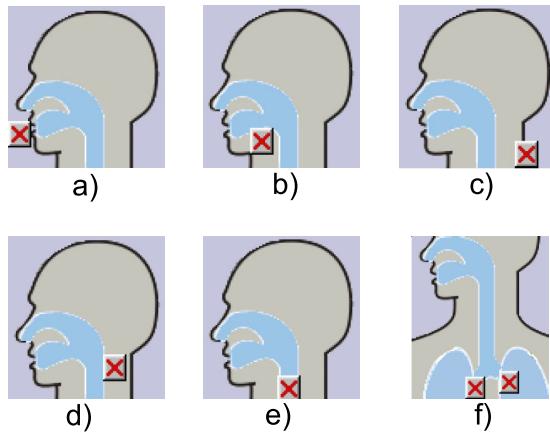
Slika 2.19: Grafični vmesnik simulatorja bolnika SimMan.

Rate), mogoče pa je z enkratnim klikom na gumb nastaviti odsotnost spontanega dihanja (Apnea). Če želimo, da simulator pri spontanem dihanju izdihuje CO<sub>2</sub>, odkljukamo polje »CO<sub>2</sub> Exhaled«.

Na tem delu uporabniškega vmesnika nastavljamo vse funkcije, povezane z avskultacijo. Nastavljajo se šumi na srcu, zvoki v črevesju in za vsako posamezno pljučno krilo nastavimo patološke zvoke, povezane z dihanjem. Za avskultacijo so nameščeni zvočniki na torzu simulatorja. Pri avskultaciji pljuč imamo na voljo 4 zvočnike - dva na sprednji strani pljuč in dva lateralno. Raven glasnosti avskultacijskih zvokov se nastavlja za vsako posamezno funkcijo. V tem nadzornem oknu izbiramo preprogramirane govore, ki jih »govori« simulator.

Na sliki 2.20 so prikazani zapleti pri vzdrževanju prostih dihalnih poti. Zapleti se uporabljajo pri simulacijah, kjer je potrebna intubacija bolnika.

Pod oznako a) je označena aktivna funkcija trizmusa. Simulator v tem trenutku močno stisne zobe skupaj in zmanjša se gibljivost mandibule. Ta zaplet traja najmanj 3 minute, potem se sprosti. Če želimo odpreti usta na širino 25 mm, moramo uporabiti silo 100 N. Edem na jeziku je prikazan pod b), v tem trenutku jezik tako oteče, da ni mogoče videti svetline odprtine v ezofagus. Zaplet traja tri minute in se simulira pnevmatsko preko elektromagnetnih ventilov. Pod oznako c) je simulacija zmanjšane gibljivosti vratnih cervikalnih vretenc. Vratu ni mogoče pomikati in je pomaknjen v



Slika 2.20: Simulacija zapletov dihalnih poti.

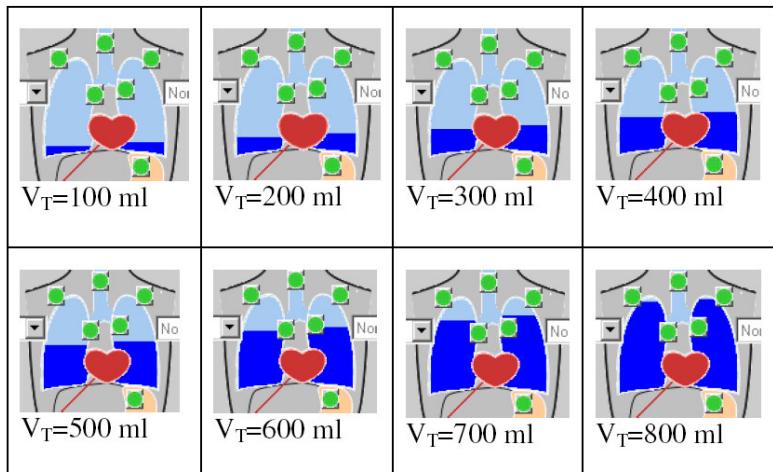
smeri naprej od nevtralne pozicije. Če želimo vrat pomakniti +/- 5 stopinj, moramo uporabiti silo najmanj 10 N. Faringealna obstrukcija je prikazana na sliki pod oznako d), kjer posteriorna faringealna površina oteče v anteriorni del žrela. Tudi ta simulacija traja kot prejšnje najmanj 3 minute in je simulirana preko elektromagnetnih ventilov. Pod oznako f) je zaplet bronhospazma, kjer se lahko zapre posamezna sapnica. Vsako pljučno krilo se nadzira posamezno.

Pljuča so glede klasifikacije, ki jo omenjajo Meurs in sodelavci [104], predstavljena kot čisti mehanski sistem. Ta sistem nima sofisticirane matematične kontrole in edino, kar lahko vidimo, je grafična oblika volumna predstavljena na sliki 2.21. Mehanični sistem pljuč ima podajnost v območju 10-50 ml/cmH<sub>2</sub>O, medtem ko je upornost v mejah 2-8 cmH<sub>2</sub>O/l/min. Med ventilacijo z dihalnim balonom se pri volumnu 300 ml prsniki dvigne za 3 mm. Dvigovanje prsnega koša je bilateralno in če imamo bronhospazem na eni strani, se drugo pljučno krilo vidno dvigne pri volumnu 200 ml.

Za kontrolo nad inspiracijskimi volumni smo zato v raziskavi [58] določili korelacijo med volumni in s prikazom na grafičnem vmesniku. Kalibracijo smo izvajali s pomočjo anestezijskega aparata Primus z vrednostmi med 100 ml in 800 ml.

Od zapletov na srcu so na voljo različne normalne in patološke spremembe elektrokardiograma. EKG ritem je v grafičnem vmesniku razdeljen na: trenutni ritem in ritem na čakanju. Trenutni ritem se izvaja in ga udeleženci tečajo vidijo na simuliranem monitorju ali realnem EKG aparatu. Čakalni ritem v trenutku pritiska gumba zamenja trenutni ritem.

Krvni tlaki se nastavljajo posamezno kot diastolni in sistolni tlak ali pa oba tlaka



Slika 2.21: Grafična predstavitev različnih dihalnih volumnov.

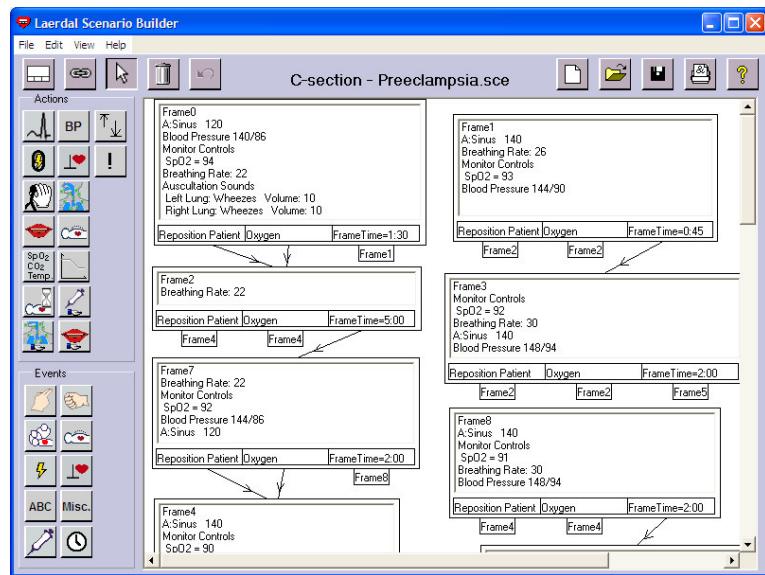
spreminjamo simultano. Pri aktivaciji elektromehanične disociacije oziroma električne aktivnosti brez pulza (EMD/PEA) je EKG signal prisoten, krvni tlaki pa padejo na ničelne vrednosti skupaj z dihanjem.

Vmesnik gradnje scenarija je prikazan na sliki 2.22. S tem grafičnim orodjem ustvarimo scenarij ali ga spremenimo. Simulatano je lahko pognan scenarij in odprt grafični vmesnik, kar je uporabno pri načrtovanju in testiranju scenarija. Scenarij je sestavljen iz okvirjev, kjer so vsebovana stanja spremenljivk (Actions). Pomik iz enega okvirja v drugi dosežemo s tem ko so izpolnjeni določeni pogoji, ki jih bomo imenovali dogodki (Events).

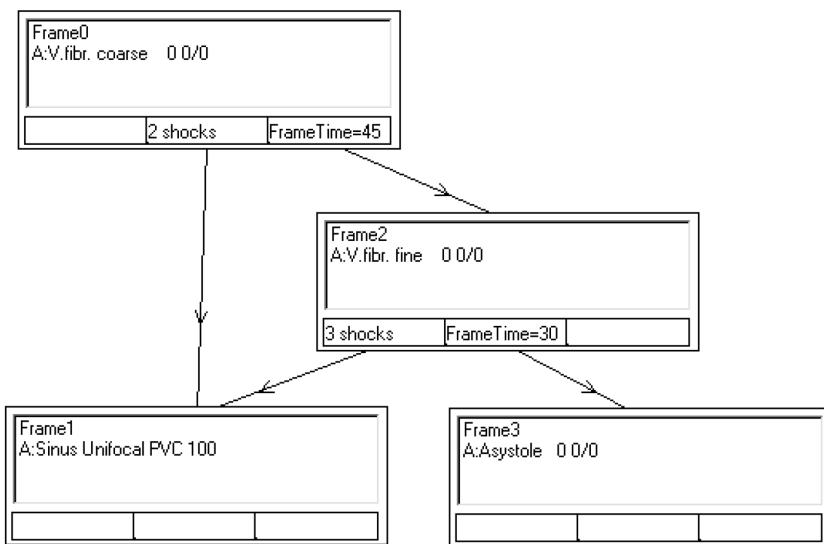
#### 2.4.4 Primer scenarija

Simulator Laerdal SimMan je simulator, kjer se scenariji izvajajo po korakih. Gradniki posameznega koraka so predstavljeni v obliki okvirjev, ki so med seboj vzročno-posledično povezani. Takšen deskriptivni način izvajanja scenarija se vedno začne z okvirjem označenim z nič (Frame 0). Iz okvirja 0 se pomaknemo v naslednji okvir, ko udeleženci izvedejo določen dogodek, ki je pogoj za prehod v naslednji element - okvir. Primer imamo prikazan na sliki 2.23.

V začetku scenarija se nahajamo v začetnem ničelnem okvirju kjer EKG signal predstavlja stanje s široko ventrikularno fibrilacijo. V spodnjem delu so dogodki, ki po-



Slika 2.22: Vmesnik gradnje scenarija.



Slika 2.23: Prikaz sekvenčnega scenarija.

maknejo simulator v naslednje stanje. Ko dvakrat izvedemo defibrilacijo (2 shocks), se scenarij pomakne iz okvirja nič (Frame 0) v okvir 1 (Frame 1), kjer EKG ritem preide v predčasno ventrikularno kontrakcijo (Unifocal PVC). Ko smo v ničelnem okvirju in če udeleženci tečaja nič ne napravijo v času 45 sekund (FrameTime=45 s), se scenarij pomakne v drugi okvir (Frame 2), kjer se stanje EKG ritma spremeni v fino ventrikularno fibrilacijo (V Fibr fine). Če niso izvedene tri defibrilacije, potem po času 30 sekund preidemo v okvir 3 (Frame 3), kjer se EKG zopet spremeni v asistolijo (Asistole). Pri treh defibrilacijah pa preidemo v že omenjeni okvir 1.

Spremenljivke, ki nastopajo v scenarijih, so zvezne in diskretne. V nadaljevanju jih bomo podrobnejše opisali. V tabeli 2.1 so spremenljivke iz EKG domene. V osnovi imamo različne EKG ritme, na katere lahko vplivajo motnje iz napetostne mreže (230 V) ali pa mišični artifakti motijo simulirani EKG signal. Pri elektromehanični disociaciji (EMD/PEA) je EKG signal prisoten, ni pa prisotnih pulzov ne tlaka.

<b>Ime spremenljivke (domena EKG)</b>	<b>Tip</b>	<b>Vrednosti spremenljivke</b>
EKG artifakt	nominalna	Brez, Mišični, Mreža
QRS kompleks	nominalna	A, B, C, D, E, F, G
EKG ritem	nominalna	Sinus, A.tach, A.flutt, A.fib, V.tach, Torsades des pointes, V.fib very coarse, V.fib coarse, V.fib standard, V.fib fine, V.fib very fine, Junct, Idiov, Asystole, Agonal, V.standstill, AVB first degree, AVB second degree, AVB third degree, Pacemaker
EMD/PEA	nominalna	No change, No EMD/PEA, EMD/PEA
Extrasystole Rate	kategorična	No change, 2, 5, 10, 15, 20, 30, bigem
Extrasystole	nominalna	Unifocal PVC, PVC RonT, Coupled PVC, Multifocal PVC, PAC, PJC
Delay	numerična	Delay before activation (min:sec)
Heart Rate (HR)	numerična	Range HR=10-200 step=2

Tabela 2.1: Spremenljivke iz domene EKG.

V tabeli 2.2 so spremenljivke, ki predstavljajo zvoke na srcu, pljučih in črevesju. Zvoki na pljučih se nastavljajo za vsako posamezno pljučno krilo posebej. Vse naštete zvoke lahko s stetoskopom poslušamo na torzu simulatorja.

Ime spremenljivke (domena Avskultacija)	Tip	Vrednosti spremenljivke
Srce	nominalna	No change, Normal, Aortic stenosis, Austin Flint murmur, Friction Rub, Mitral Valve Prolapse, Diastolic Murmur, Systolic Murmur, OS70 (Opening snap of Mitral Stenosis),
Pljuča	nominalna	No change, Normal, Crackles, Gurgling Rhonchi, Plural Rub Pneumonia, Rhonchi, Stridor, Wheezes
Črevo	nominalna	Normal, Normal Bowel 20 Year old, Normal Bowel 60 Year old, Chron Disease, Diarrhea, Hypereactive, Hypoactive, Hypereactive Bowel 16 Year Old, Hypoactive Bowel Codeine, Hypoactive Bowel Postop, Hypoactive Bowel Preop, Irritable Bowel Syndrome, Ulcerative Colitis, Borborygmus

Tabela 2.2: Spremenljivke iz domene avskultacije.

Spremenljivke, ki nastopajo v domeni krvnega tlaka, so prikazane v tabeli 2.3. Tako sistolični kot diastolični tlak sta numerični spremenljivki, medtem ko je avskultacijska reža kategorična spremenljivka.

<b>Ime spremenljivke (domena Krvni tlak)</b>	<b>Tip</b>	<b>Vrednosti spremenljivke</b>
Sistolični	numerična	Range Sys=90-300 step=2
Diastolični	numerična	Range Dia=0-110 step=2
Korotkof volume	numerična	Range Korotkof=0-10 step=1
Auscultation Gap	kategorična	No Change, No Gap, Gap

Tabela 2.3: Spremenljivke iz domene krvnega tlaka.

V tabeli 2.4 so predstavljene spremenljivke, ki nastopajo v domeni defibrilacije ali elektrostimulacije. Števec, ki resetira štetje defibrilitorskih sunkov je označen kot: Clear Shock Count. Pri elektrostimulaciji (Pacing) nastavljamо prag med 20 in 200 mA kot vrednost učinkovitega električnega toka.

<b>Ime spremenljivke (domena Defibrilacija)</b>	<b>Tip</b>	<b>Vrednosti spremenljivke</b>
Clear Shock Count	kategorična	Reset
Pacing	kategorična	Enable, Ignored
Threshold	numerična	Range Current=20-200 mA, step=20
Auscultation Gap	kategorična	No Change, No Gap, Gap

Tabela 2.4: Spremenljivke iz domene defibrilacije.

V tabeli 2.5 so trendi spremenjanja spremenljivk kliničnega monitorja. Maksimalne in minimalne vrednosti nastavljamо z namenom omejiti scenarij z najnižjimi in najvišjimi vrednostmi, saj začetna vrednost v scenariju ni vedno znana.

<b>Ime spremenljivke (domena Trend)</b>	<b>Tip</b>	<b>Vrednosti spremenljivke</b>
$S_pO_2$	numerična	Min=0, Max=10 step=1
$CO_2$	numerična	Min=0.0, Max=150.0 step=1
Temp	numerična	Min=20.0, Max=45.0 step=0.2
BP Sys	numerična	Min=0, Max=300 step=1
BP Dia	numerična	Min=0, Max=300 step=1
HR	numerična	Min=0, Max=300 step=1
BR	numerična	Min=0, Max=40 step=1
CO	numerična	Min=0.0, Max=12.0 step=0.1
CVP	numerična	Min=0.0, Max=20.0 step=0.1

Tabela 2.5: Spremenljivke kliničnega monitorja vitalnih funkcij.

Spremenljivke dihalnih poti (Airway) so zapisane v naslednji tabeli 2.6. Večina teh spremenljivk je kategoričnih dihotomih spremenljivk, ki predstavljajo aktivno ali neaktivno stanje določenih zapletov, kot so trizmus, edem jezika, faringealna obstrukcija in podobno.

<b>Ime spremenljivke (domena Airway)</b>	<b>Tip</b>	<b>Vrednosti spremenljivke</b>
Trizmus	kategorična	Yes, No
Tongue Edema	kategorična	Yes, No
Pharingeal obstruction	kategorična	Yes, No
Decreased range of motion	kategorična	Yes, No
Laringo Spasm	kategorična	Yes, No
Right Pneumothorax	kategorična	Yes, No
Left Pneumothorax	kategorična	Yes, No
Right decreased lung compliance	kategorična	Yes, No
Left decreased lung compliance	kategorična	Yes, No
Breathing Rate	numerična	Range BR=0-40 step=2
Vocal sound	kategorična	Start.Sound, Stop.Sound, Sound.1, Sound.2,...
Sound interval	numerična	Range Sound=0-999 sec step=1
Sound number	numerična	Range Number=0-20

Tabela 2.6: Spremenljivke iz domene dihalnih poti.

V predhodnih tabelah smo predstavili vse spremenljivke, ki jih vsebuje simulator SimMan. Vsi ti koraki nastopajo v scenariju, vendar ni nujno, da naenkrat. Paziti moramo na začetne prednastavljenе vrednosti v scenariju.

Študije kažejo, da se bodo študenti v izobraževalnem procesu, podprtih z najsodobnejšo tehnologijo, bolje usposobili za prakso in delo v okolju modernega zdravstvenega varstva [24, 101]. S simulacijami študenti vadijo in preizkušajo različne scenarije, ne da bi pri tem škodovali bolnikom. S tem da sprejemajo tveganja in odločitve, študenti razvijajo sposobnost kritičnega mišljenja, ki ga bodo potrebovali kasneje pri opravljanju poklica. Poleg tega pa bodo študenti, ki prakticirajo postopke na računalniku, samozavestnejši, ko se bodo znašli pred resničnim bolnikom. Učenje, ki temelji na izkušnjah, pridobljenih

iz simulacij, omogoča učenje v globino, kar je v današnjem času izrednega pomena. Simulacijski pristop je štartna točka za poglobljeno razumevanje fizioloških procesov, ki potekajo v človeškem telesu. Simulacije tako zapolnijo podrobnosti ter vrzeli in ponudijo celovito sliko v razumevanju delovanja človeškega organizma. Potrdijo in razširijo začetna oziroma osnovna razumevanja, pridobljena s klasičnim učnim pristopom, hkrati pa kvantizirajo mnoge alternative. Študent lahko namreč sam raziskuje, kako spreminjanje veličin vpliva na odgovore človeškega telesa.

Za izdelavo scenarijev je potrebno osnovno znanje o delovanju simulatorjev in o simulacijskem okolju, ki smo ga predstavili. Modelska zasnovan simulator, kot je METI HPS, ima vse modele že vgrajene v programske opreme. Simulator Laerdal SimMan, za katerega bomo razvijali metodologijo gradnje scenarijev, pa ima sekvenčno zasnovano delovanje. Metoda gradnje scenarijev tako predstavlja zelo kompleksen postopek. Za redne študente smo imeli v mislih rutinske scenarije, za izredne študente oziroma že zaposleno zdravstveno osebje pa so primerni krizni scenariji.



## Poglavlje 3

# Teorija verjetnostnih mrež in verjetnostni račun

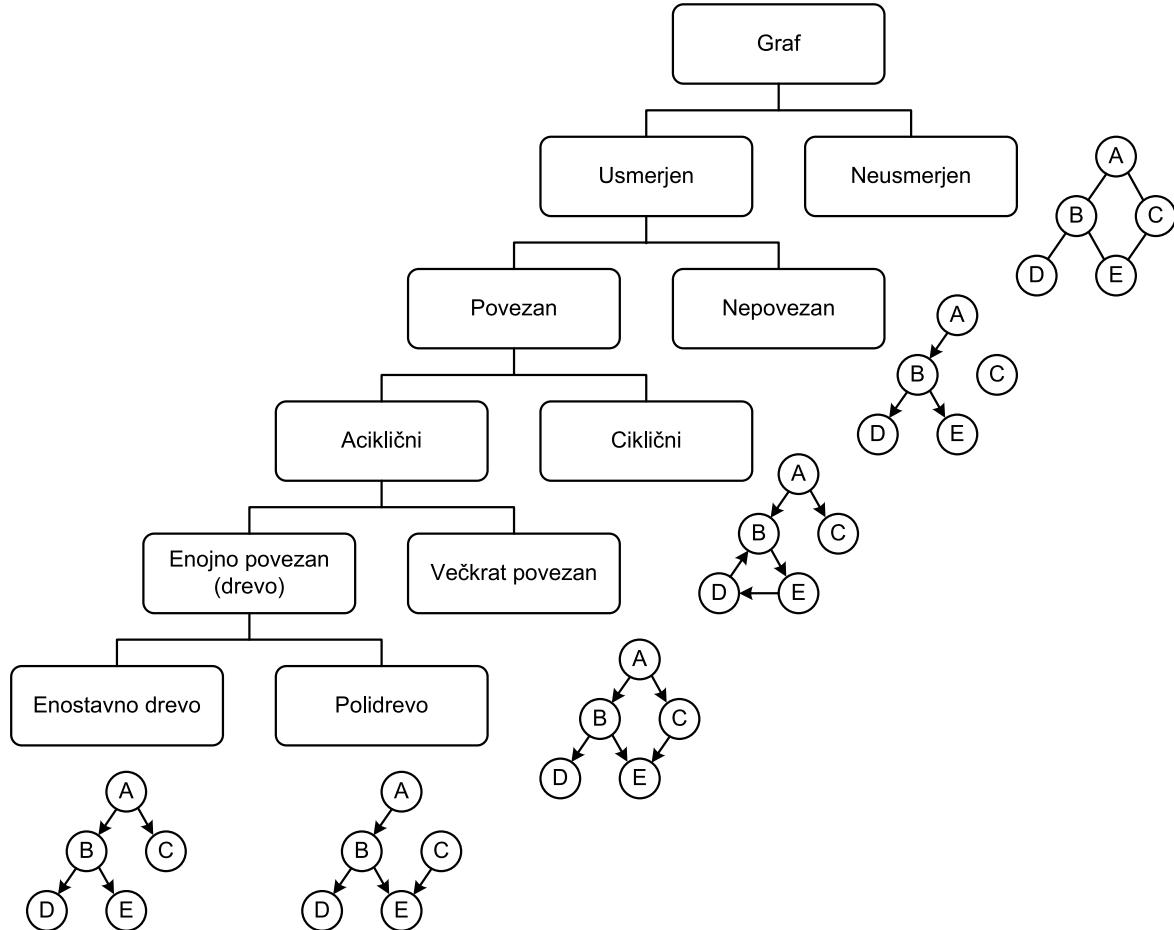
Tematika Bayesovih verjetnostnih mrež je v slovenskem prostoru slabo zastopana v učbenikih. Še največ je najdemo v učbeniku profesorja Kononenka (Strojno učenje) in nekaj v učbeniku profesorja Nikole Guida (Umetna inteligenco). Zaradi tega smo se odločili nekoliko razširiti teoretična izhodišča, ki smo jih opisali v tem tretjem in v naslednjem četrtem poglavju. Vsebine so povzete po dveh tujih učbenikih [49, 48] in so namenjene bralcem, ki se bodo ukvarjali z Bayesovimi mrežami v svojem delu.

### 3.1 Verjetnostne mreže

Verjetnostne mreže so grafični modeli (vzročnih) interakcij med množico spremenljivk, kjer so spremenljivke predstavljene v obliki vozlišč grafa, interakcije med njimi pa kot povezave med vozlišči. Odvisnosti med posameznimi spremenljivkami označujejo usmerjene povezave. Tako na primer kateri koli par nepovezanih/nesosedskih spremenljivk v grafu indicira (pogojno) neodvisnost med temi spremenljivkama, predstavljenima z vozlišči v določenih okoliščinah, ki jih lahko preberemo iz grafa. Verjetnostne mreže torej zajemajo množico (pogojnih) odvisnosti in neodvisnosti, ki se nanašajo na spremenljivke, predstavljene v vozliščih [49].

Grafi so se izkazali kot zelo intuitiven način predstavitve odvisnih in neodvisnih izjav in tako predstavljajo odličen model za komunikacijo in diskusijo o odvisnih in neodvisnih relacijah med problemskimi spremenljivkami v določeni domeni. Velik in zelo pomemben

### 64POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN

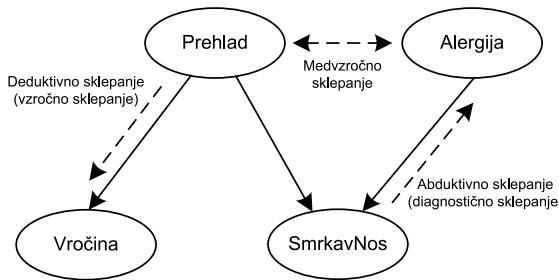


Slika 3.1: Različni razredi grafov.

razred predpostavk o odvisnih in neodvisnih relacijah, izraženih v faktorizirani predstaviti porazdelitev verjetnosti produkta se lahko predstavi v strnjrenom in učinkovitem razredu grafov, definiranih kot aciklični usmerjeni grafi (acyclic directed graphs - DAG). Shema 3.1 prikazuje različne razrede grafov in njihovo taksonomijo [49].

Verižni grafi so generalizacija DAG grafov, ki je sposobna predstavitev širšega razreda odvisnih in neodvisnih predpostavk [57, 68]. Ta dodatna izrazna moč signifikantno povečuje semantično kompleksnost, pri kateri so specifikacije faktorjev produkta verjetnosti mnogo manj intuitivne. Kljub njihovi izraziti moči so prav zaradi slednjega pridobili zelo malo pozornosti kot praktični modeli za sisteme za podporo odločanja [49].

Verjetnostne mreže lahko razložimo kot predstavitev "mehkih" vzročno-posledičnih pravil, ki so v nasprotju s standardnimi sistemmi, osnovanimi na pravilih. Verjetnostne mreže so sposobne deduktivnega in abduktivnega sklepanja, kot tudi medvzročnega (*in-*



Slika 3.2: Vzročna mreža ne podpira samo vzročnega in diagnostičnega sklepanja temveč tudi medvzročno sklepanje (eliminiranje hipoteze)

*tercausal*) sklepanja. Deduktivno sklepanje (včasih obravnavano kot *vzročno sklepanje*) sledi usmerjenosti med vzročnimi povezavami spremenljivk modela; na primer ob vednosti, da je oseba prehlajena, lahko (z veliko verjetnostjo) sklepamo, da ima vročino in smrkav nos (glej shemo 3.2). Abduktivno sklepanje (včasih obravnavano kot *diagnostično sklepanje*) sledi v nasprotnem redu vzročnih povezav; na primer opažanje, da ima oseba smrkav nos, predstavlja podporno gotovost za ali prehlad ali alergijo, kjer obe možnosti predstavlja pravilno diagnozo.

Lastnost v verjetnostnih mrežah, ki omogoča inferenco in se razlikuje od drugih paradigem verjetnostnega sklepanja, je *medvzročno* (intercausal) sklepanje: Pridobitev dane gotovosti (evidence), ki podpira izključno eno hipotezo (ali podmnožico hipotez), namreč avtomatsko vodi v zmanjšanje gotovosti nepodprtih konkurenčnih hipotez. Ta lastnost se pogosto navaja kot efekt eliminiranja razlage (*explaining away effect*). Na primer na shemi 3.2 obstajata dva konkurenčna vzroka smrkavega nosu (alergija in prehlad). Z opazovanjem vročine kot močne gotovosti vzroka za prehlad se naše zupanje v vzrok kot alergijo postopoma manjša (razlaga je eliminirana z opazovanjem vročine). Zmožnost verjetnostnih mrež, da avtomatsko izvajajo takšna medvzročna sklepanja, predstavlja ključni doprinos za njihovo sklepanje [49].

Pogosto grafični vidik verjetnostnih mrež navajamo kot *kvalitativni* vidik, njihov numerični - verjetnostni del pa kot *kvantitativni*. V teoretičnem delu doktorske naloge nadaljujemo z opisom teorije modela, ki ga uporabljamo v razviti metodologiji. Najprej se posvečamo razlagi kvalitativnega vidika verjetnostnih mrež, ki izhaja in razreda grafov DAG. V teh grafih predstavljajo vozlišča naključne spremenljivke, odločitvene spremenljivke ali funkcije koristi. Usmerjene povezave med vozlišči predstavljajo neposredne odvisnosti, informacijske ovire ali domene funkcij koristi. Nato v naslednjem poglavju opišemo kvantitativni vidik, ki izhaja iz verjetnostne teorije, nakar oboje združimo v ra-

zlagi modela Bayesovih mrež in diagramov vpliva. Problem in teoretično ozadje sklenemo z nekaj primeri uporabe Bayesovih mrež v domeni medicine.

### 3.1.1 Grafi in grafični modeli

V nadaljevanju podajamo matematične formulacije grafov, povzetih po [49]. Graf je definiran kot par  $G = (V, E)$ , kjer je množica  $V$  končna množica ločenih vozlišč in  $E \subseteq V \times V$  množica povezav grafa. Urejen par  $(u, v) \in E$  predstavlja usmerjeno povezavo od vozlišča  $u$  do vozlišča  $v$ , pri čemer obravnavamo  $u$  kot *starša (parent)* vozlišča  $v$  in  $v$  kot *otroka (child)* vozlišča  $u$ . Množici staršev in posameznega s  $pa(v)$  in  $ch(v)$ .

Pogosto uporabljamo intuitiven zapis  $u \rightarrow v$  za  $(u, v) \in E$  (ali le  $u \rightarrow v$ , če je  $G$  samoumeven). Če  $(u, v) \in E$  in  $(v, u) \in E$ , potem je povezava med  $u$  in  $v$  *neusmerjena* povezava, kar označimo z  $u - v$  ( $u - v$ ). Za katero koli povezavo  $u \rightarrow v$  ali  $v \leftarrow u$  ali  $v - u$  se uporablja zapis  $u \sim v$ , kar z drugimi besedami pomeni, da sta  $u$  in  $v$  povezani v grafu  $G$ .

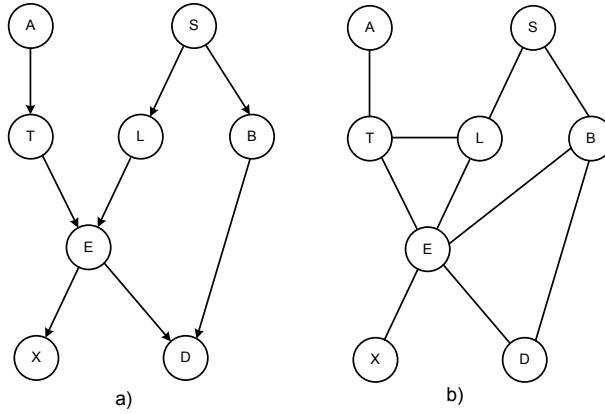
Če  $E$  ne vsebuje neusmerjenih povezav, potem je  $G$  *usmerjen graf*, če velja obratno govorimo o *neusmerjenem grafu*. Kot smo že omenili, za verjetnostne mreže niso potrebni mešani grafi, zato se v tem delu ne bomo ukvarjali z njimi.

Pot  $\langle v_1, v_2, \dots, v_n \rangle$  je zaporedje ločenih vozlišč, tako velja  $v_i \sim v_{i+1}$  za vsak  $i = 1, \dots, n-1$ ; *dolžina poti* je definirana kot  $n-1$ . Pot je usmerjena, če velja  $v \rightarrow v_{i+1}$  za vsak  $i = 1, \dots, n-1$ ;  $v_i$ , poimenovan kot predhodnik  $v_j$ , in  $v_j$  naslednik  $v_j$  za  $j > i$ . Množica predhodnikov (*ancestors*) in naslednikov (*descendants*)  $v$  označimo kot  $an(v)$  in  $de(v)$ . Množica  $nd(v) = V \setminus de(u) \cup v$  se imenuje množica nenaslednikov  $v$ . Predhodna množica (*ancestral set*)  $An(U) \subseteq V$  množice  $U \subseteq V$  grafa  $G \in (V, E)$  je množica vozlišč  $U \cup \bigcup_{u \in U} an(u)$ .

Pot  $\langle v_1, v_2, \dots, v_n \rangle$  od  $v_1$  do  $v_n$  v neusmerjenem grafu  $G = (V, E)$  je *blokirana (blocked)* z množico  $S \subseteq V$ , če  $v_1, \dots, v_{n-1} \cap S \neq \emptyset$ . Podoben, vendar nekoliko zapleten koncept, velja za poti v DAG, ki ga bomo obravnavali kasneje.

Graf  $G = (V, E)$  je *povezan*, če za kateri koli par  $u, v \subseteq V$  obstaja pot  $\langle u, \dots, v \rangle$  v  $G$ . Povezan graf  $G = (V, E)$  je *polidrevo (polytree)*, če za kateri koli par  $u, v \subseteq V$  obstaja unikatna pot  $\langle u, \dots, v \rangle$  v  $G$ .

Cikel je pot  $\langle u, \dots, v \rangle$ , ki ima dolžino, večjo od 2, z izjemo  $v_1 = v_n$ ; usmerjen cikel jasno izhaja iz definicije. Usmerjeni graf brez ciklov se imenuje aciklični usmerjeni graf ali



Slika 3.3: (a) Aciklični usmerjeni graf  $DAG$ , (b) moralizirani graf.

$DAG$ , kot smo že navedli. Neusmerjeni graf  $G$ , ki nastane z zamenjavo vseh usmerjenih vozlišč z neusmerjenimi, se imenuje *skeleton* grafa  $G$ .

Naj bo  $G = (V, E)$   $DAG$ . Neusmerjeni graf  $G^m = (V, E^m)$ , kjer je  $E^M = \{(u, v) \mid u$  in  $v$  sta povezani ali imata skupnega otroka v  $G\}$ , se imenuje *moral* graf grafa  $G$ .

$G^m$  grafa  $G$  dobimo tako, da najprej dodamo neusmerjene povezave med pare nepovezanih vozlišč, ki si delijo skupnega otroka in potem zamenjamo vse usmerjene povezave z neusmerjenimi povezavami (glej shemo 3.3).

### Grafični modeli

Na strukturni ali kvalitativni ravni so modeli verjetnostnih mrež grafi, katerih vozlišča predstavljajo spremenljivke in uporabne funkcije, povezave med njimi pa različne vrste relacij med njimi.

### Spremenljivke

Spremenljivka predstavlja množico nezdružljivih dogodkov (medsebojno izključujočih), ki se nanašajo na *domeno* spremenljivke. Domene spremenljivk bodo v doktorskem delu različna področja v okviru simulacijskih scenarijev, kot na primer elektrokardiogram, avskultacija in monitoring. Dogodek pogosto poimenujemo kot stanja, vrednosti, izbire, opcije itn. Domena spremenljivke je lahko diskretna ali zvezna, pri čemer je zaloga vrednosti v diskretnih primerih vedno zvezna [49].

## 68POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN

**Primer:** Naslednji seznam sestavljajo primeri domene spremenljivk:

- $\{F, T\}$
- $krvnaskupinaA, krvnaskupinaB, krvnaskupinaAB$
- $2, 4, 6, 8, 10$
- $-6.5, 0, 6.1, 12.6$
- $< 0, 0 - 10, > 10$
- $-\infty, \infty$

kjer  $F$  in  $T$  predstavljata "false" in "true".

V raziskovalnem delu bomo uporabljali velike črke za poimenovanje spremenljivk in množic spremenljivk in male črke za določitev določene vrednosti spremenljivke. Tako  $X = x$  lahko predstavlja dejstvo, da spremenljivka  $X$  vsebuje vrednost  $x$  ali dejstvo, da množica spremenljivk  $X = (X_1, \dots, X_n)$  vsebuje vektor vrednosti  $x = (x_1, \dots, x_n)$ . Z  $dom(X)$  bomo označevali domeno od  $X$ , kjer  $\|X\| = |dom(X)|$  predstavlja število možnih različnih vrednosti  $X$ . Če je  $X = (X_1, \dots, X_n)$ , potem  $dom(X)$  predstavlja kartezični produkt domen spremenljivk v  $X$ . Zapisano formalno:

$$dom(X) = dom(X_1) \times \dots \times dom(X_n),$$

pri čemer je  $\|X\| = \prod_i \|X_i\|$ . Za dve množici spremenljivk  $X$  in  $Y$  bomo zapisali  $dom(X \cup Y)$  ali  $dom(X, Y)$  za določitev  $dom(X) \times dom(Y)$ . Če  $z \in dom(Z)$  potem z  $z_x$  označimo projekcijo  $z$  na  $dom(X)$ , pri čemer je  $X \cap Z = \emptyset$ .

**Primer:** Predpostavimo, da je  $dom(X) = \{T, F\}$  in  $dom(Y) = \{ \text{rdeča}, \text{zelena}, \text{modra} \}$ . Potem je  $dom(X, Y) = \{ (\text{F}, \text{rdeča}), (\text{F}, \text{zelena}), (\text{F}, \text{modra}), (\text{T}, \text{rdeča}), (\text{T}, \text{zelena}), (\text{T}, \text{modra}) \}$ . Za  $z = \{F, modra\}$  dobimo  $z_x = F$  in  $z_y = modra$ .

### Naključne spremenljivke in odločitvene spremenljivke

V osnovi poznamo dve kategoriji spremenljivk. Spremenljivke, ki predstavljajo naključne dogodke in spremenljivke, kar predstavlja izbiro, ki jo določi uporabnik. V prvem primeru govorimo o tako imenovanih naključnih *spremenljivkah*, v drugem pa imenujemo spremenljivke *odločitvene spremenljivke*. Pri tem je treba povedati, da so naključne

spremenljivke v nekaterih primerih funkcionalno odvisne od drugih spremenljivk; v takem primeru jih imenujemo *deterministične (naključne) spremenljivke*. Včasih je pomembno, da ločimo prave naključne spremenljivke od determinističnih, a kjer to ni pomembno, bomo obe vrsti spremenljivk imenovali kar naključne spremenljivke. Identificiranje teh spremenljivk v domeni pri tem ni nujno najpreprostejši problem [49].

### Vozlišča in spremenljivke

Zapis spremenljivk in vozlišč je pogosto ekvivalenten v primerih modelov mrež, ki ne vsebujejo odločitvenih spremenljivk in funkcij koristi (Bayesove mreže). Pri modelih, ki uporabljajo odločitvene spremenljivke in funkcije koristi (Diagrami vpliva), pride v poštev razlikovanje med njim, ker vozlišče ne vsebuje nujno spremenljivke.

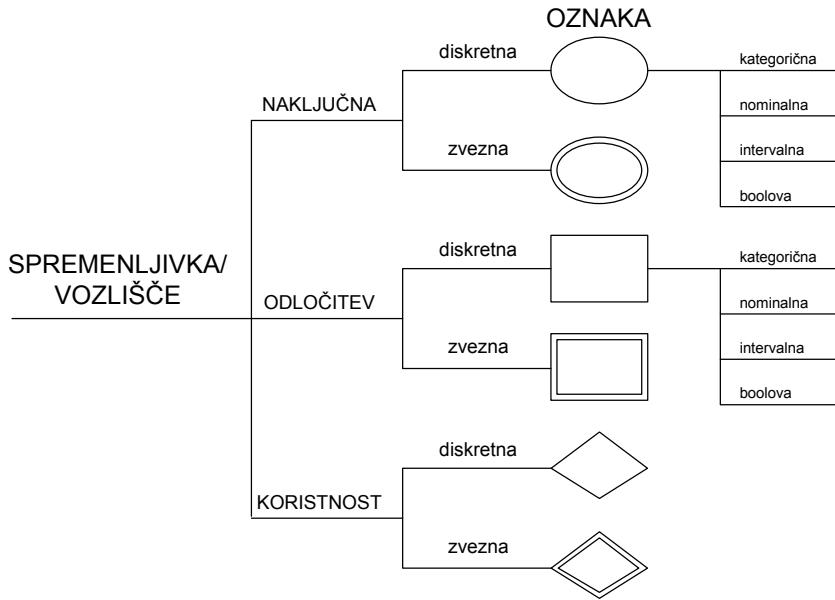
Za zapis vozlišč bomo v nalogi uporabljali male tiskane črke  $u, v, w$  (včasih tudi  $\alpha, \beta, \gamma \dots$ ), za zapis množice vozlišč pa velike črke  $U, V, W$ . Če vozlišče vsebuje spremenljivko bomo to označili z indeksom, na primer  $X_v$ , kar pomeni, da vozlišče  $v$  vsebuje naključno spremenljivko  $X$ . Podobno velja tudi za druge vrste entitet. Z  $X_{pa(v)}$  bomo označili uporabno funkcijo v vozlišču  $v$ , ki je definirana nad množico naključnih ali odločitvenih spremenljivk [49].

### Zapis vozlišč/spremenljivk

Pri zapisu terminologije za klasifikacijo vozlišč ali spremenljivk bomo uporabljali shemo opisano v nadaljevanju. Kot smo že zapisali, obstajajo trije glavni razredi vozlišč v verjetnostnih mrežah, naključne in odločitvene spremenljivke ter funkcije koristi. To bomo označevali kot *kategorija* vozlišča. Sama vozlišča lahko pri tem vsebujejo diskretne ali zvezne vrednosti, kar bomo označili kot *vrsto* vozlišča, pri naključnih in odločitvenih spremenljivkah pa bomo v delu razlikovali tudi med nominalnimi, boolovimi in numeričnimi spremenljivkami. Pri tem bomo za zapis vozlišč uporabljali grafične simbole, ki se navezujejo na kategorijo in vrsto spremenljivke. Na shemi 3.4 so predstavljene kategorije in vrste spremenljivk ter ustrezni grafični simboli za predstavitev vozlišča spremenljivke v mreži [49].

Tabela 3.1 predstavlja pregled nad zapisom spremenljivk v verjetnostnih mrežah, ki ga uporabljam v raziskovalnem delu. V zgornjem delu je zapis za oznake vozlišč, v srednjem spremenljivk in v zadnjem funkcij.

### 70 POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN



Slika 3.4: Taksonomija vozlišč/spremenljivk.

$S, U, V, W$	množica vozlišč
$V$	množica vozlišč modela mreže
$V_\Delta$	podmnožica $V$ , ki vsebuje diskretne spremenljivke
$V_r$	podmnožica $V$ , ki vsebuje zvezne spremenljivke
$u, v, w, \dots$	vozlišča
$\alpha, \beta, \gamma, \dots$	vozlišča
$X, Y_i, Z_j$	spremenljivke ali množica spremenljivk
$X_W$	podmnožica spremenljivk, ki ustreza množici vozlišč $W$
$X_u, X_\alpha$	spremenljivke, ki ustrezano vozlišču $u$ in $\alpha$
$x, y_i, z_j$	konfiguracije/stanja spremenljivke (množice spremenljivk)
$x_y$	projekcija konfiguracije $x$ na $dom(Y)$
$X_C$	množica naključnih spremenljivk modela
$X_D$	množica odločitvenih spremenljivk modela
$X_\Delta$	podmnožica diskretnih naključnih spremenljivk $X$
$X_r$	podmnožica zveznih naključnih spremenljivk $X$
$U$	množica funkcij koristi
$V_U$	podmnožica $V$ , ki predstavlja funkcije koristi
$u(X)$	funkcija koristi $u \in U$ z domensko spremenljivko $X$

Tabela 3.1: Zapisni spremenljivki v verjetnostnih mrežah.

### 3.1.2 Gotovost

Ključ inference (verjetnostnega sklepanja) pri verjetnostnih mrežah je izračun posteriorne verjetnosti po obliki  $P(x | \varepsilon)$ , kjer na splošno z  $\varepsilon$  označujemo *gotovost* (*evidence*), z drugimi besedami informacijo, pridobljeno iz zunanjih virov o možnih stanjih/vrednostih podmnožice spremenljivk mreže. Za diskretno množico gotovih spremenljivk  $X$  velja, da se gotovost pojavi v obliki pogojnega verjetja (*likelihood distribution*) nad spremenljivkami  $X$ ; pogosto to poimenujemo *funkcija gotovosti* (*evidence function*) ali *potencial* za  $X$ . Funkcija gotovosti  $\varepsilon_X$  za  $X$  je funkcija, ki slika  $\varepsilon_X : \text{dom}(X) \rightarrow \mathbf{R}^+$ . Pri zveznih naključnih spremenljivkah množice  $Y$  funkcija gotovosti  $\varepsilon_Y$  slika  $\varepsilon_Y : Y \rightarrow \mathbf{R}^+$ .

**Primer:** Če je  $\text{dom}(X) = \{x_1, x_2, x_3\}$ , potem je  $\varepsilon_X = \{1, 0, 0\}$  funkcija gotovosti, ki pravi, da se bo  $X$  zgodil z verjetnostjo  $X = x_1$ . Če je  $\varepsilon_X = \{1, 2, 0\}$ , potem sledi, da je  $X = x_2$  dvakrat verjetnejši kot  $X = x_1$ , pri čemer se  $X = x_3$  ne zgodi.

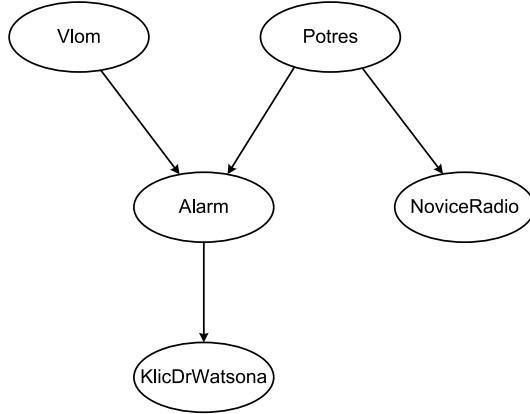
Funkcija gotovosti, ki priredi ničelno verjetnost vsem možnim stanjem spremenljivke, razen enemu, se imenuje *močna gotovost* (*hard evidence*). V drugih primerih imamo opravka s *šibko funkcijo gotovosti* (*soft evidence*). Močna gotovost spremenljivke  $X$  se pogosto navaja kot opazovanje  $X$ . V splošnem velja, da je močna funkcija gotovosti poseben primer šibke funkcije gotovosti. V zgornjem primeru je prvi primer funkcije močna gotovost, v drugem pa gre za šibko. Kjer to ni potrebno, bomo v delu šibko ali močno gotovost navajali kot gotovost [49].

### 3.1.3 Tok informacij v vzročnih mrežah

Usmerjen aciklični graf (DAG) modela Bayesove mreže je kompaktna grafična predstavitev odvisnih in neodvisnih lastnosti skupne verjetnostne porazdelitve (porazdelitve verjetnosti produkta). V tem podoglavlju bomo predstavili pravila pretoka informacij v DAG, pri čemer predstavlja vsaka povezava vzročni mehanizem; na primer *prehlad*  $\rightarrow$  *vročina* predstavlja dejstvo, da je prehlad vzrok za vročino. Skupno te lastnosti definirajo kriterij za razumevanje odvisnosti in neodvisnosti, kar je kodirano v takšnih vzročnih mrežah.

Za opis si bomo pogledali naslednji primer, ki ga bomo navajali v prihodnje.

**Primer:** (*Vlom ali potres* [39]) G. Holmes dela v pisarni, ko dobi *telefonski klic* svojega soseda dr. Watsona. Ta mu pove, da se je sprožil *alarm*. Prepričan, da je *vlomilec* vdrl v njegovo hišo, g. Holmes pohiti k avtu in se odpelje domov. Na poti



Slika 3.5: Vzročna mreža za primer vloma in potresa ([39])

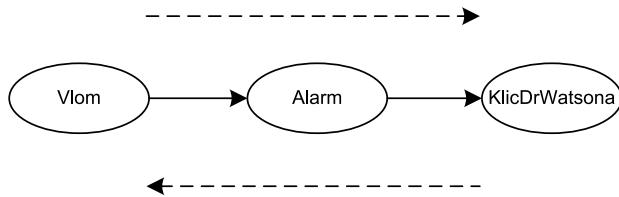
domov posluša radio in sliši *novice*, kjer povedo, da se je v bližini zgodil majhen potres. V vednosti, da se alarm lahko vklopi zaradi potresa, se g. Holmes vrne na delovno mesto.

Vzorčna mreža, ki predstavlja situacijo, je predstavljena na shemi 3.5. Mreža vsebuje vseh 5 relevantnih naključnih spremenljivk (vse spremenljivke so dvojiškega tipa). Poudarimo, da so vse povezave vzročne; vlom in potres lahko povzročita alarm, potres lahko povzroči, da so novice na radiu, in alarm lahko povzroči, da dr. Watson pokliče g. Holmesa [39].

Skupno število odvisnih in neodvisnih stavkov med spremenljivkami (povezani pari spremenljivk preko enega vozlišča v odvisni ali neodvisni relaciji) v mreži je 53, kar nam pove, da tudi majhne verjetnostne mreže kodirajo veliko število medsebojno (ne)odvisnih stavkov. V srednje velikih ali velikih mrežah je takih stavkov lahko več tisoč ali celo milijon.

Za branje takšnih stavkov iz DAG je zelo učinkovito, če upoštevamo vsako možno osnovno vrsto povezave v DAG. Iz sheme 3.5 lahko razberemo tri takšne različne povezave:

- Zaporedna povezava
  - Vlom —> alarm —> klic dr. Watsona
  - Potres —> alarm —> klic dr. Watsona
- Divergentna povezava
  - Alarm ← potres —> novice na radiu
- Konvergentna povezava



Slika 3.6: Zaporedna povezava brez močne gotovosti

- $Vlom \rightarrow alarm \leftarrow potres$

V nadaljevanju si bomo pogledali vsako vrsto relacije posebej in razložili njihovo zmožnost za prenos informacije pri podani gotovosti (*evidence*) v spremenljivki sredinskega vozlišča in v primeru, ko te gotovosti ni. Izpeljali bomo splošno pravilo za branje odvisnih in neodvisnih stavkov iz DAG, glede na tip povezave. Videli bomo, da bistveno lastnost, možnost medvzročnega sklepanja v verjetnostni mreži (eliminacija hipoteze), omogoča konvergentna vrsta povezave.

### Zaporedna povezava

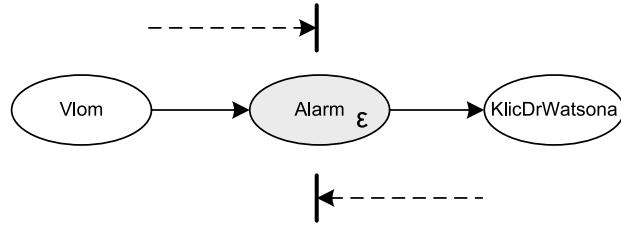
Vzemimo primer zaporedne povezave na shemi 3.5. Upoštevati moramo dva primera in sicer primer konfiguracije povezave s prisotnostjo močne gotovosti v sredinski spremenljivki *Alarm* in primer brez nje.

Najprej predpostavimo, da nimamo znanja o vrednosti in stanja spremenljivke *Alarm*. V primeru gotovosti o *Vlomu* se bo verjetnost v spremenljivko *Alarm* povečala, kar bo povzročilo tudi povečanje verjetnosti v spremenljivko *Klic dr. Watsona*. Velja tudi nasprotno: če bomo pridobili zunanjo informacijo o spremenljivki *Klic dr. Watsona* bo to povečalo verjetnost v *Alarm*, kar bo vplivalo tudi na večjo verjetnost spremenljivke *Vlom*.

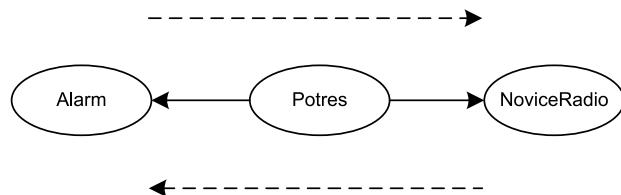
Dokler torej ne bomo zagotovo vedeli stanja spremenljivke *Alarm*, bo informacija o *Vlomu* preko spremenljivke *Alarm* vplivala na verjetnost *Klic dr. Watsona* in obratno. Situacija je prikazana na shemi 3.6, kjer puščici kažeta, da se gotovost lahko prenaša preko sredinskega vozlišča, dokler nimamo gotovega in določenega znanja o vrednosti spremenljivke v sredinskem vozlišču.

Predpostavimo, da imamo gotovo znanje o vrednosti spremenljivke *Alaram*. Z dano gotovostjo o sprožitvi *Alarma* bomo dosegli, da katera koli informacija o stanju spremenljivke *Vlom* ne bo spremenila verjetnosti v spremenljivko *Klic dr. Watsona*, saj je

## 74POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN



Slika 3.7: Zaporedna povezava s podano močno gotovostjo.



Slika 3.8: Divergentna povezava brez močne gotovosti.

v tem primeru *Alarm* edini vzrok, da dr. Watson pokliče g. Holmsa. Velja tudi obratno. Prav tako ne bo informacija o *Klicu dr. Watsona* vplivala na verjetnost *Vloma*, saj na to gotovo vpliva *Alarm*. Na shemi 3.7 je omenjena situacija prikazana s prekinjeno puščico na opazovani spremenljivki *Alarm* in označuje prekinitve pretoka informacije.

Pri tem poudarimo, da omenjena prekinitve velja le v primeru močne gotovosti spremenljivke *Alarm*. V primeru šibke gotovosti, če v stanje spremenljivke *Alarm* nismo povsem prepričani, še vedno velja, da informacija o *Vlomu* vpliva na *Klic dr. Watsona*, saj imamo nezanesljivo informacijo, da se je vklopil alarm g. Holmsa in obratno, kar bo še vedno povzročilo preverjanje v eno od obeh spremenljivk.

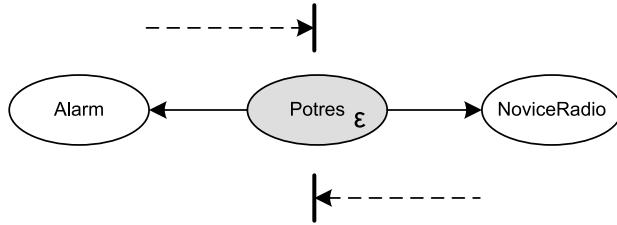
Generalno pravilo za zaporedno povezavo lahko torej zapišemo kot:

**Pravilo 1 (zaporedna povezava):** *Informacija v povezavi  $X \rightarrow Y \rightarrow Z$  lahko poteka med spremenljivkami povezave, dokler stanje  $Y$  ni znano.*

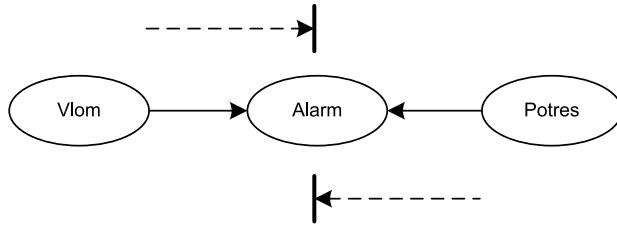
### Divergentna povezava

Ponovno vzemimo primer divergentne povezave iz primera verjetnostne mreže in upoštavamo stanje spremenljivke v sredini s prisotnostjo močne gotovosti ali brez nje. Situacija je navedena na shemi 3.8.

Predpostavimo torej, da ne poznamo dovolj stanja spremenljivke *Potres*. Če bomo torej pridobili informacijo o *Alarmu*, bo to vplivalo na verjetnost o *Potresu*, ker je



Slika 3.9: Divergentna povezava s podano močno gotovostjo.



Slika 3.10: Konvergentna povezava brez podane gotovosti.

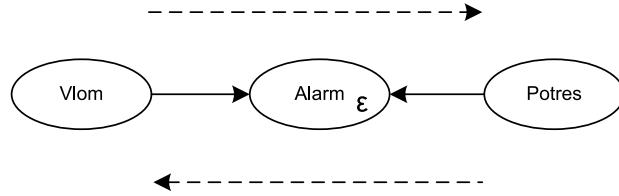
lahko alarm možna posledica potresa. Tako dopolnjena verjetnost v *Potres* bo vplivala tudi na spremenljivko *Radijske novice*. V nasprotnem primeru lahko pridemo do podobnega sklepa. Tako pridemo do podobne situacije kot pri zaporedni povezavi, kjer lahko informacija teče med skrajnima vozliščema v primeru, ko nimamo informacije o stanju spremenljivke v sredini (Shema 3.8). Predpostavimo, da je stanje spremenljivke *Potres* gotovo (opazujemo torej spremenljivko *Potres*, zanjo imamo močno gotovost). Če pridobimo katero koli informacijo o spremenljivki *Alarm* ali *Radijske novice*, ta informacija ne bo vplivala na verjetnost o *Potresu* in posledično ne bo spremojala naše verjetnosti v druge neopazovane spremenljivke, kar je podobno, kot smo navedli pri zaporedni povezavi (shema 3.10). To pa ne velja za primer šibke gotovosti (*soft evidence*) spremenljivke *Potres*, kar lahko zapišemo v splošnem pravilu za divergentno povezavo kot:

**Pravilo 2 (divergentna povezava):** *Informacija v povezavi  $X \leftarrow Y \rightarrow Z$  lahko poteka med spremenljivkami povezave, dokler stanje  $Y$  ni znano.*

### Konvergentna povezava

Konvergentno povezavo pojasnimo na naslednjem primeru iz verjetnostne mreže (3.10).

Če torej nimamo gotovosti v spremenljivko *Alarm*, potem informacija o stanju *Vloma* ne bo omogočila spremembe spremenljivke *Potres*. Z drugimi besedami - *Vlom* ni indikator *Potresa* in obratno, kar pomeni, da je za razliko od zaporedne in divergentne povezave



Slika 3.11: Konvergentna povezava s podano gotovostjo.

pri konvergentni povezavi pretok informacije ob neznani spremenljivki v središčnem vozlišču prekinjen (shema 3.10).

Če je dana gotovost o sprožitvi *Alarma*, potem bo informacija o *Vlomu* omogočila razlago gotovosti spremenljivke *Alarm* in bo tako potrdila ali zavrgla *Potres* kot vzrok za sprožitev Alarma. Velja seveda tudi obratno. Ponovno velja nasprotno, kot velja pri zaporedni in divergentni povezavi, saj se pri konvergentni povezavi ob podani močni gotovosti spremenljivke tok informacije sprosti in ne prekine, kar je predstavljeno na shemi 3.11.

Pravilo na shemi 3.10 nam torej pove, da če ni ničesar znanega o posledicah vzrokov, v našem primeru sta to *Potres* in *Vlom* (v splošnem imamo na voljo več možnih vzrokov), potem so vzroki med seboj neodvisni; sprememba informacije na enem vzroku ne bo vplivala na drug vzrok. A vendar, kakor hitro se pojavi gotovost ali znanje o posledici teh vzrokov, vzroki med seboj postanejo odvisni. Če na primer g. Holmes pridobi klic dr. Watsona, ki mu pove, da se je vklopil alarm, postaneta potres in vlom konkurenčni hipotezi za razlago alarma in pridobitev informacije o enem izmed njiju potrdi ali ovrže hipotezo drugega. Pri tem je treba poudariti, da četudi informacija o alarmu ni popolnoma gotova, oba vzroka, potres in vlom, postaneta delno odvisna. Iz tega sledi splošno pravilo za konvergentno povezavo, ki pravi:

**Pravilo 3 (konvergentna povezava):** *Informacija v povezavi  $X \leftarrow Y \leftarrow Z$  lahko poteka med spremenljivkami povezave samo takrat, če je dana gotovost stanja  $Y$  ali njihovih naslednikov.*

#### Medvzročna povezava - eliminacija hipoteze

Lastnost konvergentne povezave  $X \rightarrow Y \leftarrow Z$  je takšna, da informacije o stanju spremenljivke  $X(Z)$  zagotavljajo razlago opazovane posledice na  $Y$  in tako potrdi ali ovrže  $Z(X)$ . Vzrok opazovane posledice pogosto imenujemo kot "efekt eliminacije hipoteze" (*explaining away effect*) ali "medvzročno sklepanje" (intercausal inference). Na primer,

pridobitev novice na radiju o potresu omogoča močno gotovost, da je potres vzrok alarma in tako eliminira vzrok vloma. Zmožnost medvzorčnega sklepanja je unikatna za grafične modele in ena izmed ključnih razlik med avtomatskim sklepanjem pri sistemih, temeljujočih na produkcijskih pravilih in sistemih, ki temeljijo na verjetnostnih mrežah. Pri sistemih produkcijskih pravil namreč potrebujejo dodatna izpeljana pravila, na podlagi katerih je mogoče izvesti medvzročno sklepanje.

Pomembnost in obravnavo različnih tipov povezav v verjetnostnih mrežah, ki smo jih obravnavali v razdelkih, podajamo v naslednji tabeli.

	Brez gotovosti	Šibka gotovost	Močna gotovost
Zaporedna	odprta	odprta	zaprta
Divergentna	odprta	odprta	zaprta
Konvergentna	zaprta	odprta	odprta

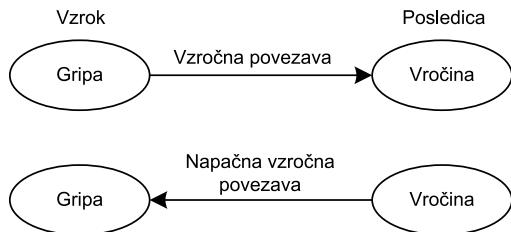
Tabela 3.2: Pretoki informacij pri različnih gotovostih.

Kot je razvidno iz tabele 3.2, potrebujemo pri zaporedni in divergentni povezavi dano močno gotovost opazovanega vozlišča, da prekinemo tok informacije med skrajnima vozliščema povezave, pri čemer šibka gotovost ni dovolj. Pri konvergentni povezavi je ravno obratno. Tam nam že prisotnost šibke gotovosti (prav tako pa močna gotovost) omogoči pretok informacije, ki je sicer v stanju nedefinirane vrednosti opazovanega vozlišča v začetku prekinjen; to je ravno nasprotno, kot je to v začetku pri drugih dveh vrstah povezav. Konvergentna povezava je, kot smo videli, tudi tista, ki omogoči poglavito lastnost verjetnostnih mrež, to je zmožnost medvzročnega sklepanja.

### 3.1.4 Vzročnost

Vzročnost (*causality*) ima pomembno vlogo v procesu konstrukcije modelov verjetnostnih mrež. Obstaja mnogo razlogov, zakaj je pravilno modeliranje vzročnih relacij pomembno, čeprav za usmerjene povezave v grafu ni nujno zahtevano, da relacije sledijo vzročnosti povezave. Zaradi narave raziskovalnega dela bomo v tem razdelku le bežno omenili nekatere pomembne točke vzročnega modeliranja, več in podrobnejše pa navajamo v literaturi [40]. Spremenljivka  $X$  je poimenovana kot neposredni vzrok za  $Y$ , če sprememba spremenljivke  $X$  povzroči spremembo na spremenljivki  $Y$  in pri tem ni nobene druge spremenljivke  $Z$ , ki bi bila neposredni vzrok za  $Y$  tako, da bi bila  $X$  neposredni vzrok za  $Z$  [40]. Kot primer navedimo spremenljivki *Prehlad* in *Vroino*. Intuicija nam pove, da je *Prehlad* lahko vzrok za *Vroino* in ne nasprotno. Shema 3.12 prikazuje to relacijo.

## 78 POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN



Slika 3.12: Prehlad povzroči vročino in ne nasprotno.

To dejstvo lahko preverimo na veliko pravilno postavljenih poizkusih. Izbijanje *Vročine* z hladnim tušem ali *aspirinom* ne bo imelo posledic na *Prehlad*. Če pozdravimo prehlad, pa bo vročina popustila (če seveda predpostavimo, da je prehlad v tem primeru edini vzrok za vročino).

Za pravilno predstavitev odvisnih in neodvisnih relacij med spremenljivkami na domenskem področju problema velja za uporabno predstavitev vzročnih relacij med spremenljivkami v obliki usmerjenih povezav od vzroka k posledici. Če na primer  $X$  povzroči  $Y$ , moramo zagotoviti povezavo od  $X$  do  $Y$ , v nasprotnem primeru naš model ni pravilen in nepravilno predstavlja relacijo odvisnosti in neodvisnosti na domeni, kar se izraža v napačnem verjetnostnem sklepanju. Velikokrat se namreč zgodi, da dopustimo povezavam usmerjenost od posledice k vzroku, kar vodi k napačnim stavkom pogojnih odvisnosti in napačnem sklepanju modela.

V našem primeru bi lahko s prehitrim razmislekom usmerili neposredno povezavo od spremenljivke *Klic dr. Watsona* do *Alarma*, saj telefonski klic dr. Watsona vzbuja sum o alarmu. Izkušnje kažejo, da se te vrste napak pojavlajo v začetnih gradnjah in pri uporabi modela verjetnostnih mrež.

Drugi vzrok upoštevanja vzročnih relacij je pomemben zaradi signifikantnega vpliva pogojne verjetnosti. Če  $Y \rightarrow X$  ne odseva vzročne povezave, potem nastane težava pri računanju pogojne verjetnosti pri  $X = x$ , z danim pogojem  $Y = y$ . Težko je na primer določiti verjetnost, da je g. Holmsu v hišo vdrl vlomilec pri danem pogoju, da se je sprožil alarm, če se lahko alarm sproži tudi zaradi drugih vzrokov. Zato je specificiranje verjetnosti pojavitve alarma pri danem možnem vzroku (potres, vlom...) bolj smiselno in naravno, saj zagotavlja vrsto popolnega opisa za lokalni fenomen.

### 3.1.5 Kriterija irelevance

Pravila branja relacij iz verjetnostnih mrež na podlagi različnih povezav (zaporedna, divergentna, konvergentna) so potrebna za formuliranje splošnega pravila branja odvisnih/neodvisnih stavkov za dve spremenljivki (množici spremenljivk) ob možni podani tretji spremenljivki ali (množici spremenljivk). To splošno pravilo je poznano kot kriterij d-ločitve (*d-separation*) [39].

V naslednjem, četrtem, poglavju o verjetnosti bomo pokazali, da za katero koli verjetnostno porazdelitev produkta, ki se lahko razdeli (faktorizira) glede na *DAG*  $G$ , velja, da so neodvisni stavki, ki vključujejo spremenljivko  $X_u$  in  $X_v$ , ekvivalentni ali podobni stavkom o d-ločitvi vozlišč  $u$  in  $v$  v grafu  $G$ . Kriterij d-ločitve se zato lahko uporablja v poizvedbah za naslednje primere: "ali sta  $X$  in  $Y$  neodvisni pri podanem  $Z$ " (v verjetnostnem smislu) ali bolj splošno "ali je informacija o  $X$  nepomembna za povečanje verjetnosti  $Y$ , glede na podano informacijo o  $Z$ ", pri čemer sta  $X$  in  $Y$  naključni spremenljivki in je  $Z$  prazna množica ali naključna spremenljivka.

D-ločitveni kriterij se lahko uporablja tudi za množice spremenljivk, čeprav je v ta namen bolje uporabiti kriterij usmerjene globalne Markove lastnosti [96], ki učinkovito odgovarja na poizvedovanja med množicami in je ekvivalentna kriteriju d-ločitve. Ker stavki (pogojne) d-ločenost/d-povezanosti in (pogojne) neodvisnosti/odvisnosti zavzemajo pomembno vlogo v verjetnostnih mrežah, podajamo v nadaljevanju standarden zapis, ki ga bomo uporabljali v nadaljevanju, kar je prikazano na tabeli 3.3.

Zapis	Pomen
$u \perp_G v$	$u \in V$ in $v \in V$ sta d-ločena v grafu $G = (V, E)$
$U \perp_G V$	Vsak $u \in U$ in vsak $v \in V$ sta d-ločena v grafu $G$ - preprosto povemo, da sta $U$ in $V$ d-ločena v $G$
$U \perp V$	$U$ in $V$ sta d-ločena, graf $G$ je razumljen iz vsebine
$U \perp V   W$	$U$ in $V$ sta d-ločenost pri podani močni gotovosti na $W$
$U \not\perp V   W$	$U$ in $V$ sta d-povezana pri podani močni gotovosti na $W$
$X \perp_P^P Y$	$X$ in $Y$ sta robno neodvisni glede na verjetnostno porazdelitev $P$
$X \perp^P Y$	$X$ in $Y$ sta robno neodvisni, verjetnostna porazdelitev se razume iz vsebine $P$
$X \perp^P Y   Z$	$X$ in $Y$ sta pogojno neodvisni pri dani močni gotovosti na $Z$
$X \not\perp^P Y   Z$	$X$ in $Y$ sta pogojno odvisni pri dani močni gotovosti na $Z$

Tabela 3.3: Standardni zapisi v verjetnostnih mrežah.

Kot primer poglejmo zapis relacij na Bayesovi mreži vloma in potresa [39]. Spodaj so zapisane povezave lastnosti med nekaterimi d-povezanimi in d-ločenimi lastnostmi.

## 80POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN

1.  $Vlom \perp Potres$
2.  $Vlom \not\perp Potres \mid Alarm$
3.  $Vlom \perp Radijske novice$
4.  $Vlom \perp Klic dr. Watson \mid Alarm$

D-ločitev in d-povezanost (kot odvisnost in neodvisnost pri verjetnosti) sta odvisni od razpoložljive informacije; odvisno od tega kar vemo (in česar ne). Za d-ločitev in d-povezanost, kot tudi neodvisnost in odvisnost, velja lastnost simetrije.

### **Kriterij d-ločitve**

Pravila od 1-3 so lahko povzeta v pravilu, poznanem kot d-ločitev [39].

**Pravilo 4: (d-ločitev)** *Pot  $\pi = \langle u, \dots, v \rangle$  v DAG,  $G = (V, E)$  je prekinjena z  $S \subseteq V$ , če vsebuje vozlišče  $w$  tako, da velja eden izmed naslednjih pogojev:*

1.  $w \in S$  in povezave v  $\pi$  se ne srečujejo z glave na glavo v  $w$  (konvergentna povezanost),
2.  $w \notin S$ ,  $de(w) \cap S = \emptyset$  in povezave v  $\pi$  se srečujejo z glave na glavo v  $w$

Za tri (ni nujno nezdružljive) podmnožice  $A, B, S$  množice  $V$  velja, da sta  $A$  in  $B$  medsebojno d-ločeni, če so vse poti med  $A$  in  $B$  prekinjene z  $S$ .

Pravilo 4 lahko uporabimo iz pogleda vozlišč ali pogleda povezav. Naj bo  $G = (V, E)$  DAG vzročne mreže in naj bodo  $H_\varepsilon \subseteq S_\varepsilon \subseteq V$  podmnožice vozlišč s podano močno gotovostjo ( $H_\varepsilon$ ) in šibko gotovostjo ( $S_\varepsilon$ ). Predpostavimo, da želimo odgovor na vprašanje, "ali so vozlišča  $v_1$  in  $v_n$  d-ločena v  $G$  pod podanimi scenariji  $S_\varepsilon$ ?"

Z uporabo pristopa vozlišč lahko na naslednje vprašanje odgovorimo kot:

Če za katero koli pot  $\langle v_1, \dots, v_n \rangle$  med  $v_1$  in  $v_n$  in za vsak  $i = 2, \dots, n - 1$ , velja ena od naslednjih trditev:

1.  $v_i \in H_\varepsilon$  in so povezave  $v_{i-1} \sim v_i \sim v_{i+1}$  zaporedne ali divergentne ali
2.  $(\{v_i\} \cup de(v_i)) \cap S_\varepsilon = \emptyset$  in  $v_{i-1} \longrightarrow v_i \longleftarrow v_{i+1}$ ,

potem sta  $v_1$  in  $v_n$  d-ločena pri podanem  $S_\varepsilon$ ; drugače sta d-povezana pri podanem  $S_\varepsilon$ .

Pogosto je lažje razmišljati intuitivno v smislu pretoka informacij. V tem primeru uporabimo pristop d-ločitve po povezavah, in sicer:

1. Če za pot  $\langle v_1, \dots, v_n \rangle$  med  $v_1$  in  $v_n$  in za vsak  $i = 2, \dots, n - 1$  povezave  $v_{i-1} \sim v_i \sim v_{i+1}$  dovoljujejo tok informacij od  $v_{i-1}$  do  $v_{i+1}$  potem sta  $v_1$  in  $v_n$  d-povezani, drugače sta d-ločeni.

Ko uporabljam pristop toka informacije ne smemo zaiti v shemo razmišljanja: "ker informacija lahko teče iz  $u$  v  $v$  in iz  $v$  v  $w$ , lahko poteka od  $u$  do  $w$ ", saj ta način ni podprt pri opisanem postopku. Problem nastane pri vozliščih, kjer se povezave srečajo v glava-na-glavo in je pretok informacije prekinjen, dokler ni na voljo močna gotovost za  $v$  ali katerega izmed naslednikov  $v$ .

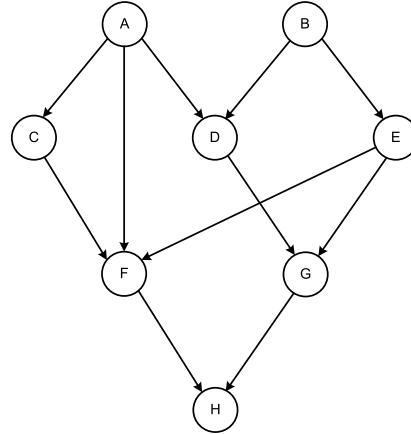
Poglejmo naslednji primer, prikazan na shemi 3.13 pri katerem ugotavljam, ali so spremenljivke  $C$  in  $G$  d-ločene na DAG: z drugimi besedami, ali sta  $C$  in  $G$  neodvisni, ko ni na voljo nobene gotovosti o kateri koli drugi spremenljivki. Z uporabo pristopa povezav najprej vpeljimo povezavo od  $C \leftarrow A \rightarrow D$ , ki dovoljuje tok informacij od  $C$  do  $D$  preko  $A$ . Potem sledi divergentna povezava  $A \rightarrow D \rightarrow G$ , ki prav tako dovoljuje pretok informacij od  $A$  do  $G$  preko  $D$ . Informacije se torej lahko prenašajo od  $C$  do  $G$ , kar pomeni, da spremenljivki nista d-ločeni, pač pa d-povezani.

$C$  in  $E$  sta na drugi strani d-ločeni, saj vsaka pot od  $C$  do  $E$  vsebuje konvergentno povezavo. Ker ni na voljo nobene gotovosti, bo pretok informacij med vozliščema prekinjen v vsaki poti. S podano gotovostjo na eni ali več spremenljivkah v množici  $\{D, F, G, H\}$  bosta  $C$  in  $E$  postali d-povezani. V primeru, da imamo podano gotovost za  $H$ , bo na primer prišlo do spremembe pretoka in povezava  $D \rightarrow G \leftarrow E$  bo dovoljevala tok, saj je  $H$  otrok  $G$ .

### Markov kriterij

Markov kriterij predstavlja kriterij, ki je ekvivalenten kriteriju d-ločitve [96] a se v nekaterih primerih lahko izkaže za učinkovitejšega zaradi manj preverjanj možnih poti med vozlišči v grafu.

**Pravilo 5: (Markov kriterij)** Naj bo  $G = (V, E)$  DAG in  $A, B, S$  nezdružljive množice  $V$ . Potem vsak par vozlišč ( $\alpha \in A, \beta \in B$ ) velja d-ločenost z  $S$ , če je katera koli



Slika 3.13: Preprosti  $DAG$  z nekaj primeri odvisnosti (d-povezanost) in neodvisnosti (d-ločenih) stakov.

pot od  $\alpha$  do  $\beta$  prekinjena od  $S$  v grafu

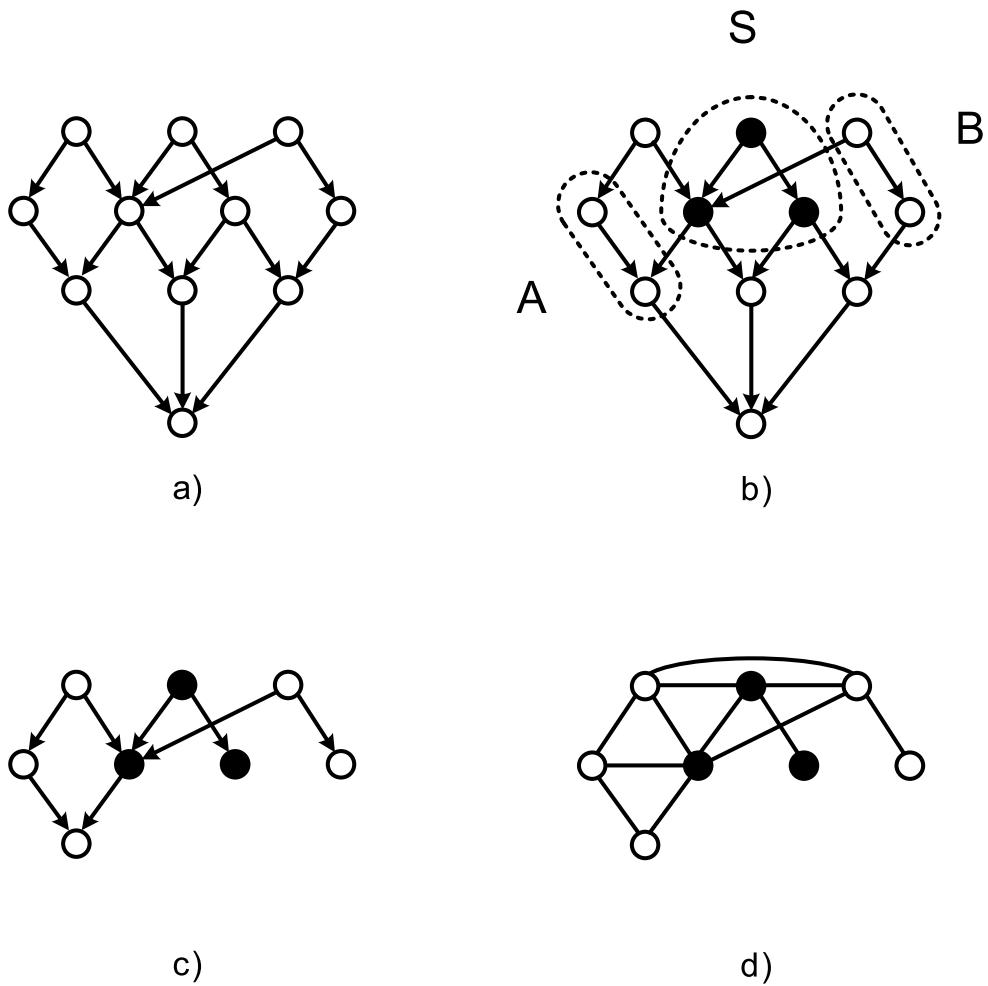
$$(G_{An(A \cup B \cup S)})^m$$

Čeprav je kriterij videti manj intuitiven in bolj zapleten, ga je pravzaprav preprosto aplicirati. Kriterij pove, da  $A \perp_G B | S$ , če vse poti med  $A$  do  $B$  vključujejo vsaj eno vozlišče  $S$  v moralnem grafu pod- $DAG$  grafa, ki nastane iz ancestralne množice  $A \cup B \cup S$ .

Kot primer vzemimo graf  $G = (V, E)$  na shemi 3.14, ki naj bodo podmnožice  $A, B, S \subseteq V$  podane tako kot kaže shema, pri čemer je  $S$ , množica podanih gotovosti predstavljena s pobravnimi vozlišči. Z uporabo pravila 5 lahko hitro pokažemo, da sta  $A$  in  $B$  d-povezani na grafu  $G$  pri podanem  $S$  saj ne velja, da vsaka pot med  $A$  in  $B$  vsebuje vozlišče v  $S$  v moralnem grafu množice ancestralne množice  $(A \cup B \cup S)$ . Da pridemo do tega sklepa, najprej odstranimo vsa vozlišča, ki ne pripadajo  $An(A \cup B \cup S)$ , potem moraliziramo pridobljen podgraf  $DAG$ , kar nam poda zadnji graf, prikazan na shemi 3.14.

## 3.2 Osnovne zakonitosti in koncepti verjetnostnega računa

Kot smo videli, imajo verjetnostne mreže kvalitativen in kvantitativen vidik, pri čemer je kvalitativen vidik podan s predstavljivo acikličnega usmerjenega grafa ( $DAG$ ), ki predstavlja relacije pogojnih odvisnosti in neodvisnosti med lastnostmi produkta verjetnostne porazdelitve, definirane na množici spremenljivk, ki so indeksirane v vozliščih  $DAG$ .



Slika 3.14: (a)  $DAG$  (b)  $G$  s podmnožicami  $A, B$  in  $S$ , obarvana vozlišča so opazovana (c), inducirani podgraf na ancestralni množici  $A \cup B \cup S$  (d), moralizirani graf  $DAG$  grafa iz (c).

## 84POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN

Da se struktura verjetnostne mreže lahko opiše kot DAG, izhaja iz osnovnih aksiomov verjetnostnega računa, ki vodijo do rekurzivne faktorizacije porazdelitve verjetnosti produkta v produkt pogojnih verjetnosti nižje dimenzionalnih porazdelitev. Velja, da se lahko porazdelitev verjetnosti produkta razstavi (ali faktorizira) v produkt pogojnih verjetnostnih porazdelitev različne dimenzionalnosti, kjer je dimenzija največje porazdelitve identična dimenziji porazdelitve verjetnosti produkta.

Porazdelitev verjetnosti produkta  $\mathcal{P}$  se lahko rekurzivno razstavi le v primeru, kadar obstaja *DAG*, v katerem so (pogojne) odvisnosti in neodvisnosti produkta  $\mathcal{P}$  pravilno predstavljene. To z drugimi besedami pomeni, da je množica porazdelitve pogojnih verjetnosti določena s predstavitvijo *DAG*,  $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ .

Model verjetnostnih mrež je sicer lahko specificiran neposredno s porazdelitvijo produkta pogojnih verjetnosti, vendar ga pogosteje in značilno specificiramo s pomočjo strukture *DAG*, ki izraža vzročno posledične relacije z množico pripadajočih porazdelitev pogojnih verjetnosti.

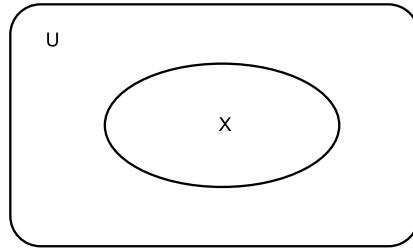
V tem poglavju povzemamo nekaj osnovnih zakonitosti verjetnostnega računa iz katerega izhaja znano Bayesovo pravilo, kot tudi verižno pravilo za dekompozicijo skupne verjetnostne porazdelitve v produkt pogojnih porazdelitev. Predstavili bomo osnovne operacije potrebne za izvedbo sklepanja (*inference*) v verjetnostnih mrežah. Pri tem se bomo omejili le na diskretne primere, čeprav lahko pravila naravno razširimo tudi na funkcije gostote verjetnosti zveznih spremenljivk in mešane porazdelitve.

Delovanje verjetnostnih mrež temelji na teoriji verjetnosti, zato je pomembno razumevanje verjetnosti in še posebej pogojne verjetnosti, ki igra pri tem pomembno vlogo. V tem delu poglavja bomo predstavili nekatere osnovne koncepte in postavke Bayesove verjetnostne teorije, več najdemo v [59, 82, 4, 102].

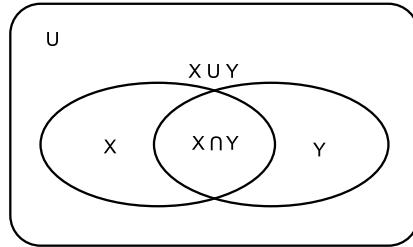
### 3.2.1 Definicija verjetnosti

Vzemimo (diskretno) univerzalno množico  $U$  z elementi in naj bo  $X \subseteq U$ . Označimo z  $\bar{X} = U \setminus X$  kot komplement od  $X$ . Shema 3.15 predstavlja množico  $U$ , kjer predpostavimo, da je površina področja, ki ga pokriva  $X$ , sorazmerna številu elementov, ki jih vsebuje.

Možnost, da iz množice  $U$  naključno izberemo element, ki pripada  $X$  definiramo kot *verjetnost*, da element pripada množici  $X$ , in označimo kot  $P(X)$ . Pri tem je lahko



Slika 3.15: Geometrijska definicija verjetnosti

Slika 3.16: Množica  $U = X \cup Y \cup \overline{X} \cup \overline{Y}$ 

$P(X)$  definirana tudi kot relativno področje, ki je pokrito z  $X$  v  $U$ .  $P(X)$  lahko zavzame vrednost med 0 in 1.

Predpostavimo, da je  $U = X \cup Y \cup \overline{X} \cup \overline{Y}$  (glej shemo 3.16). Verjetnost, da naključni element iz  $U$  sedaj pripada ali  $X$  ali  $Y$ , definiramo kot

$$P(X \cup Y) = P(X) + P(Y) - P(X \cap Y).$$

Ponovno lahko interpretiramo  $P(X \cup Y)$  kot relativno področje v  $U$ , pokrito z združenima množicama  $X$  in  $Y$ . Če torej množici  $X$  in  $Y$  nista združeni (velja,  $X \cap Y = \emptyset$ ), potem je  $P(X \cup Y) = P(X) + P(Y)$ . Konjuktivna oblika  $P(X \cap Y)$  se pogosto zapiše kot  $P(X, Y)$ .

Vzemimo naslednjo shemo 3.16 in predpostavimo, da vemo, kolikšna je verjetnost, da naključni element iz  $U$  pripada množici  $Y$ . Verjetnost, da v tem primeru pripada tudi  $X$ , se lahko izračuna kot razmerje med  $P(X \cap Y)/P(Y)$ . Ponovno velja, da pri tej definiciji pomaga, če na  $P(X \cap Y)$  in  $P(Y)$  gledamo kot na relativna področja v  $U$ . V nadaljevanju bomo za tako razmerje uporabili zapis  $P(X | Y)$ , kjer " | " preberemo kot "pri podani". Tako dobimo

$$P(X | Y) = \frac{P(X \cap Y)}{P(Y)} = \frac{P(X, Y)}{Y},$$

## 86 POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN

kjer  $P(X | Y)$  definiramo kot "pogojna verjetnost  $X$  pri danem pogoju  $Y$ ".

### Dogodki

Jezik verjetnosti je sestavljen iz stavkov o verjetnosti dogodkov. Kot primer vzemimo dogodek  $a$ , ki se zgodi, ko element iz univerzuma  $U = X \cup \bar{X}$  pripada  $X$ . Verjetnost dogodka  $a$  označimo kot  $P(a)$ . V splošnem lahko *dogodek* razumemo kot rezultat nekega poizkusa (na primer met kovanca), opazovanja določene vrednosti spremenljivke ali množice spremenljivk itn. Kot verjetnostno mrežo definiramo porazdelitev verjetnosti preko množice spremenljivk  $V$ , v našem kontekstu je dogodek konfiguracija  $x \in \text{dom}(X)$  podmnožice spremenljivk  $X \subset V$ .

### Aksiomi

Naslednji aksiomi predstavljajo osnove za Bayesovo verjetnost in povzemajo izhodišča omenjena v prejšnjih podpoglavljih.

1. Za kateri koli dogodek  $a$ , pri čemer velja  $0 \leq P(a) \leq 1$  velja, da je  $P(a) = 1$ , samo v primeru, ko se  $a$  pojavi z gotovostjo.
2. Za katera koli dogodka  $a$  in  $b$ , ki se ne moreta pojaviti hkrati (nezdružljiva dogodka) velja naslednje:

$$P(a \text{ ali } b) \equiv P(a \vee b) = P(a) + P(b)$$

V splošnem velja, če so dogodki  $a_1, a_2, \dots, a_n$  nezdružljivi potem

$$P\left(\bigcup_i^n (a_i)\right) = P(a_1) + \dots + P(a_n) = \sum_i^n P(a_i)$$

3. Za katera koli dogodka  $a$  in  $b$ , ki se pojavita hkrati velja:

$$P(a \text{ in } b) \equiv P(a \wedge b) \equiv P(a, b) = P(b | a)P(a) = P(a | b)P(b).$$

$P(a, b)$  je definirana kot verjetnost produkta dogodkov  $a$  in  $b$ .

Aksiom 1 preprosto pravi, da je verjetnost ne negativno realno število, ki je enako ali manjše od 1, pri čemer je enako 1 samo v primeru, ko se dogodek zagotovo zgodi.

Aksiom 2 govorji, da če gre za dva nezdružljiva dogodka, ki se ne moreta zgoditi hkrati, potem je verjetnost da se je zgodil eden izmed njiju enaka vsoti njunih posameznih pojavitev.

Aksiom 3, včasih obravnavan kot *temeljno pravilo* verjetnostnega računa, pravi, da če sta dogodka  $a$  in  $b$  odvisna, potem je verjetnost dogodka  $b$  različna v primeru, če se je dogodek  $a$  zgodil ali ne. Verjetnost dogodka  $b$  v primeru, če se je dogodek  $a$  zgodil, imenujemo pogojna verjetnost dogodka  $b$  pri pogoju  $a$  in jo označimo  $P(b | a)$ . Tako se produkt odvisnih dogodkov izračuna kot produkt verjetnosti dogodka  $b$  pri pogoju  $a$ ,  $P(b | a)$ , in verjetnosti dogodka  $P(a)$  ki se je že zgodil.

### 3.2.2 Pogojna verjetnost

Osnovni koncept Bayesove obravnave nedoločenosti predstavlja *pogojna verjetnost*: Pri danem dogodku  $b$  je pogojna verjetnost dogodka  $a$  enaka  $x$ , kar se zapiše kot:

$$P(a | b) = x$$

To z drugimi besedami pomeni, da če se je dogodek  $b$  zgodil in je kot tak vplival na  $a$ , potem je verjetnost dogodka  $a$  enaka  $x$ .

Naslednji koncept, ki ga moramo predstaviti za razumevanje verjetnostnih mrež je definicija neodvisnosti.

#### Neodvisnost

Spremenljivka  $X$  je neodvisna od spremenljivke  $Y$ , glede na verjetnostno porazdelitev  $P$ , če velja:

$$P(x | y) = P(x), \forall x \in \text{dom}(X), \forall y \in \text{dom}(Y) \quad (3.1)$$

To lastnost zapišemo kot  $X \perp PY$  ali preprosto kot  $X \perp Y$ , če je porazdelitev  $P$  podana iz vsebine. Pri tem stavek  $Y \perp Y$  pogosto nava jamo kot robna ali marginalna neodvisnost med  $X$  in  $Y$ .

Spremenljivka  $X$  je pogojno neodvisna od  $Y$  pri podanem  $Z$  (glede na porazdelitev  $P$ ), če velja:

$$P(x | y, z) = P(x | z), \forall x \in \text{dom}(X), \forall y \in \text{dom}(Y), \forall z \in \text{dom}(Z) \quad (3.2)$$

## 88POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN

Pogojno neodvisnost med spremenljivkami v enačbi 4.2 zapišemo kot  $X \perp\!\!\!\perp Y | Z$ . Izjemoma v delu zapišemo tudi, da  $P(X | Y, Z) = P(X | Z)$ , kar sicer ni popolnoma pravilno, saj velja ob predpostavki, da ne upoštevamo razlik v dimenzionalnosti členov  $P(X | Y, Z)$  in  $P(X | Z)$ .

### 3.2.3 Verjetnostne porazdelitve

Verjetnostne mreže so definirane preko (končne) množice spremenljivk, ki predstavljajo nezdružljiva (medsebojno izključljiva) stanja ali dogodke. Zato (pogojne) verjetnostne porazdelitve za spremenljivke (porazdelitve preko obsežnih množic nezdružljivih dogodkov) zavzemajo pomembno mesto pri verjetnostnih mrežah.

Če je  $X$  (naključna) spremenljivka z domeno  $dom(X) = (x_1, \dots, x_{\|X\|})$ , potem  $P(X)$ , označuje verjetnostno porazdelitev (vektor verjetnosti, katerega seštevek je enak 1), kjer je  $P(X) = P(X = x_1), \dots, P(X = x_{\|X\|})$ . Pogosto bomo navajali  $P(x)$  kot okrajšavo za  $P(X = x)$ . Če je verjetnostna porazdelitev za spremenljivko  $Y$  podana pogojno, glede na spremenljivko (ali množico spremenljivk)  $X$ , potem bomo zapisali  $P(Y | X)$ . To pomeni, da je za vsako možno vrednost (stanje)  $x \in dom(X)$  verjetnostna porazdelitev  $P(Y | X = x)$ . Ponovno bomo skrajšavo, kjer je možno, zapisali kot  $P(Y | x)$ .

#### Grafična predstavitev porazdelitve

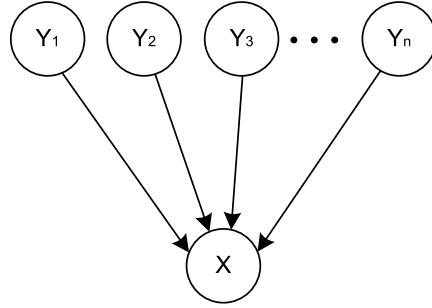
Pogojne verjetnostne porazdelitve za verjetnostne mreže zapisujemo v obliki

$$P(X | Y),$$

kjer predstavlja  $X$  naključno spremenljivko in  $Y$  množico naključnih spremenljivk (lahko tudi prazno).  $X$  in  $Y$  v nekaterih primerih poimenujemo tudi kot *glava* in *rep*  $P(X | Y)$ . Če je  $Y = \emptyset$ , potem  $P(x | Y)$  pogosto navajamo kot *robna* ali *marginalna verjetnostna porazdelitev* in jo zapišemo kot  $P(X)$ . Povezavo med  $X$  in  $Y = \{Y_1, \dots, Y_n\}$  lahko predstavimo v obliki grafa *DAG*, ki ga prikazuje shema 3.17, kjer je vozlišče otroka enako  $X$  in starši  $Y_1, Y_2$  itn.

#### Teoremi pogojnih verjetnostnih porazdelitev

Navajamo dva teorema pogojne verjetnosti, ki ju bomo pogosto uporabljali. To sta teorem "popolne verjetnosti" in "verižno pravilo".

Slika 3.17: Grafična predstavitev  $P(X | Y_1, \dots, Y_n)$ .

### 3.2.4 Popolna verjetnost

Naj bo  $P(X, Y)$  skupna verjetnostna porazdelitev (porazdelitev verjetnosti produkta) za spremenljivki  $X$  in  $Y$  z domenama  $dom(X) = (x_1, \dots, x_m)$  in  $dom(Y) = (y_1, \dots, y_n)$ . Z uporabo predpostavke, da sta  $dom(X)$  in  $dom(Y)$  množici medsebojno nezdružljivih dogodkov  $X$  in  $Y$ , in uporabo aksioma 3.2 dobimo tako imenovano pravilo ali teorem popolne verjetnosti:

$$\forall : P(x_i = P(x_i, y_1) + \dots + P(x_i, y_n) = \sum_j^n P(x_i, y_j)$$

Z uporabo te enačbe lahko izračunamo  $P(X)$  iz  $P(X, Y)$

$$P(X) = (\sum_j^n P(x_1, y_j), \dots, \sum_j^n P(x_m, y_j),$$

ali skrajšano

$$P(X) = \sum_j^n P(X, y_j), \quad (3.3)$$

ali

$$P(X) = \sum_Y P(X, Y),$$

kar označuje seštevanje preko vseh pojavitev  $Y$ . Operacijo zato navajamo kot projekcijo ali marginalizacijo, včasih tudi kot "marginalizacija  $Y$ " iz  $P(X, Y)$ .

### Verižno pravilo

Za verjetnostno porazdelitev  $P(X)$  preko množice spremenljivk  $X = \{X_1, \dots, X_n\}$  lahko v ponavljanju uporabimo osnovno pravilo verjetnosti in verjetnost razstavimo v produkte pogojnih verjetnostnih porazdelitev:

$$\begin{aligned}
 P(X) &= P(X_1 | X_2, \dots, X_n)P(X_2, \dots, X_n) \\
 &= P(X_1 | X_2, \dots, X_n)P(X_2 | X_3, \dots, P(X_n) \dots P(X_{n-1} | P_n)P(X_n) \\
 &= \prod_{i=1}^n P(X_i | X_{i+1}, \dots, X_n)
 \end{aligned} \tag{3.4}$$

Pri tem velja, da je aktualna verjetnostna porazdelitev, sestavljena iz posameznih razčlenjenih faktorjev, določena z vrstnim redom, v katerem izberemo glavo spremenljivk pogojnih porazdelitev. Zatorej obstaja  $n$  različnih razčlenitev (faktorizacij)  $P(X)$  in vsaki razčlenitvi ustreza unikaten *DAG*. Vsi možni grafi *DAG*, ki tako nastanejo, so polni grafi in so zato med seboj ekvivalentni, glede na lastnosti odvisnosti in neodvisnosti, saj ne vsebujejo neodvisnih povezav.

Predpostavimo, da je  $G$  *DAG*, ki pravilno predstavlja lastnosti pogojne odvisnosti in neodvisnosti porazdelitve  $P$  in da se vrstni red, v katerem izbiramo glavo pogojnih porazdelitev, nanaša na topološki red v grafu  $X_{v_1}, \dots, X_{v_n}$ , kjer je  $G : pa(v_i \subseteq pa(v_i) \dots pa(v_{i-1}))$  za vsak  $i = 1 \dots n$  (starši vsake spremenljivke so izbrani, pred samo spremenljivko). Vsaka spremenljivka v repu ima vedno izbrane starše, kar potem sledi iz kriterija d-ločitve ali Markovega kriterija, da za katerokoli vozlišče  $v$  v *DAG* velja  $v \perp_G nd(v) | pa(v)$ , pri čemer z  $nd(v)$  označujemo množico nenaslednikov  $v$  in z  $pa(v)$  množico staršev. Ker je  $G$  pravilen iz zapisanega sledi  $X_v \perp \perp_P nd(X_v) | pa(X_v)$ . Vsak  $P(X_{v_i} | X_{v_1} \dots X_{v_i})$  lahko skrajšamo in zapišemo kot  $P(X_{v_i} | X_{pa_{v_i}})$ . Produkt v enačbi X se potem skrajša v verižno pravilo, ki je temeljni gradnik v verjetnostnih mrežah:

$$P(X_v) = \prod_{i=1}^n P(X_{v_i} | X_{pa_{v_i}}) \tag{3.5}$$

### 3.2.5 Osnovni princip in Bayesovo pravilo

Drug temeljni gradnik verjetnostnega računa v verjetnostnih mrežah je Bayesov obrazec. Bayesov obrazec predstavlja osnovo verjetnostnega računa, izpeljemo ga lahko iz poslošenega aksioma 3.6 za skupno verjetnost (verjetnost produkta) spremenljivke  $X$  in  $Y$ , in sicer:

$$P(X, Y) = P(X | Y)P(Y) = P(Y | X)P(X) \quad (3.6)$$

Bayesov obrazec sledi iz pravila verjetnostnega računa, in sicer

$$P(Y | X) = \frac{P(X | Y)P(Y)}{P(X)} \quad (3.7)$$

Z uporabo aksioma 3.6 in pravila popolne verjetnosti, 3.7 lahko zapišemo kot:

$$P(Y | X) = \frac{P(X | Y)P(Y)}{P(X | Y = y_1)P(Y = y_1) + \dots + P(X | Y = y_n)P(Y = y_n)} \quad (3.8)$$

Števec v enačbi 3.8 lahko izpeljemo iz imenovalca v XX. Ker je števec očitno enak za vse vrednosti spremenljivke  $Y$ , pogosto Bayesov obrazec zapišemo kot:

$$P(Y | X) \propto P(X | Y)P(Y), \quad (3.9)$$

kar se prebere kot " $P(X | Y)$  je sorazmerno  $P(X | Y)P(Y)$ ". Operacijo deljenja pri tem definiramo kot  $0/0 = 0$  za vsak  $P(x_i = \sum_j P(x_i | y_j)P(y_j))$ , zato deljenje z nič ne predstavlja težave.

#### Interpretacija Bayesovega pravila

Zaradi pomembnosti Bayesovega pravila za sklepanje v Bayesovem verjetnostnem računu v nadaljevanju razložimo, kako lahko Bayesov obrazec razumemo. Predpostavimo, da imamo dve (možnosti, množici) spremenljivk  $X$  in  $Y$ , model  $P(X, Y)$ , podan v razčlenjeni obliki  $P(X | Y)P(Y)$ , in da opazujemo  $X = x$ . V takem primeru bi želeli po navadi izračunati  $P(Y | x)$ .

Apriorna porazdelitev  $P(Y)$  izraža naše vnaprejšnje znanje o verjetnosti  $Y$  in  $P(Y | x)$ , izraža naše znanje o verjetnosti  $Y$  z vidika  $X = x$  (ko se zgodi dogodek x). Bayesov obrazec nam potem pove, kako dobimo posteriorno verjetnostno porazdelitev z množenjem  $P(Y)$  in razmerjem  $P(x | Y)/P(x)$ , znanem kot normalizirano verjetje  $Y$  pri po-

## 92POGLAVJE 3. TEORIJA VERJETNOSTNIH MREŽ IN VERJETNOSTNI RAČUN

danem  $x$ . Ker je  $P(x)$  konstanta za vsak  $y \in \text{dom}(Y)$ , dobimo:

$$P(Y | x) \propto P(Y)P(x | Y) \quad (3.10)$$

$P(Y | x) = L(Y | x)$  imenujemo verjetje (*likelihood*)  $Y$  pri danem  $x$ . Sledi

$$P(Y | x) \propto P(Y)L(x | Y) \quad (3.11)$$

ali v splošnem

$$\text{posteriorna} \propto \text{apriorna} \times \text{verjetje} \quad (3.12)$$

**Primer:** Za primer uporabe Bayesovega obrazca vzemimo klasični primer diagnoze pljučnice, kjer imamo vzročno-posledično relacijo. Označimo dogodke kot:

- A: kašelj
- B: pljučnica

Pri tem lahko  $\text{dom}(A)$  in  $\text{dom}(B)$  zapišemo kot booleanove spremenljivke:

- $\text{dom}(A) \in \{\text{da, ne}\}$   $A \in \text{In}B$
- $\text{dom}(B) \in \{\text{da, ne}\}$

Iz splošno znanih dejstev vemo, kakšna je verjetnost v populaciji, da bolnik zboli za pljučnico  $P(B)$  (apriorna verjetnost). Vemo tudi, kakšna je verjetnost simptoma pri diagnozi, se pravi verjetnost kašlja pri pljučnici, formalno zapisano  $P(A | B)$  (verjetje). S pomočjo Bayesovega obrazca lahko izračunamo, kakšna je verjetnost diagnoze pri simptomu, torej, kakšna je verjetnost, da ima bolnik pljučnico zaradi kašlja  $P(B | A)$ .

V konceptu strojnega učenja igra Bayesovo pravilo pomembno vlogo. Vzemimo na primer, apriorno porazdelitev  $P(M)$  za naključno spremenljivko  $M$ , ki izraža množico možnih modelov. Za katero koli vrednost  $d$  spremenljivke  $D$ , ki izraža podatke, količina  $P(d | M)$  - razumljena kot funkcija  $M$  - predstavlja funkcijo verjetja za modele v množici  $M$  pri vzorcu  $d$ . Posteriorna porazdelitev za  $M$  pri podanem vzorcu  $d$  je potem

$$P(M | d) \propto P(M)P(d | M),$$

kar podaja množico metrik prilagajanja (*set of goodness-of-fit measures*) za model.

## Poglavlje 4

# Bayesove verjetnostne mreže

V prejšnjih dveh poglavjih smo si ogledali nekatere teoretične osnove iz teorije grafov in verjetnostnega računa. Kot so zapisali, sta obe domeni združeni v formalizmu verjetnostnih mrež, saj so verjetnostne mreže grafični modeli (vzročnih) interakcij med množico spremenljivk, kjer so spremenljivke predstavljene v obliki vozlišč grafa. Interakcije med njimi so zapisane z medsebojnimi povezami, kjer odvisnosti med posameznimi spremenljivkami označujejo usmerjene povezave. Za modele verjetnostnih mrež se uporabljajo tako imenovani usmerjeni aciklični grafi *DAG*. Da strukturo mreže lahko zapišemo v obliki grafov *DAG*, izhaja iz osnovnih aksiomov verjetnostnega računa, ki vodijo do rekurzivne razstavitev (faktorizacije) porazdelitve verjetnosti produkta v produkt pogojnih verjetnosti nižje dimenzionalnih porazdelitev.

S tem smo opisali kvalitativen in kvantitativen vidik verjetnostnih mrež. V nadaljevanju bomo oba vidika združili v opis modela Bayesovih mrež iz katerega izhaja naše raziskovalno delo in aplikacija teoretičnega modela v prakso pri simulaciji scenarijev z razvito metodologijo CASGen.

### 4.1 Modeliranje Bayesovih verjetnostnih mrež

Bayesove mreža (BN) predstavlja model multivariantne verjetnostne porazdelitve produkta preko množice naključnih spremenljivk. Sestavljena je iz grafične strukture  $G$  in množice njenih pogojnih porazdelitev  $P$ . BN predstavljajo vzročno - posledične strukture [9], z zelo pomembno možnostjo vpeljave gotovost (evidence) [38]. Domačo literaturo na področju Bayesovih mrež najdemo v poglavjih avtorja Kononenka [36].

### Grafična struktura

Kvalitativni del BN je predstavljen z njeno strukturo. BN je usmerjen aciklični graf *DAG*, kjer predstavljajo vozlišča množico naključnih spremenljivk  $X$ , predstavljenih z vozlišči  $V = \{v_1, \dots, v_n\}$ , pri čemer je  $n > 1$ , povezave med njimi  $E \subseteq V \times V$  pa vpliv med posameznimi naključnimi spremenljivkami. Vozlišča BN predstavljajo diskretne naključne spremenljivke. Če je povezava usmerjena iz  $v_1$  na  $v_2$ , potem je  $v_1$  starš in  $v_2$  otrok. Starši imajo neposreden vpliv na otroke. Zraven tega ima vsako vozlišče svojo lokalno verjetnostno porazdelitev. Vpliv med posameznimi naključnimi spremenljivkami določajo predpostavke o pogojni odvisnosti ali neodvisnosti, glede na kriterij d-ločitve. Velja, da je spremenljivka  $v_i$  odvisna od njenih staršev in otrok v usmerjenem grafu, a je pogojno neodvisna od katerih koli ne-naslednikov pri njenih podanih starših; lastnost je poznana kot Markov kriterij.

Omenjene komponente skupaj tvorijo skupno verjetnostno porazdelitev (verjetnostno porazdelitev produkta - *joint probability distribution JPD*) BN. Skupna verjetnostna porazdelitev na  $X$  sledi iz uporabe enačbe 4.1 na strukturi mreže. Starši  $X_v$  so pri tem označeni z  $X_{Pa(v)}$

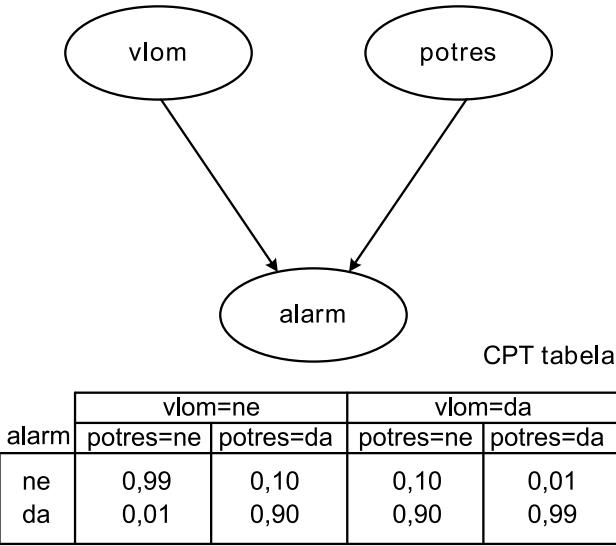
$$P(X) = \prod_{v \in V} P(X_v | X_{pa(v)}). \quad (4.1)$$

$P(X_v | X_{pa(v)})$  se imenuje lokalna verjetnostna porazdelitev (*local probability distribution LPD*). Proces razstavljanja skupne verjetnostne porazdelitve v LPD pa faktorizacija, kar omogoča učinkovito predstavitev hitrega sklepanja. Ta lastnost BN tvori glaven do-prinos pri uspehu uporabe BN.

### Pogojne verjetnostne tabele

Kvalitativni del BN je predstavljen z dodelitvami pogojnih verjetnostnih porazdelitev za posamezno vozlišče. Vsako vozlišče v BN vsebuje pogojno verjetnostno tabelo (*conditional probability table CPT*), ki definira pogojno verjetnostno porazdelitev (*conditional probability distribution CPD*) predstavljenih diskretnih naključnih spremenljivk. CPT za primer *Vloma ali Potresa* je predstavljena na shemi 4.1.

Potencialni problem pri uporabi CPT za definiranje pogojnih verjetnostnih porazdelitev



Slika 4.1: Pogojna verjetnostna tabela - CPT.

je njihova velikost. Velikost CPT za spremenljivko  $x_i \in X$  je odvisna od števila njenih stanj  $r_i$  in števila stanj  $r_j$  vsakega očeta  $x_j \in Pa(x_i)$ :

$$size(CPT)_i = r_i \prod_{r_j=X_j \in Pa(x_i)} r_j \quad (4.2)$$

Če je  $r_j$  enak za vse starše, potem se enačba poenostavi:

$$size(CPT)_i = r_i(r_j)^n, \quad (4.3)$$

kjer je  $n$  število staršev. Kot lahko razberemo, velikost CPT narašča eksponentno s številom staršev. To je pomembno pri načrtovanju BN, saj je dobro obdržati minimalno število staršev pri posameznem vozlišču.

## Inferenca

Inferenca je proces izračuna verjetnosti ene ali več spremenljivk v  $X$  pri podani gotovosti  $\epsilon$ . Pri tem je gotovost  $\epsilon$  izražena kot postavitev neke spremenljivke na določeno vrednost v BN, kar pomeni na kratko izračun  $P(X | \epsilon)$ . Za inferenco sta potrebni dve pravili: Bayesov teorem in izračun robne ali marginalne verjetnosti, poznan tudi kot razširitevno pravilo. Inferenco najlažje razložimo na primeru. Shema predstavlja primer "Apple Jack", ki je sestavljen iz treh vozlišč. "Apple Jack" je pridelovalec, ki v sadovnjaku skrbi za svoje

jablane. Pri tem opazuje pojav bolezni (vozlišče Sick) in pojave suše, o katerem spremišča vremenska poročila (vozlišče Dry). Vozlišče L predstavlja izpadanje listov na jablanah (vozlišče Losses), ki je odvisno od bolezni in suše. "Apple Jacka" zanima, kakšna je verjetnost, da je listje odpadlo zaradi suše.  $D$  in  $S$  se imenujeta povpraševalni spremenljivki (*query variable*) in  $L$  opazovana spremenljivka (*evidence variable*). Opazovalec torej želi vedeti, kakšna je verjetnost  $L = \text{true}$  pri podanem  $D = \text{true}$ , kar lahko izračunamo kot

$$p(x | e) = p(d | l) \frac{p(l | d)p(d)}{p(l)} \quad (4.4)$$

Izraz potrebuje nekaj preoblikovanja, da lahko vstavimo verjetnosti v CPT tabelah:

$$p(d | l) \frac{p(l | d)p(d)}{p(l)} = \frac{\sum_D p(l | s, d)p(d)p(s)}{\sum_S \sum_D p(l | s, d)p(s)p(d)} \quad (4.5)$$

Pri vstavljenih številkah dobimo:

$$\frac{(0.85 \cdot 0.9 + 0.95 \cdot 0.1) \cdot 0.1}{0.02 \cdot 0.9 + 0.85 \cdot 0.1 \cdot 0.9 + 0.9 \cdot 0.9 \cdot 0.1 + 0.95 \cdot 0.1 \cdot 0.1} = \frac{0.086}{0.1832} \quad (4.6)$$

Verjetnost za  $D$  je *true*, pri tem, da smo seznanjeni z  $L$ , je enaka približno X. Da je  $D$  enaka *false* pri  $L$  dobimo z  $1 - p(s) \approx X$ . Kot lahko vidimo iz 4.4, je imenovalec precej zapleten, vendar konstanten, ne glede na vrednost spremenljivke  $S$ . V osnovi je imenovalec normalizacija konstante, ki je potrebna, da se različne vrednosti v  $S$  seštejejo v 1. Zaradi tega se pogosto predstavi normalizacijski faktor  $\alpha$ :

$$\alpha p(l | d)p(d) = \alpha \left( \sum_D p(l | s, d)p(d)p(s) \right), \quad (4.7)$$

kar izračun spremeni v:

$$D = \text{false} : \alpha(0.02 \cdot 0.9 + 0.85 \cdot 0.1) \cdot 0.9 \quad (4.8)$$

$$D = \text{true} : \alpha(0.9 \cdot 0.9 + 0.95 \cdot 0.1) \cdot 0.1 \quad (4.9)$$

$\alpha(X, Y)$  rezultira v normaliziranih verjetnostih ( $\approx X \approx Y$ ). Kljub tej poenostavitvi originalnega izračuna je natančna inferenca velikih in gosto povezanih mrež zelo kompleksna. Pravzaprav je NP težek problem [65]. Zaradi tega so potrebni aproksimacijski inferenčni algoritmi, v splošnem so to algoritmi z naključnim vzorčenjem, znani tudi kot Monte Carlo.



Slika 4.2: Proces gradnje Bayesove mreže

Za natančno inferenco se uporabljajo algoritmi eliminacije spremenljivk (*variable elimination*) ali razreza drevesa (*junction tree*) algoritmi. Algoritmi eliminacije spremenljivk so algoritmi, ki uporabljajo inferenco ob posebnem dobro izbranem vrstnem redu eliminiranja spremenljivk, kar naredi izračun učinkovitejši. Algoritmi razreza drevesa pretvorijo BN v razrezano drevo, kjer se potem lahko izvede algoritem za eliminacijo [65]. Seveda je pretvorba lahko zahtevna in ni primerna za vsak problem pri BN.

Tretja tehnika, ki zmanjšuje kompleksnost izračuna inference, se imenuje relevantno sklepanje (*relevant reasoning*). To je korak preprocesiranja, ki razšče strukturo BN in njene numerične lastnosti in potem določi, kateri deli BN so tisti, za katere je potreben izračun. Ta tehnika zmanjša velikost in povezanost BN z izločitvijo vozlišč, ki so računsko nerelativna, na tista, ki so interesantna. Več podrobnosti in natančna razlaga o aproksimacijskih algoritmih v različnih tipih Bayesovih mrež je na voljo v literaturi [65].

#### 4.1.1 Gradnja Bayesove mreže

Model Bayesove mreže lahko zgradimo ročno s pomočjo znanja ekspertov ali s pomočjo podatkov, ki so na voljo, glede na domeno problema. V osnovi uporabljamo v realnosti en ali drug način, lahko pa tudi kombinacijo obeh, kar lahko nadgradi kvaliteto izdelanega modela. Na shemi 4.2 je prikazan proces gradnje Bayesove mreže na določeni domeni.

V nadaljevanju natančneje predstavljamo oba načina s podrobnostmi, kar predstavlja osnovo, iz katere izhajata raziskovalna osnova in izdelana metodologija CASGen doktorskega dela.

Ko se srečujemo s problemom na določeni domeni, je najprej potrebno razmisiliti, ali so BN dobra izbira kot orodje za reševanje problema. Glede na naravo problema, so mreže lahko intuitivna metodologija za modeliranje, lahko pa tudi ne. V naslednjih alinejah bomo opisali kriterij, ki nam omogoča identifikacijo BN kot primerrega orodja.

Ker so parametri modela pogojeni s strukturo modela, se gradnja modela vedno začne v dveh stopnjah: najprej je treba identificirati spremenljivke, funkcionalne in informacijske odvisnosti med njimi, ki zagotavljajo kvalitativen del modela. Druga stopnja je interaktivni proces, ki vključuje testiranje spremenljivk in odvisnih ter neodvisnih kriterijev, preverjanje usmerjenih povezav od koder se nastavijo vrednosti posameznih parametrov.

Ročna gradnja verjetnostne mreže (BN) je zahtevno laboratorijsko delo, ki zahteva veliko sposobnosti, kreativnosti in komunikacije s strokovnjakom na domenskem področju. Pri tem je treba poudariti dva ključna problema: identifikacija relevantnih spremenljivk in identifikacija povezav med njimi.

Za uporabo verjetnostnih mrež (BN) obstaja veliko dobrih vzrokov, ki vključujejo koherentno matematično formo za obravnavo nedoločenosti, avtomatsko konstrukcijo in adaptacijo modela, glede na podatke, intuitivno in kompaktno predstavitev vzročno-posledičnih relacij in pogojno odvisnih in neodvisnih relacij in zmožnost podpore velikega spektra analiz, vključno s konfliktno analizo, analizo senzitivnosti in informacijsko analizo. V nadaljevanju opisujemo kriterij za uporabo BN, kot orodja pri reševanju problemov.

#### **4.1.2 Kriteriji za uporabo verjetnostnih mrež**

Glede na model in lastnosti verjetnostnih mrež (BN) obstajajo problemi, ki jih lahko modeliramo z BN. V splošnem so mreže lahko dobra izbira za modeliranje, če definicija problema vključuje element nedoločenosti in izraža željo po pričakovanem maksimalnem izkoristku. Za uporabo verjetnostnih mrež pri reševanju problemov lahko posebej omenimo naslednji kriterij:

- Dobro definirane spremenljivke: na primer problemi, kjer so spremenljivke jasne, kot je domena medicine (glavobol, vročina...), manj pride v poštev pri spremenljivkah, ki določajo, ali je nekomu všeč določena slika ali ne
- Problemska domena z vzročno-posledičnimi relacijami: v splošnem mora biti na voljo znanje, iz katerega lahko potegnemo jasne vzročno-posledične relacije. Velja

tudi, da se le-te ne spreminja v času in so statične. Če se časovna komponenta pojavi v problemu, moramo model pravilno redefinirati v določeni časovni rezini.

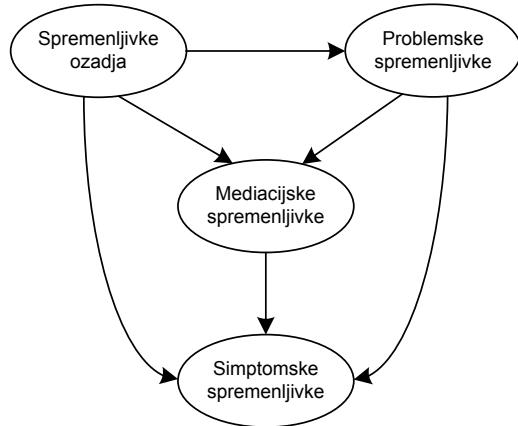
- Nedoločenost povezana z vzročno posledičnimi relacijami: če so vse vzročno posledične relacije natančno določene (pogojne verjetnosti so 0 ali 1), potem verjetno obstajajo boljši modeli za reševanje problema. Vendar v večini realnih primerov temu ni tako.
- Ponavljačoče reševanje problema: pogosto se trud, vložen v izdelavo modela povrne, če je narava problema ponavljača. Na primer, zdravnik, ki diagnosticira bolezni dihal, internetno podjetje, ki razvršča svoje kupce, banke, ki se odločajo za odobritev kreditov. Vse to so problemi, kjer se spreminja le vrednosti opazovanih spremenljivk, medtem ko vzročno posledične relacije in mehanizem ostajajo enaki.
- Maksimalna pričakovana korist: za verjetnostne mreže so problemi, ki vsebujejo element odločitve pri maksimiziranju koristi odločitve, naravna izbira.

Pri tem seveda obstaja kar nekaj domen, kjer BN ali verjetnostne mreže v splošnem niso najprimernejše kot paradigma modeliranja. Na primer, nekateri problemi pri prepoznavanju vzorcev, kot je prepoznavanje prstnih odtisov, kjer ni dobro razumljenega mehanizma v ozadju vzorca, ali pri problemih, kjer se vzročno-posledične relacije spreminja skozi čas (kjer ni fiksne strukture mreže) in je zato treba poseči po drugih modelih.

#### 4.1.3 Identifikacija in tipi spremenljivk

Množica spremenljivk v verjetnostni mreži predstavlja temelj modela. V osnovi imamo dve vrsti spremenljivk v mrežah, odločitvene in naključne. Naključne spremenljivke izključno v Bayesovih mrežah, medtem ko odločitvene uporabljamo v njihovi razširjeni različici. Od naključnih se razlikujejo po kontroli, saj z njimi upravlja uporabnik in kot take predstavljajo njegove odločitve. V splošnem so na voljo diskretne in zvezne spremenljivke. Zaradi narave problema v doktorski nalogi posvečamo pozornost predvsem diskretnim.

Pri tem morajo diskretne spremenljivke v mreži predstavljati medsebojno izključljive dogodke. Značilno za verjetnostne mreže je, da množica spremenljivk predstavlja unikatno množico dogodkov. To pomeni, da vrednost ali stanje določene spremenljivke ne smeta biti medsebojno izključljiva z vednostjo katere druge spremenljivke. Če imamo na primer dve stanji spremenljivk  $A$  in  $B$ , ki se medsebojno izključujeta, bomo po vsej verjetnosti



Slika 4.3: Značilna vzročna struktura verjetnostne mreže.

spremenljivki morali združiti v eno samo  $AB$  kot množico vseh njunih stanj. Tak test pri identifikaciji spremenljivk imenujemo *unikatni test*.

Čeprav po navadi potrebujemo spremenljivke, ki zadostijo testu unikatnosti, dovoljujemo, da se določena vrednost spremenljivke nastavi v odvisnosti od drugih spremenljivk. Za izboljšanje modeliranja in računske zahtevnosti v mreži zato pogosto uporabljamo tako imenovane omejitvene spremenljivke (*constraint variables*), ki nam lahko pomagajo v mnogih situacijah. Njihova odvisnost temelji samo na starših, zato lahko zmanjšajo število pogojnih odvisnosti, ki morajo biti specificirane ali prisilijo omejitve na določene kombinacije stanj podmnožic spremenljivk.

### Tipi spremenljivk

V procesu identifikacije spremenljivk poznamo štiri tipe spremenljivk [65]:

**Problemske spremenljivke** so tiste spremenljivke, ki nas zanimajo in za katere želimo izračunati posteriorno odvisnost, glede na podana opazovanja informacijskih spremenljivk (naslednji tip). Po navadi problemskih spremenljivk ne moremo opazovati, saj drugače sploh ne bi bilo smiselnega graditi verjetnostne mreže.

**Informacijske spremenljivke** so spremenljivke, za katere so lahko na voljo določeni podatki, na podlagi katerih jih opazujemo, in lahko doprinesejo pomembno informacijo pri reševanju problema. Dve podkategoriji teh spremenljivk so:

**Simptomske spremenljivke** so pravzaprav posledice, ki se lahko pojavijo po pojavitvi problema. Z drugimi besedami so to problemske spremenljivke, ki imajo posledičen vpliv na njihove simptome. Po navadi so te naslednice spremenljivk v ozadju in problemskih spremenljivk. V medicini so take spremenljivke na primer simptomi z različnimi informacijami, kot so krvni tlak, vročina, glavobol, teža itn.

**Mediacijske spremenljivke** so neopazovane spremenljivke, za katere nimamo interesa v posteriornih verjetnostih, a igrajo pomembno vlogo za dosego pravilne pogojne odvisnosti in neodvisnosti. Te spremenljivke imajo starše pogosto tipa problemskih in spremenljivk iz ozadja, medtem ko so njihovi otroci simptomske spremenljivke.

Tabela 4.1 predstavlja tipično vzročno odvisne relacije za različne tipe našetih spremenljivk.

Tip	Posledičnost od
Problemske	ni
Spremenljivke ozadja	ni
Mediacijske	spremenljivke ozadja in problemske spremenljivke
Simtomske	ozadne, problemske in mediacijske spremenljivke

Tabela 4.1: Vzročno odvisne relacije različnih topov spremenljivk.

#### 4.1.4 Gradnja strukture

Pri podani množici identificiranih spremenljivk za podano problemsko domeno, v naslednjem koraku gradimo strukturo mreže, za katero moramo identificirati in preveriti relacije med posameznimi vozlišči. Kot smo že zapisali, v tem primeru upoštevamo vzročnostno perspektivo pri gradnji mreže, ki lahko precej izboljša jasnost in pravilnost modela, s pravilnimi predstavitvami odvisnosti in neodvisnosti. Pri tem je vzročna perspektiva nujna pri gradnji diagramov vpliva.

Kot smo zapisali v 4.1.3, imamo štiri kategorije spremenljivk: (i) spremenljivke ozadja (informacijske) spremenljivke, (ii) problemske spremenljivke, (iii) mediacijske spremenljivke in (iv) simptomske (informacijske) spremenljivke. Različni tipi spremenljivk se posledično povezujejo z določenimi tipi. Z upoštevanjem tega dobimo tipično vzročno strukturo verjetnostne mreže, kot je prikazano na shemi 4.3:

## 4.2 Strojno učenje - učenje Bayesove mreže iz podatkov

Na področju medicine se iz leta v leto zbira več podatkov, ki obsegajo dolga obdobja. Takšne podatkovne zbirke po navadi vsebujejo visoko vrednostne relacije, ki se skrivajo med zbranimi podatki. Če je na voljo dobra podatkovna zbirka, lahko na podlagi le-te izdelamo kvalitetno BN brez načrtovanja ekspertov.

Za takšno učenje morajo zbrani podatki ustrezati različnim lastnostim. Med prvimi morajo podati biti zbrani z veliko pozornostjo. Vrednosti, ki lahko nastanejo v podatkovni zbirki kot posledica različnih strategij zbiranja podatkov za ta namen, niso želene, saj niso v skladu z namenom gradnje modela BN. Prav tako se morajo vsi zbrani parametri iz zbirke pojavit v BN ali morajo vsaj zagotavljati preprosto transformacijo v spremenljivke BN.

Podatkovna zbirka mora zagotavljati tudi dovolj veliko število vzorcev za zanesljivo identifikacijo verjetnostnih relacij med parametri. Zraven teh splošnih parametrov mora podatkovna zbirka ustrezati tudi nekaj implicitnim lastnostim, ki jih zahtevajo metode strojnega učenja. Ena predpostavka je, da so vrednosti zbrane za vsak posamezen parameter in da ni manjkajočih vrednosti. Na žalost v realnem okolju to ne drži, zato se v teh primerih uporablja različne tehnike za premostitev manjkajočih vrednosti. V tem primeru imamo več možnih rešitev. Manjkajoče vrednosti lahko obidemo in vzorce s takimi lastnostmi zbrisemo iz podatkovne zbirke, lahko jih tudi nadomestimo s pomočjo strokovnjakov ali glede na (grobe) verjetnostne ocene porazdelitev. Večina algoritmov strojnega učenja tudi domneva, da so vzorci v podatkovni zbirki med seboj neodvisni, da so torej vrednosti posameznega vzorca neodvisne od njegovega predhodnika.

Učenje BN iz podatkov vsebuje nalogu učenja strukture mreže, torej identifikacije grafične strukture in učenje parametrov, to je ocenitev pogojnih verjetnostnih porazdelitev, ki so povezane z usmerjenim acikličnim grafom. V veliko učnih algoritmih sta ti dve nalogi izvedeni simultano, zato ju posledično težje razlikujemo.

V nadaljevanju si bomo pogledali nekaj algoritmov, ki se uporabljajo za obe omenjeni nalogi.

### 4.2.1 Učenje strukture Bayesove mreže

Za učenje strukture Bayesove mreže v osnovi ločujemo med dvema splošnima pristopoma:

1. Na osnovi omejitev (*constraint-based*): pristop se začne s polno povezanim *DAG* in odstranjuje povezave, če se med podatki izmerijo določene pogojne neodvisnosti.
2. Iskalno-nagrajevalne (*search and score*): postopek iskanja se naredi čez vse možne strukture *DAG*. Vrne se ali najboljši *DAG* ali množica modelov, ki ustreza rešitvi; ker je število možnih *DAG* v eksponentni odvisnosti od števila vozlišč v mreži, se predpostavijo omejitve in tako uporablajo hevristične metode, na primer lokalni iskalni algoritmi, kot so požrešno plezanje po hribu (*greedy hill climbing*) ali globalni iskalni algoritmi, na primer Markov Chain Monte Carlo.

Drugi pristop učenja strukture je bolj priljubljen. V nadaljevanju bomo tako predstavili dobro poznani algoritem K2 in intuitivno omenili ostale metode za gradnjo strukture mreže, ki jih najdemo v literaturi.

### **Algoritem K2**

Eden izmed prvih algoritmov za učenje BN iz podatkov je algoritem K2 [30]. K2 je požrešen hevristični algoritem, ki išče takšen *DAG*, katerega verjetje (likelihood) pri-dobi maksimalno vrednost in najbolje razloži podatke. Išče torej usmerjeni graf  $G^*$ , ki maksimizira verjetnostno porazdelitev produkta mreže  $P(G, D)$  preko vseh možnih usmerjenih grafov  $G$ . S podano topološko razvrščenostjo naključnih spremenljivk algoritem gradi za vsako spremenljivko  $v_i$  optimalno množico staršev  $Pa(v_i)$ . Začne s predpostavko, da je množica staršev prazna, in potem iterativno dodaja množici tistega starša, ki največ doprinese k verjetnosti nastale strukture; z dodajanjem staršev konča, ko nobeno vozlišče ne doprinese povečanja verjetnosti  $P(G, D)$ .

Naj bo  $V$  množica  $n$  diskretnih spremenljivk, kjer spremenljivka  $V_i \in V$  vsebuje  $r_i$  možnih vrednosti  $v_1^i, \dots, v_{r_i}^i$ . Naj bo  $D$  podatkovna zbirka z  $m$  primeri (vzorci), kjer vsak vzorec vsebuje vrednost za vsako spremenljivko v  $V$ . Naj  $G$  označuje BN strukturo, ki vsebuje le spremenljivke  $V$ , in naj bo  $P$  pripadajoča množica pogojnih verjetnostnih porazdelitev. Vsako vozlišče  $v_i \in V(G)$  vsebuje množico staršev  $Pa(v_i)$ . Naj  $w_{ij}$  določa jto unikatno instanco  $Pa(v_i)$ , glede na  $D$ . Predpostavimo, da je  $q_i$  takih instanc  $Pa(v_i)$ . Definiramo  $N_{ijk}$ , ki predstavlja število primerov  $D$ , v katerih ima  $v_i$  vrednost  $v_k^i$  in množico staršev  $Pa(v_i)$ , zgrajeno iz  $w_{ij}$ . Naj bo  $N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$ . Če podamo model BN, ki predpostavlja, da se vsi vzorci v  $D$  pojavijo neodvisno in da imamo uniformno

diskretno verjetnostno porazdelitev  $P$ , potem sledi:

$$P(G, D) = P(G) \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \prod_{k=1}^{r_i} N_{ijk}! \quad (4.10)$$

K2 algoritmom predpostavlja, da je vrstni red spremenljivk na voljo in da so vse strukture enako možne. Za vsako vozlišče  $v_i$  potem išče množico staršev, ki maksimizira naslednjo funkcijo:

$$g(i, Pa(v_i)) = \prod_{j=1}^{q_i} \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \prod_{k=1}^{r_i} N_{ijk}! \quad (4.11)$$

K2 algoritmom je primer požrešne iskalne metode. Raziskovalci so podobne požrešne metode uporabljali tudi pri klasifikacijskih sistemih, na primer za gradnjo odločitvenih dreves [65] (Quinlan, 1986) in izbiro spremenljivk [65] (James, 1985).

## Ostali algoritmi

Podobne hevristične metode, ki se uporablajo v ta namen pri iskanju  $DAG$ , so na primer uporaba principa minimalnega opisa (*minimum description length MDL*) in uporaba genetskih algoritmov [65].

Drugi način učenja BN iz podatkov je uporaba analize odvisnosti [65]. BN v osnovi modelira zbirko pogojno odvisnih in neodvisnih stavkov preko Markovega kriterija. Z analizo podatkovne zbirke se tako lahko izluščijo odvisnosti in neodvisnosti med različnimi spremenljivkami, na primer z uporabo statističnih testov, ki so potem transformirani v grafično strukturo. Primer takšnega algoritma je informacijsko teoretični algoritmom avtorja Chenga in sodelavcev [65]. Algoritom ima tri stopnje, ki so poimenovane načrtovanje (*drafting*), debeljenje (*thickening*) in tanjšanje (*thining*). V prvi fazi algoritom iz podatkov izračuna medsebojno informacijsko odvisnost za vsak par spremenljivk (*mutual information*). Na tej podlagi tega konstruira grobi usmerjeni graf (digraf). V drugi fazi doda povezave med posamezne pare, če spremenljivke med seboj niso pogojno neodvisne pri določeni pogojni množici spremenljivk. V zadnji fazi vsako pridobljeno povezavo preveri z uporabo pogojnih neodvisnih testov in jo odstrani, če se izkaže, da sta povezani dve spremenljivki pogojno neodvisni.

### 4.2.2 Učenje parametrov Bayesove mreže

Po definirani strukturi *DAG* za Bayesovo mrežo, ki smo jo pridobili s pomočjo strojnega učenja ali ročne gradnje eksperta, se lahko izračunajo potrebne pogojne verjetnostne porazdelitve za model. Naj bo  $X = \{X_1, \dots, X_n\}$  množica spremenljivk in  $S_m$  fiksna struktura Bayesove mreže z vozlišči, ki predstavljajo te spremenljivke. Naj bo  $\Theta_m$  naključna spremenljivka z zalogo vrednosti  $\theta_m$ , vsaka izmed vrednosti odraža množico realnih števil pogojnih verjetnostnih porazdelitev, potrebnih za  $S_m$ . Predpostavimo, da imamo sedaj surove podatke v obliki vzorcev (primerov), pri čemer so za vsak vzorec znane vse spremenljivke v podatkih. Tak vzorec imenujemo naključni vzorec  $D = \{x_1, \dots, x_N\}$ , kjer  $x_k$  predstavlja instanco spremenljivke  $X$ . Naša naloga je izpeljati vrednosti v  $\theta_m$  tako, da bodo ustrezno razložile podatke, torej podale pogojne verjetnostne porazdelitve, potrebne za Bayesovo mrežo. Klasična metoda za pridobitev teh vrednosti se imenuje maksimalna ocena verjetja (*Maximum Likelihood Estimation - MLE*). Primerjava različnih algoritmov učenja mreže je podana na primeru organizacije službe nujne medicinske pomoči (SNMP) [84].

#### Maksimalna ocena verjetja

Maksimalna ocena verjetja *MLE* vsebuje izbire parametrov iz  $\theta_m$ , tako da maksimizirajo verjetje posameznega vzorca  $P(D | S_m, \theta_m)$ :

$$\theta_{m*} = \operatorname{argmax}_{\theta_m} P(D | S_m, \theta_m) = \operatorname{argmax}_{\theta_m} \prod_k P(x^k | S_m, \theta_m) \quad (4.12)$$

kjer se predpostavi, da je podan model  $S_m$  in  $\theta_m$ , resničen z vzorci, ki so med seboj neodvisni in identično porazdeljeni. Druga pomembna predpostavka je, da nimamo manjkajočih podatkov.

Verjetnosti posameznih vzorcev se lahko izrazijo iz pogojnih verjetnostnih porazdelitev za  $S_m$ , ki je določena z  $\theta_m$ :

$$P(x_k | S_m, \theta_m) = \prod_i P(x_i^k | Pa_i^k, \theta_{m,i}) \quad (4.13)$$

Maksimalno verjetje se lahko optimizira in razčleni v posamezna verjetja z optimizacijo množice parametrov  $\theta_{m,i}$ , ki predstavlja pogojne verjetnostne porazdelitve, glede

na posamezne spremenljivke  $X_i$ :

$$\theta_{m,i}^* = \operatorname{argmax}_{\theta_{m,i}} \prod P(x_i^k | Pa_i^k, \theta_{m,i}) \quad (4.14)$$

Če je  $X_i$  binarna naključna spremenljivka ( $\operatorname{dom}(X_i) = \text{true}, \text{false}$ ), potem imamo opraviti z *binomsko porazdelitvijo* verjetja za vzorec. Če  $D_i$  del podatkov, ki vsebujejo le vrednosti  $X_i$ , kjer  $p_i$  in  $n_i$  označujeta število pojavitev  $X_i$  pri vrednostih *true* in *false*, dobimo:

$$P(D | \theta_{m,i} = \theta_{m,i}^{p_i}) = \theta_{m,i}^{p_i} (1 - \theta_{m,i})^{n_i} \quad (4.15)$$

V tem primeru je maksimalno verjetje podano z opazovanjem *frekvence*, in sicer:

$$\theta_{m,i}^* = \frac{p_i}{p_i + n_i} \quad (4.16)$$

Za vsako instanco staršev spremenljivke  $X_i$  se ta optimizacija lahko izvede s pridobitvijo pogojnih verjetnostnih porazdelitev  $X_i$  pri podanih starših  $Pa(X_i)$ . Za vsako konfiguracijo staršev  $Pa(X_i)$ ,  $p_i$  označuje število pojavitev  $X_i = \text{true}$  (in tistih s *false*) v vzorcih, ki vsebujejo  $Pa(X_i)$ .

MLE pristop ni primeren, če imamo opravka z manjkajočimi podatki. V tem primeru uporabimo metodo največjega pričakovanja (Expectation Maximization), ki jo opisujemo v nadaljevanju.

### Algoritem največjega pričakovanja

Ocene parametrov v primeru manjkajočih podatkov se lahko izvedejo z uporabo algoritma največjega pričakovanja (Expectation-Maximization - EM) [95]. EM algoritem je primeren za izračun maksimalnega verjetja (*maximum likelihood* - *ML*) in maksimalne posterorne ocene (*maximum a posterior* - *MAP*) v primeru nepopolnih (nepodanih) gotovosti za parametre in nepopolnih podatkov. EM algoritem se izvede v dveh iterativnih korakih, in sicer: korak pričakovanja (*expectation* - *E*) in korak maksimalizacije (*maximization* - *M*).

Naj bo  $N = (X, G, P)$  Bayesova mreža, za katero bi radi ocenili parametre  $\Theta$  pri porazdelitvi  $P$ , glede na podatkovno zbirko  $D$ . Kot smo že zapisali, se ocena parametrov  $\Theta$  v odvisnosti od  $D$  izvede v dveh korakih, koraku *E* in koraku *M*. Pri podani inicjalizacijski dodelitvi parametrov  $\Theta$ , E korak izračuna pričakovano zadostno statistiko

za  $\Theta$ . Zadostna statistika je statistika, ki povzame podatke in vsebuje vse relevantne informacije o podatkih glede na določeno povpraševanje. M korak maksimizira log-verjetje parametrov za takšno statistiko. Ta dva koraka se iterativno izmenjujeta, dokler ne dosežemo končnega kriterija. V primeru manjkaajočih podatkov je log-verjetnostna funkcija parametrov definirana kot linearna funkcija z zadostnimi robnimi porazdelitvami [95]. Log-verjetnostna funkcija  $l(\Theta)$  parametrov  $\Theta$  pri dani podatkovni zbirki  $D = \{c_1, \dots, c_N\}$  in danem DAG  $G$  je tako:

$$\begin{aligned}
 l(\Theta) &= \sum_{l=1}^N P(c^l | \Theta) \\
 &= \sum_{l=1}^N \sum_{i=1}^{|V|} P(X_i = x_i^l | Pa(X_i) = x_{Pa(X_i)}^l, \Theta_i, c^l) \\
 &= \sum_{i=1}^{|V|} l(\Theta)_i
 \end{aligned} \tag{4.17}$$

kjer je  $l(\Theta_i) = \sum_{l=1}^N \sum_{i=1}^{|V|} P(X_i = x_i^l | Pa(X_i) = x_{Pa(X_i)}^l, \Theta_i, c^l)$  in velja neodvisnost med posameznimi parametri  $l(\Theta_i)$ , kjer so  $(c_i^l, c_{Pa(X_i)}^l)$  l-ti po možnosti nepopolni vzorci v  $D$ .

Za Bayesovo mrežo, E korak EM algoritma izračuna pričakovana štetja (zadostno statistiko za celotno podatkovno zbirko  $D$ ), kjer je pričakovanje obravnavano, glede na porazdelitev produkta preko množice vozlišč  $V$  (spremenljivk  $X$ ) pod vrednostmi parametrov  $\Theta$  in podatkov  $D$ :

$$E_\Theta(N_{i,j,k}) = \sum_l^N P(X_i = k, Pa(X_i) = j | c^l, \Theta_i, G) \tag{4.18}$$

kjer je  $N_{i,j,k}$  število vozlišč  $X_i, Pa(X_i) = (k, j)$  in  $c^l$  je l-ti vzorec v  $D$ . M korak nato izračuna novo oceno  $\theta^*$  od  $\theta_{i,j,k}$ , tako da izračuna aktualno zadostno statistiko, glede na vse vzorce v  $D$ , kar zapišemo z naslednjo enačbo, kjer je v imenovalcu razviden seštevek ocen vseh vzorcev:

$$\theta_{i,j,k}^* = \frac{E_\Theta(N_{i,j,k})}{\sum_{k=1}^{|X|} E_\Theta(N_{i,j,k})} \tag{4.19}$$

E in M korak ponavljamo, dokler ne nastopi konvergenca  $l(\Theta)$  ali dokler ne dosežemo zadostnega števila iteracij. Konvergenca je dosežena, če je razlika med log-verjetjem dveh zaporednih iteracij manjša ali enaka numerični vrednosti log-verjetja krat  $\delta$ , pri čemer  $\delta$  predstavlja definiran prag in je  $l_i(\Theta)$  log verjetje po i-ti iteraciji in  $l_{i+1}(\Theta)$  i+1 iteraciji:

$$|l_i(\Theta) - l_{i+1}(\Theta)| \leq \delta \quad (4.20)$$

Pri tem lahko določimo tudi število iteracij, da zagotovimo konec procedure.

Učenje parametrov z EM algoritmom optimizira pogojne verjetnostne tabele CPT v mreži. Optimizacija maksimizira verjetje za vse možne spremenljivke in njihova stanja. Kot smo zapisali, algoritem zraven izračuna frekvence izračuna verjetnosti za manjka joče vrednosti pri posameznih vzorcih v podatkih. EM algoritem upošteva tudi že pridobljeno znanje, če so na voljo CPT tabele, ki jih je konstruiral strokovnjak, preden se začne učenje parametrov mreže. Te vrednosti v tabelah CPT so upoštevane kot del podatkov, zato EM algoritem kombinira znanje v mreži z znanjem, zajetih v podatkih. To je dobra lastnost algoritma, saj zagotavlja dopolnitev modela znanja v predstavitvi Bayesove mreže z vzorci, izraženimi v podatkih, kar pripomore k kvaliteti gradnje modela predstavitve znanja.

### 4.3 Razširitev formalizma Bayesove mreže v sisteme odločanja

Do sedaj smo spoznali uporabo in učenje Bayesovih mrež pri verjetnostnem sklepanju (inferenci), njihovo ročno in strojno gradnjo in pomembnejše algoritme, ki jih za to uporabljamo. V tem podoglavlju bomo razširili model Bayesovih mrež za podporo odločanju. Z dodanjem eksplicitne predstavitve odločitvenih akcij in njihovih vrednosti (cen, koristi) uporabe Bayesove mreže razširimo v tako imenovani odločitveni model, imenovan *diagram vpliva (Influence diagram)* [78]. Diagrami vpliva združujejo verjetnostno sklepanje s funkcijami koristi in na tak način pomagajo uporabnikom pri odločitvah z maksimiziranjem pričakovanih koristi.

#### Koristi

Ko se odločamo za določeno akcijo, moramo upoštevati koristi posamezne akcije med različnimi možnimi izidi akcij, ki so na voljo. Teorija odločanja predstavlja način za

predstavitev sklepanja in koristi. Funkcija koristi (*utility function*) preslika vrednosti, ki zajemajo "koristi" ali "zaželenost" v prostor realnih števil. Takšna preslikava nam dovoljuje združevanje teorije koristi z verjetnostno teorijo, določneje nam omogoča izračun, katera akcija je tista, ki lahko doprinese največjo vrednost (korist) pri podani poljubni gotovosti in njeni pričakovani koristi:

$$EU(A | E) = \sum P(O_i | E, A)U(O_i | A), \quad (4.21)$$

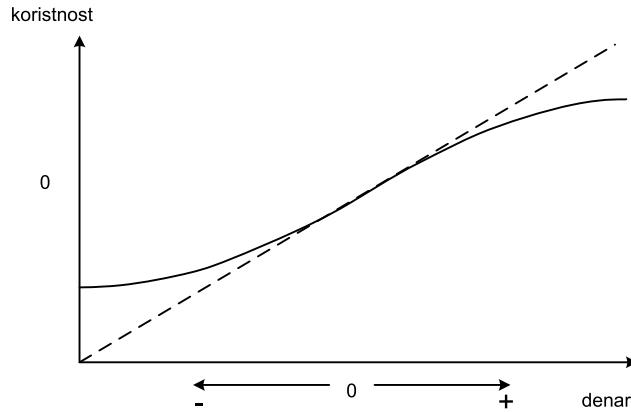
kjer je:

- $E$  podana gotovost
- $A$  nedeterministična akcija z možnimi izidi  $O_i$
- $U(O_i | A)$  funkcija koristi vsakega izida pri podani akciji
- $P(O_i | E, A)$  pogojna verjetnostna porazdelitev preko vseh možnih izidov stanj pri podani opazovani gotovosti za  $E$  in izvedeni akciji  $A$ .

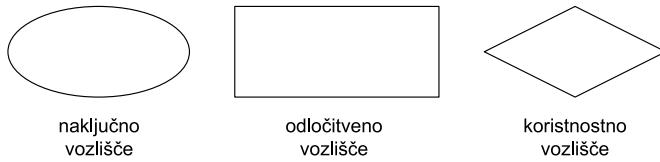
Za primer vzemimo snovanje funkcije koristi pri poslovanju. V tem primeru imamo opraviti z vrednostjo denarja, ki je pogojena s časom. Povezava med denarjem in koristjo je na primer razvidna s sheme 4.4, kjer predstavlja črtkana vrednost nerealen primer, saj sta korist in vrednost denarja identični. Izrisana črta predstavlja realnejši primer, ki je lahko razumljiv. Če upoštevamo ekstreme te funkcije, lahko zapišemo, da gre pri izgubi določene količine denarja podjetje v stečaj. Večja izguba torej za odločitev stečaja ni več pomembna, saj je podjetje že tako v stečaju. Podobno je pri pridobivanju denarja. Vzemimo analogijo pri upokojitvi. Posameznik se upokoji, ko v državno blagajno odvede dovolj denarja. Tako večji znesek ni več pomemben (potreben), glede na upokojitev. Na kratko bi lahko zapisali, da v navedenem primeru pojenjajo robne vrednosti denarja, kar moramo upoštevati pri načrtovanju funkcij koristi. Podoben primer bi lahko navedli tudi na drugih področjih, na primer na področju urgentne medicine, kjer gre za preživetje posameznika, ki je pogojena s časom.

### 4.3.1 Diagrami vpliva

Diagram vpliva je razširitev Bayesove mreže, ki je sposobna predstavitev ključnih razmislekov odločanja: stanje sveta, odločitve ali akcije pod določenimi razmisleki, stanja, ki so lahko rezultat posamezne akcije in koristi teh pridobljenih stanj.



Slika 4.4: Funkcija koristi.



Slika 4.5: Različni tipi vozlišč v diagramu vpliva.

### Tipi vozlišč

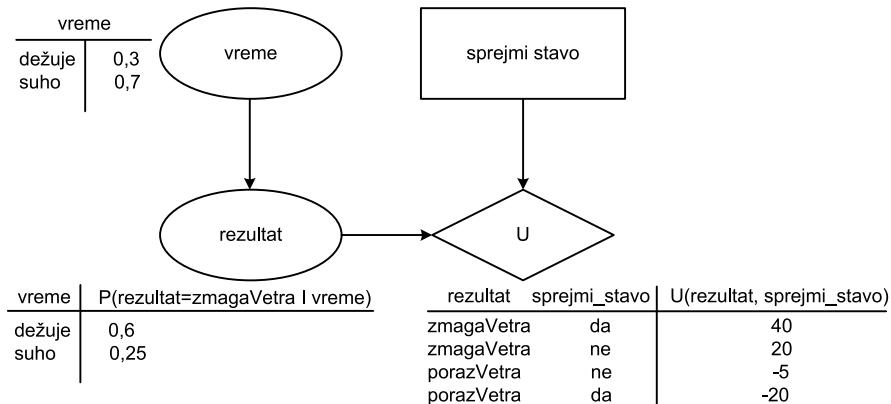
Diagram vpliva je sestavljen iz treh različnih tipov vozlišč, kot je prikazano na sliki 4.5

Tipi vozlišč v diagramu vpliva:

**Naključno vozlišče** je ovalne oblike in predstavlja naključne spremenljivke. Gre za enako vozlišče, kot je vozlišče v Bayesovi mreži, kjer je vsakemu vozlišču pripojena CPT tabela, ki podaja verjetnosti vrednosti spremenljivke pri določenih vrednostih kombinacij njenih staršev. Pri tem so lahko starši tako odločitvena kot naključna vozlišča.

**Odločitveno vozlišče** je pravokotne oblike in predstavlja določeno odločitev, ki je bila podana v določenem času. Vrednosti odločitvenih vozlišč so akcije, ki jih uporabnik izbere pri uporabi diagrama. Odločitveno vozlišče ima lahko naključna vozlišča, kot posebne primere staršev, kjer je razvidno, da bo gotovost v starših na voljo ob odločitvi v vozlišču.

**Vozlišča koristi** so zapisana v obliki romba in predstavljajo funkcijo koristi. Poimenujemo jih lahko tudi vrednostna vozlišča. Starši vozlišč so spremenljivke; opisujejo izid stanja, ki neposredno vpliva na koristi in lahko vključuje odločitveno vozlišče.



Slika 4.6: Diagram vpliva za primer stave na dirkah

Vsako vozlišče koristi ima ustrezno tabelo koristi, z vhodom vsake možne vrednosti njenih staršev, morda tudi z vključajočo izvedeno akcijo. Kjer je na voljo več vozlišč koristi, je splošna korist seštevek individualnih koristi.

Za predstavitev uporabe različnih vrst vozlišč v mreži si oglejmo naslednji primer.

### Primer stave na dirkah

*Jankov favorit Srečko bo na dirkah tekmoval z Metinim favoritom Veter. Janko ponudi Metki prijateljsko stavo: lastnik slabšega favorita na tekmi plača večerjo. Za večerjo Janko in Metka ne porabita več kot 15 evrov. Ko se Metka odloča, ali bo sprejela stavo, mora upoštevati verjetnosti zmage svojega favorita (ki bo zelo odvisna od vremena na dan tekme). Sama tudi ve, da bo srečna, ne glede na stavo, če bo boljši njen favorit, in nesrečna, če bo boljši Jankov favorit.*

Diagram vpliva za opisano mrežo je prikazan na shemi 4.6. Diagram ima eno naključno spremenljivko *Rezultat*, ki predstavlja ali bo Metkin favorit boljši od Jankovega favorita (vrednosti zmaga Vetra, poraz Vetra), in drugo naključno spremenljivko *Vreme*, ki predstavlja, ali bo med tekmo deževalo ali ne (vrednosti dežuje, suho). Diagram vsebuje binarno odločitveno vozlišče *SprejmiStavo*, ki predstavlja, ali bo Metka sprejela ali ne ponujeno stavo, in vozlišče koristi *U*, ki izmeri raven zadovoljstva pri stavi.

Apriorne verjetnosti za *Vreme* predstavljajo tipične vrednosti, ki ustrezajo razmeram v letnem času. CPT za *Rezultat* prikazuje Metkina pričakovanja in da bo njen favorit imel večje možnosti za boljši rezultat, če ne bo deževalo (ker predpostavlja, da ima favorit Veter izjemno formo v mokrem vremenu).

Povezave med *Rezultat* in *SprejmiStavo* in  $U$  zajemajo idejo, da je Metka zadovoljna, glede na kombinacijo boljšega favorita in njene odločitve o stavi. Njene želje so eksplisitno zapisane v tabeli koristi. Podana števila označujejo, da je najboljši izid za Metko zmaga njenega favorita in sprejetje stave ( $U=40$ ), medtem ko je naslednji izid, da je zmagal njen favorit, vendar ni sprejela ponujene stave ( $U=20$ ). Ko njen favorit izgubi, Metka ni zadovoljna ( $U=-5$ ), najslabši pa je primer, kadar njen favorit izgubi in je sprejela ponujeno stavo  $U = -20$ .

Metkino stanje odraža več kot le riziko denarja, v tem diagramu predstavljenega problema tudi ni odločitvenih vozlišč, ki bi imela vpliv na modelirane spremenljivke.

### Ocenjevanje diagramov vpliva

Ocenitev diagrama vpliva z enim odločitvenim vozliščem ocenimo z naslednjim algoritmom:

Algoritem: Odločitev diagrama vpliva (ena odločitev)

1. Vstavi katero koli podano gotovost
2. Za vsako vrednost akcije v odločitvenem vozlišču:
  - (a) Postavi odločitveno vozlišče na to vrednost.
  - (b) Izračunaj posteriorne verjetnosti staršev koristnega vozlišča enako kot za Bayesove mreže z uporabo standardnega inferenčnega algoritma.
  - (c) Izračunaj pričakovano korist za akcijo.
3. Vrni akcijo z največjo pričakovano koristjo.

Za navede primer z nepodanimi gotovostmi je lahko razvidno, da je pričakovana korist v vsakem primeru vsota produktov verjetnosti in koristi različnih primerov.

### Informacijske povezave

Kot smo že omenili pri predstavitvi različnih vrst vozlišč, se lahko pojavijo povezave med naključnimi in odločitvenimi vozlišči. Te povezave imenujemo informacijske povezave [65]. Povezave niso na voljo v osnovni ocenitvi diagrama in nimajo dodatnih parametrov. Namesto tega označujejo, kdaj moram biti opazovano naključno vozlišče, preden se izvede

odločitev  $D$  v odločitvenem vozlišču - a po kateri koli odločitvi, ki se mora izvesti pred  $D$ . Z informacijskimi povezavami se ocenitev mreže lahko razširi na izračun, katere odločitve morajo biti narejene, glede na različne vrednosti v naključnem vozlišču. Z drugimi besedami - sestavimo lahko tabelo optimalnih akcij, ki je pogojno odvisna od različnih drugih stanj. Prejšnji algoritmom razširimo z dodatno zanko in na tak način izračunamo odločitveno tabelo.

Algoritmom: Izračun odločitvene tabele (ena odločitev, informacijske povezave)

1. Vstavi katero koli podano gotovost.
2. Za vsako vrednost akcije v odločitvenem vozlišču:
  - (a) Postavi odločitveno vozlišče na to vrednost.
  - (b) Izračunaj posteriorne verjetnosti staršev koristnega vozlišča enako kot za Bayesove mreže, z uporabo standardnega inferenčnega algoritma.
  - (c) Izračunaj pričakovano korist za akcijo.
  - (a) Shrani akcijo z največjo koristjo v odločitveno tabelo.
3. Vrni odločitveno tabelo.

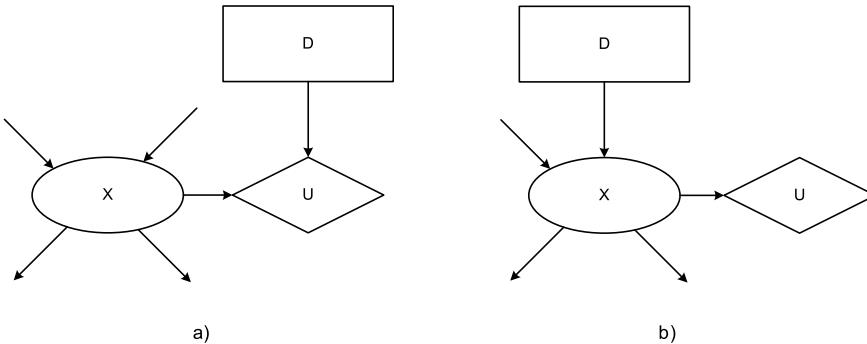
### Tipi povezav

Poznamo dve vrsti tipov akcij in odločitvenih problemov, prepletajoče (*intervening*) in neprepletajoče (*non-intervening*). Neprepletajoče akcije nimajo neposrednega vpliva na modelirane naključne spremenljivke, kot je razvidno na shemi 4.7 (a). V navedenem primeru odločitev o stavi ne vpliva na stanje modeliranih spremenljivk, medtem ko prepletajoče akcije neposredno vplivajo na modeliran scenarij 4.7 (b).

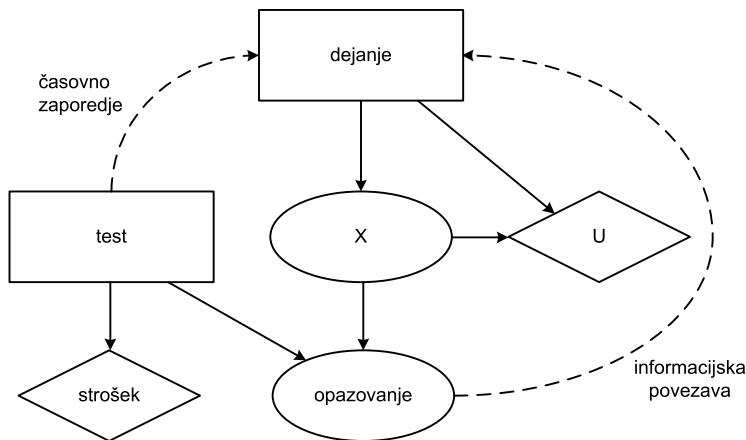
### Zaporedno odločanje

Do sedaj smo se ukvarjali le s primeri, ki imajo eno samo odločitev. Pogosto pa mora uporabnik sprejeti več odločitev ali plan.

Preprost primer zaporednih odločitev je situacija, v kateri ima uporabnik na voljo možnosti za izvedbo testa, v splošnem opazovanja, ki bo pripomogla k uporabnim informacijam, preden bo izbrana odločitev za nadaljnjo akcijo. V primeru konjskih dirk bi



Slika 4.7: (a) odločitev ne vpliva na stanje spremenljivk (b) vpliv odločitve na spremenljivke.



Slika 4.8: Diagram vpliva za test-izbiro.

Metka lahko imela izbiro, da pridobi informacije o vremenu (morda s klicem na meteoroško agencijo). Tak tip odločitvenega problema ima potem dve stopnji:

1. odločitev o izvedbi testa ali opazovanja,
2. izbira odločitve (aktivnosti).

Testiranje (opazovanje) odločitve pride na vrsto pred izbiro odločitve. V mnogih primerih ima tudi testiranje ali opazovanje posredne stroške, povezane s tem, ali v sami ceni izvedbe, časa ali drugih posledic. Diagram vpliva, ki predstavlja značilno strukturo za naveden primer testiranja-izbire zaporednih korakov, je predstavljen na shemi 5.1. Na shemi sta dve odločitveni vozlišči *Test* z vrednostmi *da* in *ne* in *Dejanje* s toliko vrednostmi, kolikor je na voljo izbir. Časovno zaporedje med odločitvami je prikazano s povezavo (*precedence link*), ki je zapisana kot črtkana linija.

Če je odločitev narejena za izvedbo testa, bo na voljo gotovost, pridobljena iz opazovanja vozlišča *Opazovanje*, preden bo izbrana odločitev v vozlišču *Dejanje*. Zato imamo informacijsko povezavo od *Opazovanje* k *Dejanje*. Vprašanje, ki se potem poraja, je pomen informacijske povezave, če je izbrana odločitev, da *Test* ne bo izveden. Nastala situacija je dodana z dodajanjem dodatnega stanja *neznano* k vozlišču *Opazovanje* in ustrezni postavitevi CPT tabele:

1.  $P(Opazovanje = neznano \mid Test = ne) = 1$
2.  $P(Opazovanje = neznano \mid Test = de) = 0$

V tem generičnem diagramu vpliva so povezave med vozliščem *Dejanje* do obeh vozlišč naključnega  $X$  in koristi  $U$ , ki ponazarjata prepletajoča dejanja z dejanskimi stroški. Obe povezavi lahko umaknemo, če gre za neprepletajoča dejanja ali dejanja, pri katerih ni stroškov. V diagramu je tudi implicitna predpostavka o hranjenju informacij. Uporabnik si zapomni opazovanja in odločitve v preteklosti, ki so ponazorjene z informacijsko in s "precedence" povezavo. Naslednji algoritem prikazuje, kako uporabiti "test-dejanje"-diagram vpliva za zaporedno odločanje.

#### Uporaba "test-dejanje" odločitvenega diagrama

1. Oceni diagram vpliva s katero koli podano gotovostjo (različno od izhoda *Test*)
2. Vrni odločitev *Test*.
3. Vstavi *Test* odločitev kot gotovost.
4. Če je  $Test = da$ , potem
  - izvedi *Test* in vrni rezultat.
5. Drugače
  - vstavi rezultat *neznano* kot gotovost v diagram
6. Oceni diagram vpliva.
7. Vrni odločitev za *Dejanje*.

## 4.4 Uporaba Bayesovih verjetnostnih mrež v medicini

Bayesove mreže se vedno bolj uporabljajo v medicini kot orodje za podporo reševanja različnih problemov [86, 20, 70, 21]. Nekateri izmed problemov, kjer se mreže uporabljajo v medicini, navajamo v nadaljevanju. Na podlagi podobnih idej smo izhajali pri zasnovi doktorske naloge in jih tako uporabili za potrebe simulacij.

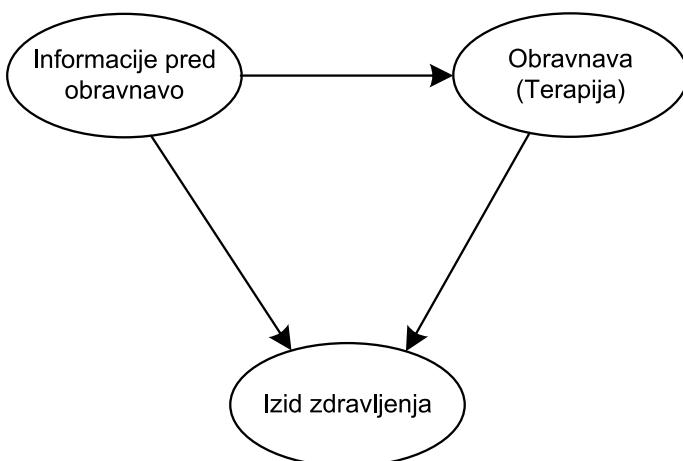
### 4.4.1 Podpora pri določanju diagnoz

Določanje diagnoze za posameznika temelji na konstrukciji hipoteze o bolezni bolnika, ki izhaja iz anamneze in diagnostičnih testov. Diagnostični testi v splošnem ne zagotavljajo popolnoma zanesljivih rezultatov o stanju bolnika. Po navadi njihove vrednosti obsegajo stanja resnično pozitivnih (true-positive) in resnično-negativnih (true-negative) vrednosti, ki niso enake 100 % senzitivnosti in specifičnosti. Zato je treba pri gradnji hipoteze upoštevati nedoločenost, ki nastane pri izvedbi različnih testov. Bayesove mreže ponujajo naravno osnovo za takšen način sklepanja, saj vsebujejo nedoločenost [27]. V preteklosti je bilo razvitih precej mrežno podprtih sistemov za diagnozo v medicini, ki so tudi danes v razvoju [44]. Zelo dobro poznan zgodnji primer takšnih sistemov je Pathfinder sistem [12, 13] in MUNIN [87]. Pregled ostalih aplikacij strojnega učenja na področju medicinske diagnostike podaja Kononenko [34, 33, 32].

Formalno lahko diagnozo definiramo kot vrednost  $D_*$  za podmnožico naključnih spremenljivk, tako da velja

$$D_* = \operatorname{argmax} Pr(D | \epsilon),$$

kjer je  $\epsilon$  opazovana gotovost, sestavljena iz več simptomov, znakov in testov. Diagnoza je torej lahko definirana kot maksimalna posteriori (maximum a posteriori assignment - MPA) na dano podmnožico spremenljivk. Vzpostavitev MPA iz Bayesove mreže je z vidika računske zahtevnosti vse prej kot preprosta naloga in zahteva veliko računske moči. Ker se v realnosti kombinacija bolezni redkeje pojavi skupaj, se v splošnem diagnostično sklepanje nanaša na eno samo bolezen. Zato je lahko en pristop k temu predpostavka, da so vse bolezni medsebojno izključujoče, in se tako posamezne bolezni lahko pojavijo kot vrednost spremenljivke vozlišča bolezen. Drug pristop je posamezna bolezen v posameznem vozlišču, pri katerem se izračun verjetnostnih porazdelitev izračuna za vsako spremenljivko posebej. Pri tem ni nujno, da je kombinacija najbolj verjetnih vrednosti za te ločene spremenljivke bolezni enaka MPA.



Slika 4.9: Struktura prognostične Bayesove mreže.

Za pomoč ekspertom v kompleksnih nalogah pri diagnostičnem sklepanju so Bayesove mreže pogosto podprte z metodo selekcije testa, ki pove, kateri vrstni red testov je tisti, ki najbolj pripomore k zmanjšanju nedoločenosti o trenutni bolezni obravnavanega bolnika. Metode testa selekcije v principu uporabljajo informacijsko-teoretične metrike pri delu z nedoločenostjo. Te metrike so definirane na verjetnostni porazdelitvi bolezenske spremenljivke in izražajo pričakovano vrednost informacije, ki je potrebna, da se vrednost v spremenljivki vzpostavi iz nedoločenega v stanje z določenostjo. Shannonova entropija je pogosto primer take metrike, razširi pa se lahko tudi z drugimi informacijami, ki vsebujejo vrednosti o ceni in stroških, povezanih z določeno specifično naložbo. Pri tem se selekcija zaradi računske kompleksnosti izvaja v zaporednih korakih, pri katerih uporabnik lahko predlaga posamezen test, pridobi rezultate in se potem odloči za drugega.

#### 4.4.2 Prognostično sklepanje

Prognostično sklepanje v medicini se uporablja v predikcijske namene o dogodkih v prihodnosti. Ker je prihodnost sama po sebi nedoločena, so Bayesove mreže tudi v teh primerih uporabna orodja. Prognostično sklepanje v primerjavi z diagnostičnimi sklepanjem prinaša uporabno vrednost pri iskanju in uporabi znanja o evoluciji posameznega procesa, glede na čas. Čeprav takšno začasno znanje o procesu v bolezni ni zapisano eksplizitno, je podano v strukturi prognostične Bayesove mreže na shemi 4.9. Rezultat in predikcija za posameznega bolnika sta v splošnem pod vplivom določenega zaporedja aktivnosti zdravljenja, ki so lahko odvisne od informacij o bolniku, pridobljenih pred zdravljenjem.

Formalno lahko prognozo definiramo kot:

$$Pr(izhod | E, F),$$

kjer so  $\varepsilon$  ponovno podatki o bolniku, vključujuč simptome, znake in rezultate testov, in kjer  $F$  določa določeno zaporedje aktivnosti zdravljenja. Izhod se potem lahko preprosto definira kot ena sama spremenljivka, na primer ”preživetje bolnika“, ali tudi bolj kompleksno, vključujuč druge informacije, ki so pri tem pomembne. V tem primeru je izhod predstavljen s podmnožico spremenljivk. Prognostične Bayesove mreže so v medicini v razvoju in se z razliko od mrež za namene diagnosticiranja uporabljajo manj časa. Raziskovalci so take mreže predstavili pred kratkim, na primer na področju onkologije [94, 75] in infekcijskih bolezni [85, 76].

#### 4.4.3 Izbira postopka zdravljenja

Formalizem Bayesovih mrež zagotavlja le zajemanje spremenljivk in njihove verjetnostne porazdelitve produkta, zato dovoljujejo le verjetnostno sklepanje, kot je postavitev diagnoze za posameznega bolnika ali predikcijo posledic zdravljenja. Za uporabo v podporo odločanju pri izbiri posameznega zdravljenja za določeno bolezen pa formalizem ni dovolj. V ta namen so Bayesove mreže pogosto vključene v odločitveno podprte sisteme, ki vključujejo njihovo diagnostično in prognostično sklepanje [85, 75].

Kot drug pristop, ki smo ga že navedli, pa formalizem Bayesovih mrež lahko razširimo z vključitvijo znanja o odločitvah in izbirah. Takšen primer razširjenega formalizma so diagrami vpliva, ki smo jih natančneje predstavili v 5. poglavju in se uporabljajo za podporo pri izbiri zdravljenja. Bayesove mreže se razen omenjenih glavnih treh področij lahko uporabljajo tudi v sorodnih domenah, kot je na primer modeliranje postopkov v anesteziji [67], ali organizacija dela v službi nujne medicinske pomoči [84]. Dobri rezultati so se pokazali tudi pri triaži bolnikov, glede na vhodne podatke o abdominalni bolečini [90].

### 4.5 Programska orodja za delo z Bayesovimi mrežami

V prejšnjem razdelku smo predstavili razvoj in specifikacijo metodologije CASGen za gradnjo medicinskih scenarijev za simulator SimMan, ki temelji na Bayesovih verjetnostnih mrežah in prinaša izboljšave pri gradnji scenarijev iz 1) vidika uporabe Bayesovih

mrež v posameznem stanju, ki omogočajo inferenco in tako izboljšujejo uporabo scenarijev v simulacijskem okolju, ter 2) - v gradnjo scenarijev vnašajo možnost uporabe realnih podatkov, ki na tak način simulacijo približujejo realnemu okolju. Če podatkov nimamo na voljo, jih v ta namen lahko zbiramo za gradnjo simulacij v prihodnje; metodologija CASGen pa pri tem predstavlja postopek in način zbiranja podatkov, ki jih potrebujemo za pravilno uporabo metodologije za gradnjo scenarija na podlagi podatkov.

V tem razdelku predstavljamo dve empirični študiji uporabe metodologije CASGen, in sicer primer uporabe metodologije pri situacijah, ko nimamo na voljo zbranih podatkov, ki bi jih lahko uporabili pri gradnji scenarija, in primer, ko smo scenarij izboljšali in dogradili z realnimi podatki, zbranimi na domeni urgentne medicine. V začetku razdelka zato najprej predstavimo programska orodja, ki se uporablajo za gradnjo Bayesovih mrež CASGen in nato opišemo omenjena primera z medicinskega področja, primer anafilaktične reakcije in primer oživljanja bolnika na terenu.

V nadaljevanju torej predstavljamo programska orodja, ki so na voljo za delo z Bayesovimi verjetnostnimi mrežami. Preizkusili smo nekaj aktualnih orodij, ki jih opisujemo v nadaljevanju in izmed njih izbrali najustreznejše, glede na zahteve metodologije CASGen.

#### 4.5.1 GeNIE in SMILE

SMILE in GeNIE sta člana programskih rešitev, razvitih na univerzi v Pittsburghu. To programsko orodje je neposreden rezultat raziskav in je bilo razvito za potrebe modeliranja v negotovi domeni, s posebnim poudarkom na diagnostičnem sklepanju. Orodje, dokumentacija in primeri aplikacij so prosto dostopni na <http://genie.sis.pitt.edu>.

GeNIE (The Graphical Network Interface) je grafični vmesnik za knjižnico SMILE. Implementiran je v programskem jeziku C++ in uporablja MFC razrede (Microsoft Foundation Classes) operacijskega sistema Windows. Poudarja dostopnost in prijaznost do uporabnika za kreiranje odločitvenih modelov z intuitivnim vzemi in spusti pristopom. Je uporabniku prijazno okolje za gradnjo grafičnih odločitvenih modelov in modelov diagnostičnega sklepanja. Njegove poglavite lastnosti so:

- grafični urejevalnik kreira in spreminja modele,
- podpira različne šumne verjetnostne porazdelitve,
- odlična funkcionalnost izreži in prilepi med BN,

- integracija z Microsoft Excel programskim paketom,
- kompatibilnost z ostalimi programskimi rešitvami (Netica, Hugin, Ergo itn),
- podpora diagnostičnemu upravljanju.

Orodje ima danes več tisoč uporabnikov, aplikacije orodja pa segajo od industrijskih projektov do akademskega raziskovalnega sektorja. Uporablja se tudi kot orodje za pedagoške namene na več univerzah.

#### 4.5.2 BayesiaLab

BayesiaLab (<http://www.bayesia.com>) je orodje za modeliranje BN, razvito pri francoskem podjetju Bayesia. BayesiaLAB ima dva načina, način za načrtovanje BN in način za validacijo BN in inferenco. V načrtovalnem načinu je omogočeno načrtovanje posameznih vozlišč in njihovih povezav, medtem ko imamo pri validaciji možnost različne izbire algoritmov. Orodje omogoča uporabo osnovnih algoritmov inference. Zvezne spremenljivke je treba diskretizirati, kar je omogočeno z enakomerno porazdelitvijo frekvence ali enakomernih intervalov.

#### 4.5.3 Netica

Netica je izdelek podjetja Norsys (<http://www.norsys.com>) iz Kanade. V Netici najprej načrtamo BN, jo prevedemo, nakar lahko uporabimo inferenco na mreži. Orodje je plačljivo, podobno, kot to velja za BayesiaLab.

#### 4.5.4 WEKA

Weka je odprtokodna zbirka orodij za strojno učenje in podatkovno rudarjenje Univerze Waikato v Novi Zelandiji [65]. Načrtovanje in uporabo Bayesovih mrež so dodali šele v zadnji verziji, vendar grafični vmesnik še ne deluje, prav tako pa paket pri delu z Bayesovimi mrežami ni stabilen. Sicer omogoča predstavljene algoritme v doktorskem delu.

#### 4.5.5 HUGIN

Hugin je razvila skupina na Univerzi Aalborg kot del projekta ESPRIT [65]. Za gradnjo Bayesovih mrež uporablja algoritme, kot prej omenjena programska orodja, prav tako pri inferenci uporablja algoritme, ki smo jih predstavili v nalogi. Del Hugina je odkupil tudi Hewlet Packard - namen razvoja orodja s podporo odločitvam.

Glede na dostopnost programskih orodij, njihovo prijaznost do uporabnika, prost pristop in razširjenost in uporabnost v akademskem okolju, smo se odločili za uporabo orodja GeNIE, s pomočjo katerega smo aplicirali metodologijo CASGen na dveh realnih študijah, ki ju opisujemo v nadaljevanju.



## **Del III**

**Izdelava metodologije uporabe  
verjetnostnih mrež za potrebe  
simulatorja**

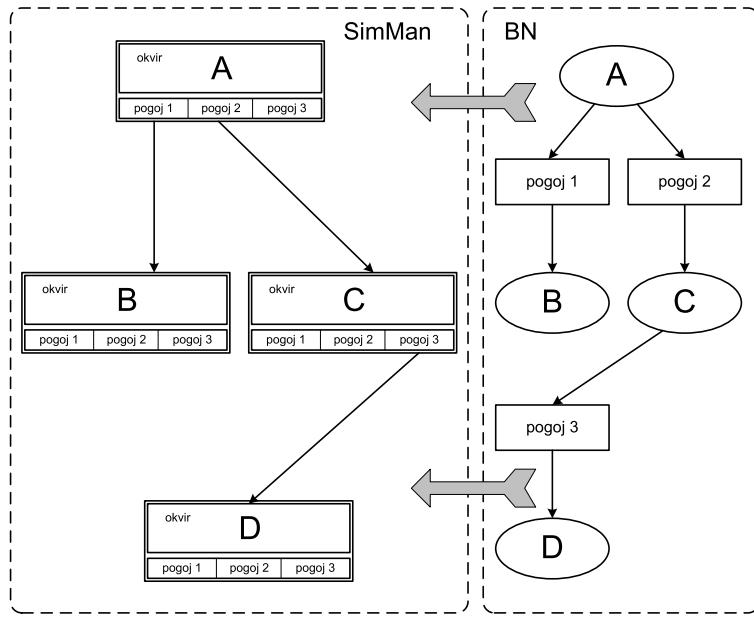


## Poglavlje 5

# Simulacije kot vzorčno odvisni sistemi dogodkov in stanj

### 5.1 Narava izdelave scenarija za simulator

Scenariji so navodila, po katerih delujejo simulatorji med izvajanjem urjenja medicinskega osebja. Odražajo bolnikovo stanje, ki se spreminja s časom, ali glede na posege osebja. V njih morajo biti predvideni vsi zapleti, ki lahko nastanejo, prav tako pa tudi odzivi simulatorja, glede na intervencije študentov. Model posameznega scenarija lahko zapišemo s pomočjo grafičnih gradnikov in programskega orodja za gradnjo scenarijev simulatorja. Iz primera scenarija, in njegove narave, lahko razberemo, da gre pri gradnji simulacijskih scenarijev za vzročno-posledične relacije med posameznimi entitetami, ki zavzemajo določeno stanje bolnika. Gre torej za vzročno-posledične povezave, ki ji lahko učinkovito modeliramo v obliki grafov. Ti so kvalitativna osnova pri zgradbi verjetnostne mreže. Z upoštevanjem nedoločenosti, ki nastopi v posameznem scenariju, kot tudi nedoločenosti, ki nastopa v medicinski domeni pri obravnavi posameznega bolnika, imamo pri gradnji scenarijev opraviti tudi z verjetnostmi. Oboje skupaj, tako verjetnosti kot vzročno posledične relacije, ki jih nevede uporabljamo pri gradnji koncepta scenarija, so bistveni element modela verjetnostnih mrež. Zato je uporaba modela verjetnostnih mrež za potrebe gradnje scenarija za simulator naravna, intuitivna in logična, saj gre za povezave "stanja bolnika" med različnimi "dogodki", ki to stanje spreminjajo. Shema 5.1 predstavlja podobnosti med gradniki in okoljem za generiranje scenarijev in Bayesovim modelom.



Slika 5.1: Preslikava med modelom BN in gradniki scenarija.

Bayesove verjetnostne mreže nam tako predstavljajo dobro izbiro za modeliranje problema gradnje scenarija, saj definicija samega problema pri gradnji scenarijev vključuje element nedoločenosti, kot tudi željo po maksimalnem pričakovanem izkoristku, ko gre za čim kvalitetnejšo obravnavo bolnika. V prejšnjih poglavjih smo zapisali nekatere najpomembnejše kriterije, na podlagi katerih se odločamo za uporabo verjetnostnih mrež. Pri naravi problema gradnje simulacije scenarija ugotavljamo, da problem ustreza omenjenim kriterijem. Za gradnjo scenarija velja:

- ima dobro definirane spremenljivke: na primer problemi, spremenljivke v simulatorju so jasne (EKG, krvni tlak, saturacija, dihanje itn);
- predstavlja problemsko domeno z vzročno-posledičnimi relacijami (adrenalin na primer vpliva na zoženje žil, kar ponovno vpliva na dvig tlaka);
- vsebuje nedoločenost, povezano z vzročno-posledičnimi relacijami: stanje spremenljivk v scenariju v veliko primerih vsebuje vrednosti, ki niso deterministične (na primer: verjetnost, da povrnemo bolniku cirkulacijo po defibrilaciji zavzema določeno vrednost med 0 in 1);
- scenariji se uporabljajo za različne skupine študentov in različne variacije znotraj posameznih scenarijev. Na primer anaflaktični šok, hitro uvajanje v anastezijo

## 5.2. PREDSTAVITEV ZNANJA V SIMULATORJU Z GRAFIČNIM MODELOM VERJETNOSTNIH MREŽ

itn. Vse to so problemi, kjer se spreminjajo le vrednosti opazovanih spremenljivk, medtem ko vzročno-posledične relacije in mehanizem ostajajo enaki. Na podlagi tega se lahko študentje večkrat urijo za različno reševanje problemov.

- Maksimalna pričakovana korist, vsaka odločitev v scenariju vsebuje določeno korist, ki jo lahko razumemo v kontekstu preživetja bolnika, kvalitete življenja oziroma ustreznih odločitev, ki jih pričakujemo od študentov (izbira ustreznegata zdravila, izbira primerenega odmerka zdravila, izbira primerenega časa itn.).

Pri tem seveda obstaja tudi nekaj omejitev, ki smo jih povzeli že v uvodu. Gre predvsem za zaprt sistem scenarija (patentiran izdelek), kjer ni mogoča implementacija avtomatske gradnje modela s pomočjo BN. Četudi bi ta bila na voljo, tega ne bi bilo smiselno uporabiti, saj smo v domeni medicine, kjer se orodja za podporo odločanju uporablajo izključno za podporo odločitvam zdravnika, v našem primeru gre tukaj za inštruktorja, ki gradi scenarij. Drugi tak aspekt so vzročno posledične relacije, ki se lahko v scenariju spreminjajo skozi čas. V tem delu smo se zaradi kompleksnosti narave izdelave scenarija, ki predstavlja kompleksen in dolgotrajen proces, omejili na uporabo klasičnega modela BN. Tako možne pojavitve vzročno-posledičnih relacij, ki se spreminjajo skozi čas, rešujemo v sami metodologiji CASGen. Ta temelji na skupkih posameznih BN in diagramu vpliva, ki te mreže med seboj povezuje. Na tak način se časovna komponenta transformira med različnimi posameznimi Bayesovimi mrežami, vpetimi v strukturi simulacije.

### 5.2 Predstavitev znanja v simulatorju z grafičnim modelom verjetnostnih mrež

Verjetnostne mreže so torej ustrezen in naraven model za zapis scenarija in predstavitev znanja, zraven tega pa nam omogočajo tudi

1. učenje parametrov izdelane mreže na podlagi realnih podatkov in
2. učenje strukture na podlagi realnih podatkov.

Simbolično znanje lahko iz podatkovnih zbirk pridobimo tudi z drugimi simboličnimi metodami strojnega učenja, kot so to na primer odločitvena drevesa ali produkcijska pravila. Vendar nam Bayesove mreže zraven zapisa znanja v človeku zapisani razumljivi

obliki, omogočajo tudi možnost sklepanja (inference) v verjetnostnem okolju. Tako med več pravilnimi hipotezami pridobimo veljavnejšo, kar pa ne velja za sisteme produkcijskih pravil ali odločitvenih dreves. Scenarij v simulaciji, kjer se parametri spreminjajo od primera do primera, lahko na tak način zapišemo z verjetnostno (Bayesovo) mrežo, kjer gotovost nekega parametra privede do drugačnega scenarija, na katerega se odzove študent v simulacijskem okolju. V naslednjem razdelku podrobno predstavljamo hevrištično metodologijo za generiranje scenarijev na podlagi uporabe Bayesovih verjetnostnih mrež za simulator, poimenovano CASGen.

# Poglavlje 6

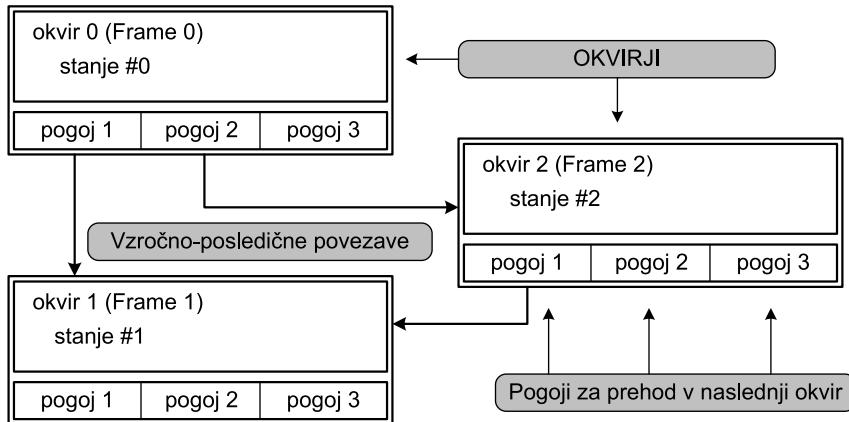
## Izdelava metodologije

Metodologija CASGen (*Computer aided generation of scenarios*) temelji na uporabi verjetnostnih mrež za potrebe generiranja scenarijev simulatorja. V poglavju 2 smo predstavili simulacijsko okolje in simulator, kasneje smo podali teoretično ozadje in metode verjetnostnih mrež, ki izhajajo iz teorije grafov in verjetnostnega računa. V tem razdelku pa predstavljamo metodologijo CASGen, ki smo jo razvili za podporo generiranja scenarijev za simulator s pomočjo Bayesovih verjetnostnih mrež. Kot smo zapisali, predstavlja gradnja scenarija za simulator kompleksen problem, pri katerem je treba upoštevati specifične karakteristike sistema, prav tako pa tudi karakteristike verjetnostnih mrež.

Metodologija CASGen v osnovi zajema sedem večjih sklopov, v okviru katerih podrobno razdelamo uporabo Bayesovih mrež za podporo pri gradnji scenarijev za simulator. V tem poglavju opisujemo strukturo metodologije CASGen in njeno arhitekturo ter natančno opišemo vse stopnje, ki jo sestavljajo in se sestojijo iz naslednjih večjih sklopov: analiza problemske domene, gradnja strukture Bayesovih mrež, optimizacija in učenje parametrov Bayesovih mrež, integracija Bayesovih mrež v scenarij, določitev težavnosti scenarija, gradnja scenarija in uporaba inference v njem. Poglavlje sklenemo z umestitvijo metodologije v realno simulacijsko okolje, kjer je namenjena strokovnjakom za gradnjo in uporabo scenarija pri urjenju ciljnih udeležencev za simulatorjem.

### 6.1 Metodologija CASGen

Metodologija CASGen temelji na uporabi hevrističnega pristopa uporabe Bayesovih mrež za podporo strokovnjaku pri gradnji scenarijev za simulator. Shema 6.1 predstavlja



Slika 6.1: Osnovni gradniki scenarija.

osnovne gradnike okolja simulatorja (glej poglavje 2).

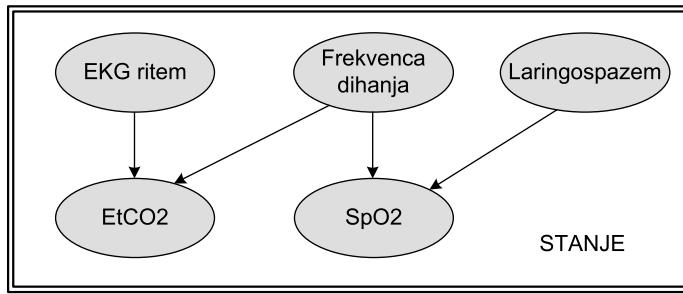
V sekvenčnih simulatorjih se scenariji izvajajo po korakih. Kot lahko uvidimo iz sheme, scenarij sestavlja posamezni gradniki ("okvirji") in povezave med njimi. Vsak okvir vsebuje množico spremenljivk, ki definirajo trenutno stanje bolnika, v spodnjem delu pa potrebne pogoje, da se bolniku stanje spremeni iz enega v drugo. Okvirji so tako med seboj vzročno-posledično povezani, pri čemer se takšen deskriptivni način izvajanja korakov vedno začne z okvirjem, označenim z nič (Frame 0). Iz okvirja 0 se pomaknemo v naslednji okvir, ko udeleženci izvedejo določen dogodek kot pogoj za prehod v naslednji element - okvir. Primer je prikazan na sliki 2.23 v poglavju 2.

## 6.2 Arhitektura metodologije CASGen

### 6.2.1 Preslikava med predstavitevijo znanja v scenariju in verjetnostnimi mrežami

Scenarij torej predstavlja sekvenčno zaporedje posameznih stanj, pri čemer vsako stanje zase vsebuje množico spremenljivk, ki so medsebojno odvisne in to stanje definirajo. Gre torej za dva pogleda odvisnosti, ki se pojavljajo v scenariju:

- vzročno-posledične povezave med posameznimi spremenljivkami v določenem stanju
- vzročno-posledična povezanost med posameznimi stanji, glede na pogoje pri prehodu iz enega v drugo stanje



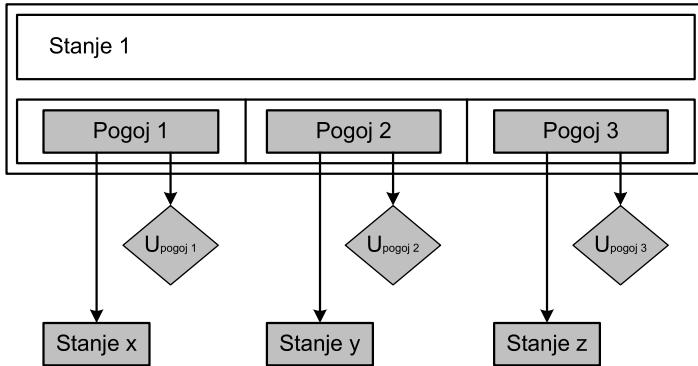
Slika 6.2: Bayesova mreža za posamezno stanje v scenariju.

Pri prvem načinu vzročno-posledični relacij za posamezne spremenljivke v stanju gre za diagnostično vrsto sklepanja, saj na primer tlak vpliva na srčni utrip, spet ta lahko vpliva na  $CO_2$ , kar vpliva tudi na  $SO_2$  izdihanega zraka. Ko torej sprememimo eno vrednost spremenljivke, se v ovisnosti od te spremenijo tudi parametri nekaterih drugih spremenljivk v stanju. Glede na predstavitev posameznega stanja in opisane lastnosti, lahko relacije med posameznimi spremenljivkami v stanju učinkovito predstavimo z modelom diskretne Bayesove mreže. Tako vsako stanje v scenariju predstavlja Bayesovo mrežo, ki jo v ta namen konstruira strokovnjak, hkrati pa jo lahko pridobimo tudi na podlagi realnih podatkov s pomočjo strojnega učenja, če razpolagamo z njimi. Bayesovo mrežo za posamezno stanje prikazuje shema 6.2.

Uporaba Bayesove mreže v scenariju pri definiciji spremenljivk za posamezno stanje h gradnji scenarija prinaša dve dobrodošli izboljšavi:

- Bayesova mreža v posameznem stanju nam omogoča inferenco in s tem avtomatske nastavitev posameznih stanj bolnika, ki jih pri klasičnem načrtovanju scenarija moramo vnašati ročno. S tem prihaja do zmanjšanja napak pri uporabi scenarija v simulacijski učilnici in kakovostnejšo uporabo le-tega
- Če razpolagamo s primernimi podatkovnimi zbirkami, ki vsebujejo vzorce bolnikov pri posameznih diagnozah, lahko s pomočjo strojnega učenja podatke uporabimo za učenje mreže in nastavitev parametrov ali za gradnjo strukture, po navadi pa posežemo po obojem.

V primeru, da podatkov nimamo na voljo, lahko mrežo zgradi strokovnjak. Tako z uporabo mreže v vsakem primeru omogočimo inferenco, ki izboljša kakovost pri izvedbi simulacij, s podatki pa lahko scenarij izboljšamo tudi s pomočjo znanja iz realnih podatkovnih zbirk, kar je vsekakor poglavitna prednost. Tudi če s takšnimi zbirkami ne

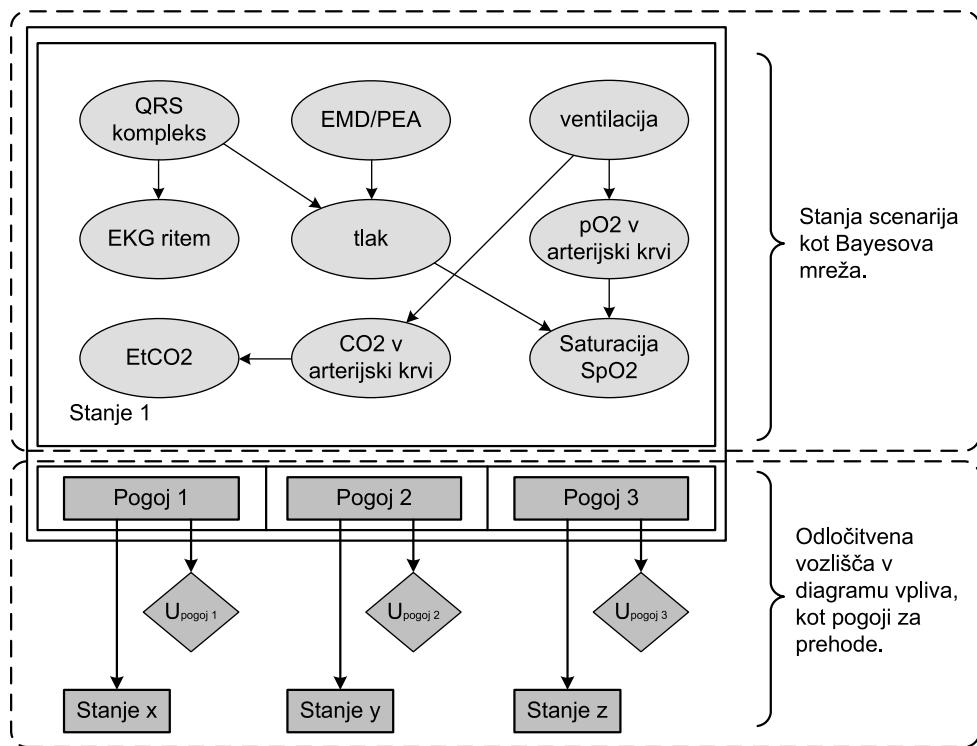


Slika 6.3: Diagram vpliva in povezava stanj v scenariju.

razpolagamo, metodologija CASGen izboljšuje intuitivno gradnjo scenarija in natančno definira postopek za zbiranje podatkov v podatkovne zbirke, ki jih lahko v prihodnosti uporabimo za načrtovanje scenarija. Tako lahko scenarij teoretično načrtujemo najprej z definicijo potrebnih podatkovnih zbirk za obravnavo problema in šele, ko le-te pridobimo, uporabimo CASGen za gradnjo scenarija, ki ga lahko pridobimo iz vnaprej predvidenih podatkovnih zbirk. V realnosti je seveda najpogostejsa kombinacija obojega, saj lahko strokovnjaki zdravniki določena stanja scenarija gradijo na podlagi strojnega učenja, kjer mrežo na tak način izboljšajo, nekatera, kjer podatkov ni na voljo, pa generirajo ročno.

Drugi vidik vzročno-posledičnih relacij predstavljajo prehodi med posameznimi stanji in pogoji, ki jih določi uporabnik, izvajalec simulacije. V tem primeru imamo opraviti z odločitvami strokovnjaka pri uporabi samega modela, kjer vsaka odločitev vsebuje določeno oceno njene vrednosti (cenovna, časovna, kvaliteta zdravljenja ...). Ker imamo opraviti z vzorčno-posledičnimi relacijami in zunanjimi odločitvami uporabnika, nam v vidiku povezave med stanji opis scenarija omogoča razširjen formalizem Bayesovih mrež - tako imenovani diagrami vpliva. Na shemi 6.3 so prikazane povezave med gradniki scenarija in diagramom vpliva.

Kot smo zapisali, vsebuje metodologija CASGen za hevristično gradnjo scenarija za simulator Bayesove mreže kot posamezna vozlišča naključnih spremenljivk v diagramu vpliva, ki posamezna stanja povezuje med seboj. Povezave med Bayesovimi mrežami omogočajo odločitvena vozlišča diagrama vpliva, kjer uporabnik (inštruktor na simulatorju) določi odločitve, ki predstavljajo pogoje med prehodi posameznih stanj v scenariju. Shema 6.4 predstavlja dvoslojno arhitekturo gradnikov metodologije CASGen, katerih korakih postopoma opisujemo v nadaljevanju.



Slika 6.4: Dvoslojna arhitektura metodologije CASGen.

### 6.3 Definicija Metodologije CASGen

V tem poglavju predstavljamo metodologijo CASGen in jo povzemamo v obliki diagrama, predstavljenega na shemi 6.8. Iz diagrama lahko razberemo sinergijo in povezavo vseh sklopov, ki jih opisujemo v nadaljevanju in se združujejo v razviti metodologiji CASGen. Ta je v pomoč strokovnjaku na področju simulacij pri uporabi hevristike za načrtovanje scenarijev. Pri tem je pomembno poudariti, da prinaša metodologija CASGen naslednje prednosti gradnje scenarija:

- omogoča transparenten postopek gradnje scenarija,
- integrira uporabo Bayesove mreže v gradnjo scenarija,
- omogoča lažje upravljanje s scenarijem v simulatorju (uporaba inference Bayesovih mrež in podanih gotovosti) ter
- možnost uporabe realnih podatkov v gradnji scenarija (uporaba podatkovnih zbirk, načrtovanje podatkovnih zbirk za uporabo v simulacijah).

Še posebej pomembno je poudariti lastnost uporabe realnih podatkovnih zbirk ali njihovega načrtovanja, ki jih lahko uporabimo pri gradnji posameznih stanj v scenariju z uporabo Bayesovih mrež. Na tak način lahko učinkovito izboljšamo urjenje študentov in jih tako bolje pripravimo na srečanje z realnim okoljem.

## 6.4 Analiza problemske domene za scenarij

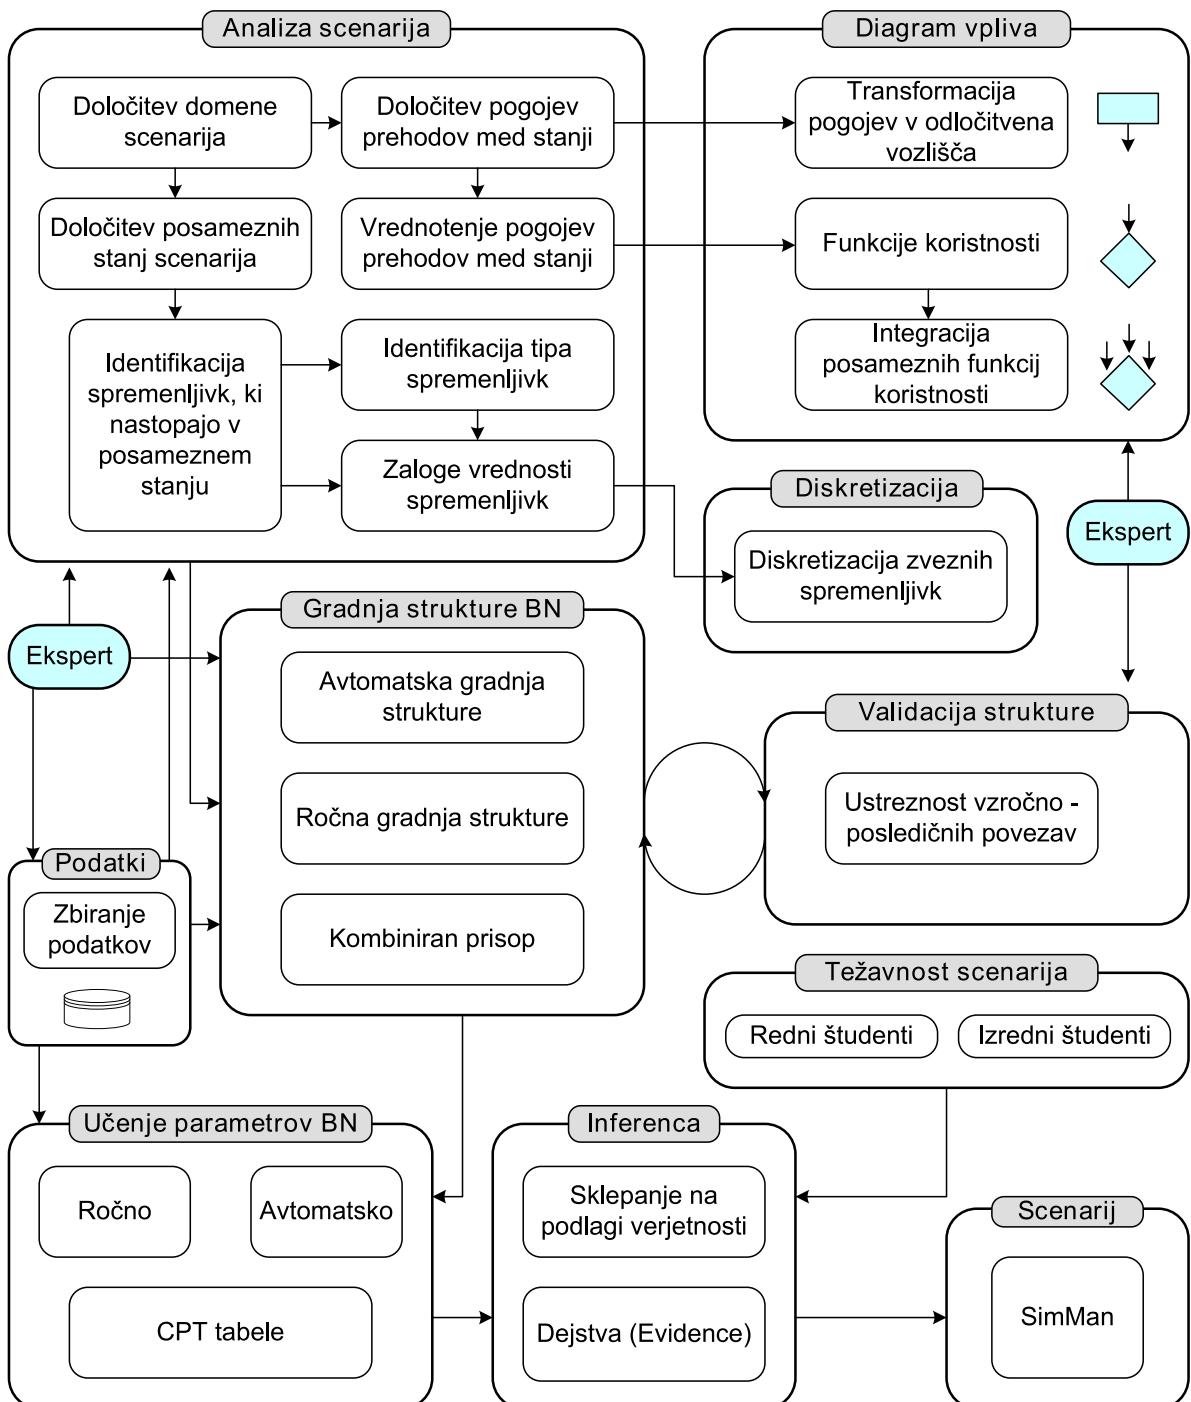
Pri gradnji scenarija gre torej za izdelovanje modela realnega sveta v določenih situacijah, ki se kasneje uporabljam za urjenje ciljnih skupin. Prvi korak metodologije CASGen je zato analiza obravnawanega problema z zajemanjem vseh potrebnih karakteristik, potrebnih za gradnjo scenarija, ki služi strokovnjaku kot podpora pri njegovem delu (shema 6.6). Pri modeliranju scenarija za simulator je tako najprej treba določiti domeno za načrtovan scenarij, kjer gre seveda za odločitev inštruktorja o urjenju za posamezne ciljne skupine (na primer izdelava scenarija za anafilaktični šok, ki spada v domeno urgentne medicine).

Za določitvijo domene scenarija sledi določitev njegovih posameznih stanj, to je stanj bolnika, ki lahko nastopijo pri obravnavi. Od tega so nato odvisni prehodi med posameznimi stanji, ki jih določi in ovrednoti strokovnjak in nastopajo v odločitvenih vozliščih diagrama vpliva. Sledi identifikacija posameznih spremenljivk za posamezno stanje bolnika, na podlagi katere lahko gradimo Bayesovo mrežo. V procesu identifikacije, kot smo že zapisali, poznamo štiri tipe spremenljivk. K že opisanim tipom spremenljivk v domeni gradnje scenarija dodajamo novo skupino "invariantnih" spremenljivk, ki so potrebne za prehod med različnimi stanji v scenariju, hkrati pa fiziološke spremenljivke v domeni scenarija predstavljajo splošne mediacijske spremenljivke kot jih bomo obravnavali v nadaljevanju. V nadaljevanju so predstavljeni tipi spremenljivk pri gradnji scenarija za simulator:

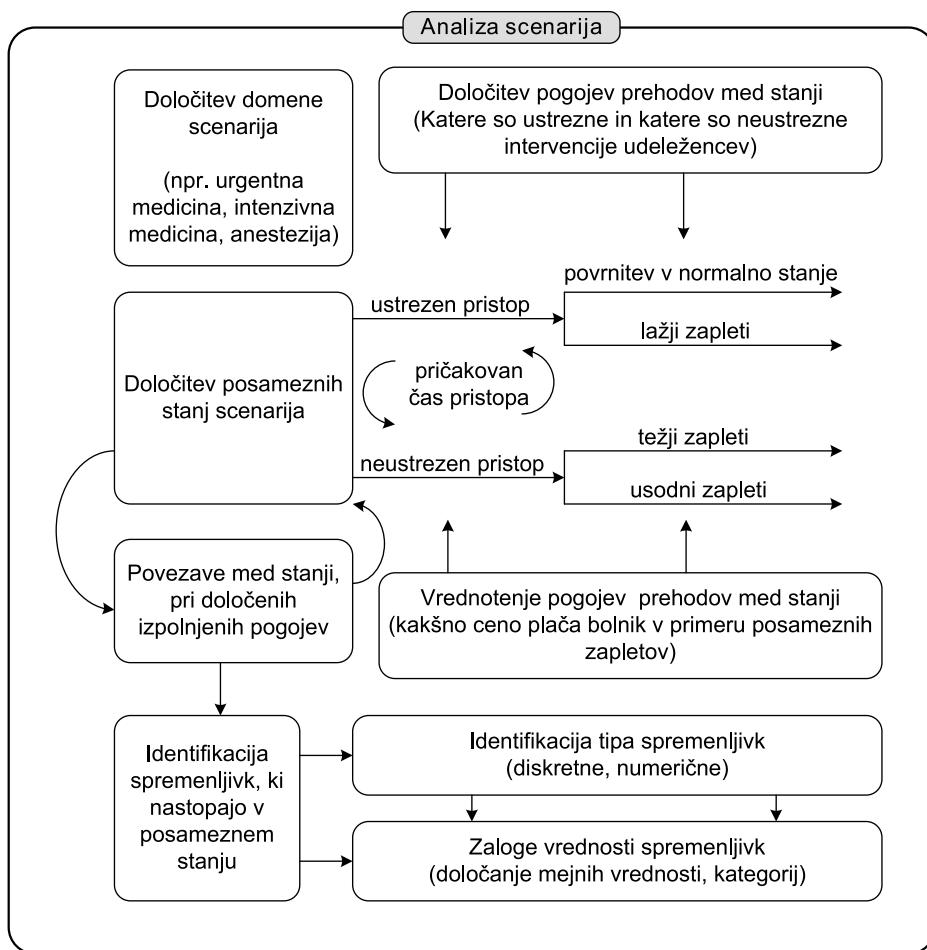
**Problemske spremenljivke**, za katere želimo izračunati posteriorno odvisnost, glede na podana opazovanja informacijskih spremenljivk,

**Informacijske spremenljivke**, za katere so lahko na voljo določeni podatki, na podlagi katerih jih opazujemo in lahko doprinesejo pomembno informacijo pri reševanju problema. Dve podkategoriji teh spremenljivk sta:

**Spremenljivke v ozadju** vsebujejo informacije v ozadju (predstavljene z eno ali več spremenljivkami) in so na voljo pred pojavitvijo problema ter imajo posledičen



Slika 6.5: Metodologija CASGen.



Slika 6.6: Analiza scenarija.

vpliv na problemske in simptomske spremenljivke (glej naslednji tip). Spremenljivke v ozadju so po navadi med poglavitnimi spremenljivkami Bayesove mreže.

**Simptomske spremenljivke** so pravzaprav posledice, ki se lahko pojavijo po pojavitvi problema. Z drugimi besedami so to problemske spremenljivke, ki imajo posledičen vpliv na njihove simptome. Po navadi so te naslednice spremenljivk v ozadju in problemskih spremenljivk. V medicini so take spremenljivke na primer simptomi z različnimi informacijami, kot so krvni tlak, vročina, glavobol, teža itn ...

**Fiziološke spremenljivke (mediacijske)** so neopazovane spremenljivke, za katere nismo interesa pri inferenci in izračunu posteriornih verjetnosti, a igrajo pomembno vlogo za dosego pravilne pogojne odvisnosti in neodvisnosti. Te spremenljivke imajo starše pogosto tipa problemskih in spremenljivk v ozadju, medtem ko so njihovi otroci simptomske spremenljivke. Pri scenarijih in simulatorju mediacijske spremenljivke predstavljajo fiziološke spremenljivke.

**Invariantne spremenljivke** so spremenljivke, katerih vrednosti se ob določenih pogojih lahko prenesejo v naslednje stanje scenarija. Invariantne spremenljivke so v scenariju podtip opazovanih spremenljivk, omogočajo pa prenos vrednosti po inferenci v naslednje stanje v scenariju, kar določi ekspert.

Pri scenariju in njegovi gradnji lahko vsaka spremenljivka v stanju spada med informacijske ali problemske odvisno od narave problema, ki ga v stanju opisujemo. Če na primer nastavljamo krvni tlak, je ta v tem primeru informacijska spremenljivka, problemska pa na primer srčni utrip, ki je od tlaka odvisen. Pri drugem primeru snovanja mreže je lahko relacija nasprotna, srčni tlak je lahko informacijska konferenca, problemska pa krvni tlak. Pri informacijskih spremenljivkah v scenariju imamo največkrat opraviti s simptomskimi spremenljivkami, v kompleksnejših primerih tudi s skritimi spremenljivkami, ki so predhodnice problemskih. V naslednjem seznamu navajamo problemske in informacijske spremenljivke, ki nastopajo v simulaciji v posameznem stanju scenarija v šestih različnih domenah:

**EKG:** EKG artifakt, QRS kompleks, EKG ritem, EMD/PEA, Extrasystole Rate, Extrasystole Delay, Heart rate

**Avskultacija:** srce, pljuča, črevo

**Krvni tlak:** sistolični, diastolični, Korotkof volume, Auscultation Gap

**Defibliracija:** Clear Shock Count, Pacing Treshold, Auscultation Gap

**Trend:**  $S_pO_2$ ,  $CO_2$ , Temp, BP Sys, BP Dia, HR, BR, CO, CVP

**Airway:** Trismus, Tongue Edema, Pharyngeal obstruction, Decreased range, Laringo Spasm, Right Pneumothorax, Left Pneumothorax, Right decreased, Left decreased, Breathing Rate, Vocal sound Sound interval, Sound number

Podrobnosti o nastavitev zapisanih spremenljivk in njihovih vrednostih ter potrebo po diskretizaciji v primerih zveznih spremenljivk smo natančno predstavili v drugem poglavju.

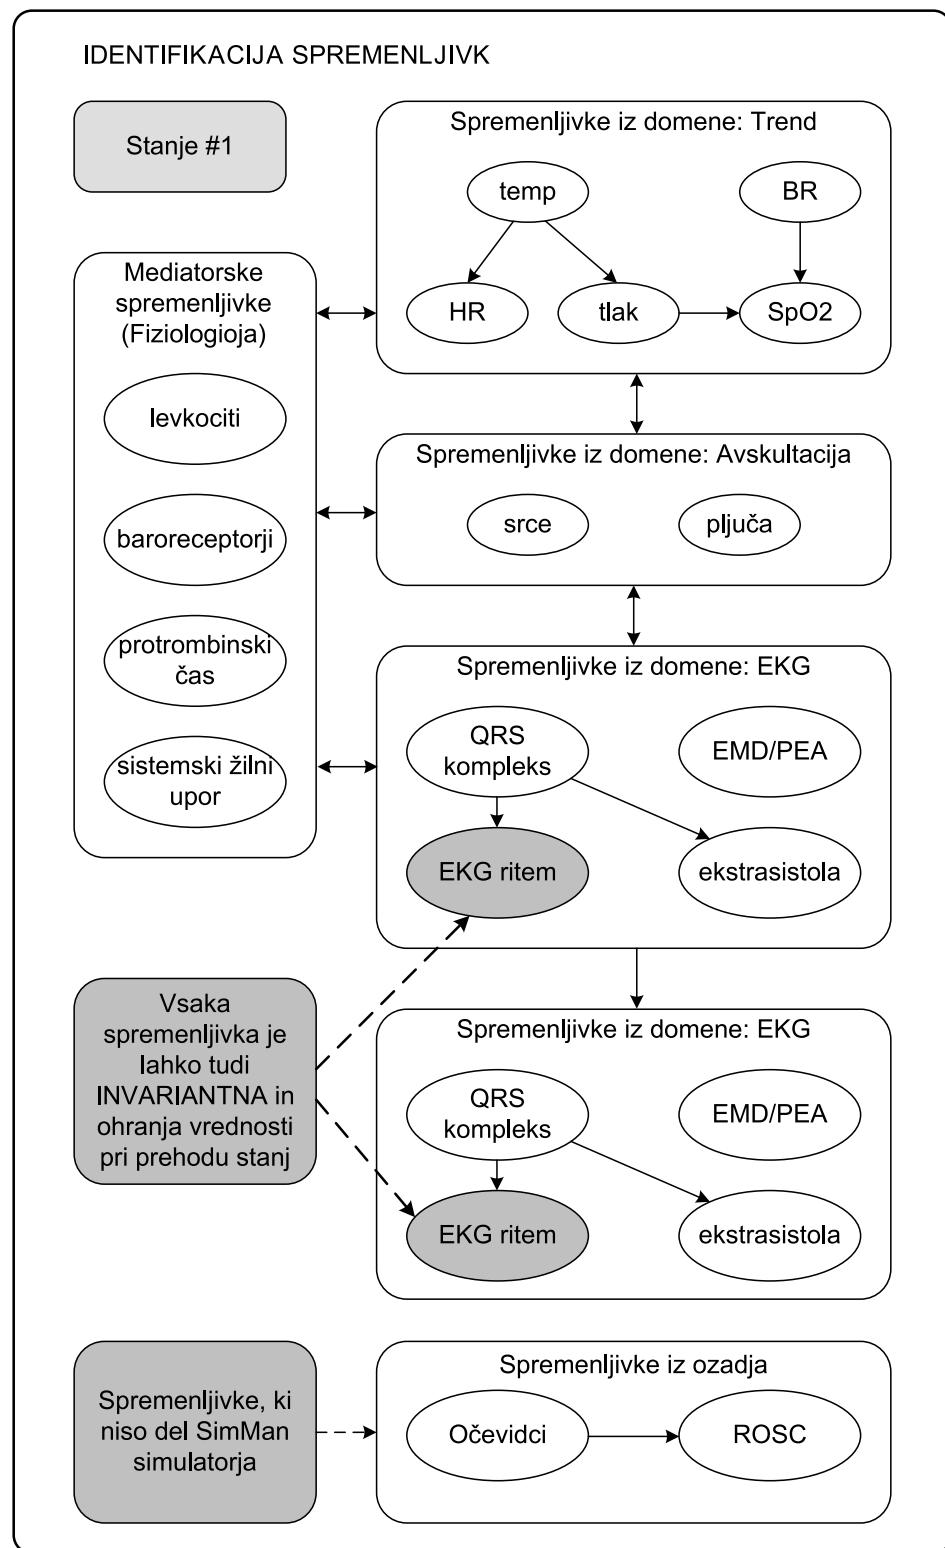
Mediacijske spremenljivke v scenariju za simulator so fiziološke spremenljivke, ki jih ne moremo opazovati in za katere nimamo interesa, so pa lahko pomembne pri izračunu pogojne odvisnosti in neodvisnosti. Fiziološke spremenljivke v scenariju predstavljajo naslednje spremenljivke:

- baroreceptroji,
- vazomotorični center,
- karidovaskularni center,
- simpatikus,
- parasimpatikus,
- sistemski žilni upor.

V naslednji tabeli 6.1 podajamo tipično vzročno odvisne relacije za različne tipe spremenljivk za scenarij.

Tip	Posledičnost od
Problemske	ni
Ozadje	spremenljivke ozadja
Fiziološke	spremenljivke iz ozadja in problemske spremenljivke
Simptomske	ozadje, problemske in fiziološke spremenljivke
Invariantne spremenljivke	ni

Tabela 6.1: Vzročno posledične povezave različnih tipov spremenljivk.



Slika 6.7: Identifikacija in tipi spremenljivk.

Določitev tipa spremenljivk in vrednosti v metodologiji, naredi ekspert s pomočjo tipov predstavljenih spremenljivk na shemi 6.7), prav tako pa tudi diskretizira spremenljivke, če gre za zvezne spremenljivke (pri gradnji scenarija smo se zaradi kompleksnosti le tega v doktorskem delu omejili na diskretne Bayesove mreže).

To so osnovni in nujni koraki, ki jih potrebujemo pri prvem sklopu metodologije CASGen za hevristično generiranje scenarija. Opisani koraki zagotavljajo popoln nabor informacij, ki so tako potrebne za snovanje scenarija s pomočjo Bayesovih verjetnostnih mrež.

## 6.5 Gradnja strukture Bayesovih mrež

Za analizo problemske domene sledi hevristični korak gradnje scenarija, pri katerem uporabimo diskretne Bayesove mreže. Kot je razvidno iz arhitekture CASGen, gradimo Bayesove mreže za posamezna stanja bolnika v scenariju, določimo jih pri analizi problemske domene. V tem koraku se odločimo tudi za način gradnje Bayesovih mrež, ki jih lahko snujemo ročno ali zgradimo s pomočjo strojnega učenja, pogosto pa za kompleksne scenarije uporabimo kombiniran pristop.

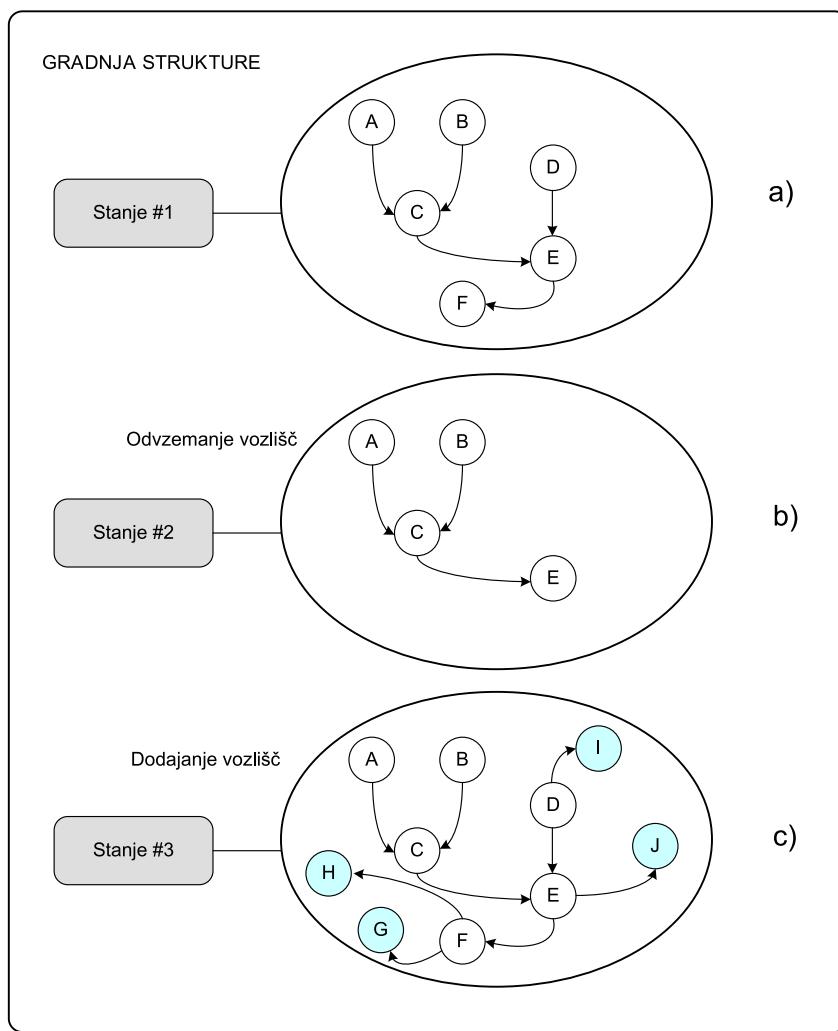
Kriteriji, ki se navezujejo na odločitev avtomatske ali ročne gradnje Bayesove mreže za posamezno stanje, izhajajo iz podatkovnih zbirk, ki jih imamo na voljo, in zahtev za strojno učenje, ki jih na kratko povzemamo. Za podatke velja, da:

- morajo biti pozorno zbrani,
- morajo vsebovati vse parametre, ki se pojavijo v BN,
- podatkovne zbirke morajo zagotavljati dovolj veliko število vzorcev.

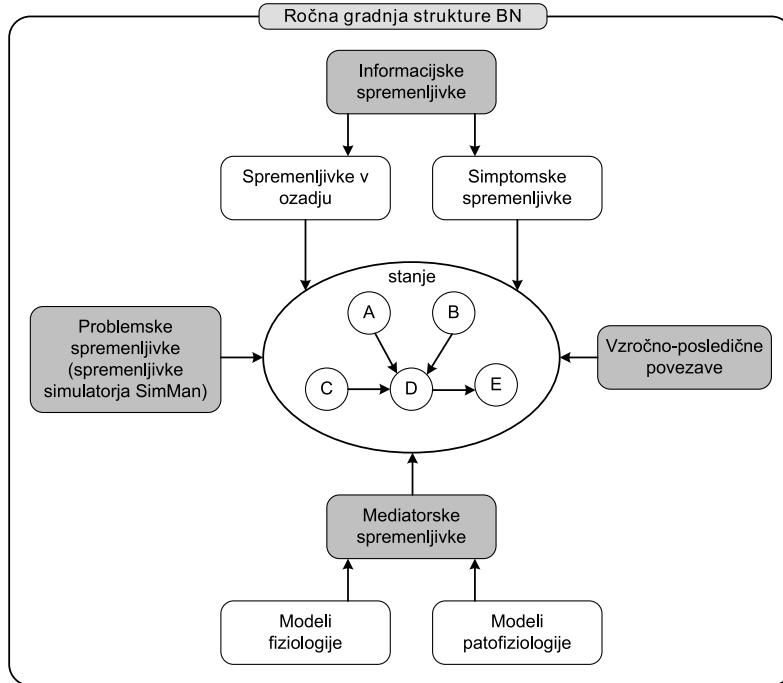
Preden posežemo po avtomatski gradnji, lahko verjetnostno mrežo v posameznem stanju scenarija spreminja in dopolnjujemo. Pri tem lahko strokovnjak doda ali odvzame vozlišče za izboljšanje predstavitve posameznih vzročno-posledičnih povezav v posameznem stanju, kot je prikazano na shemi 6.8.

### 6.5.1 Ročna gradnja Bayesovih mrež

Kot smo že zapisal, se gradnja modela BN vedno začne v dveh stopnjah: najprej je treba identificirati spremenljivke, funkcionalne in informacijske odvisnosti med njimi, ki



Slika 6.8: a) povezovanje vozlišč, glede na domeno, b) odvzemanje vozlišč, c) dodajanje vozlišč.



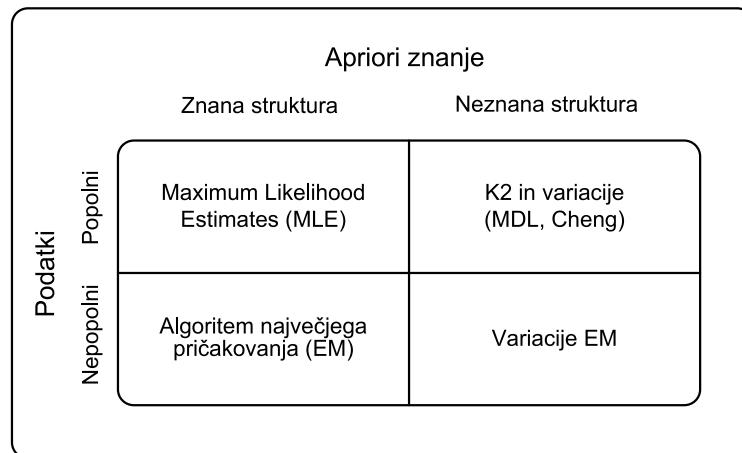
Slika 6.9: Ročna gradnja Bayesove mreže.

zagotavljajo kvalitativen del modela, nato pa sledi iterativen proces, ki vključuje testiranje spremenljivk in odvisnih ter neodvisnih kriterijev, preverjanje usmerjenih povezav, od koder se nastavijo vrednosti posameznih parametrov (6.9). V koraku gradnje verjetnostnih mrež metodologije CASGen, zahteva ročna gradnja verjetnostne mreže laboratorijsko delo, ki pogojuje sposobnosti kreativnosti in komunikacije s strokovnjakom na domenskem področju. Gre torej za korak, ko identificirane spremenljivke in njihove odvisnosti v posameznem stanju, ki smo jih določili pri analizi scenarija; sedaj uporabimo za gradnjo posamezne Bayesove mreže za posamezno stanje v scenariju.

### 6.5.2 Avtomatska gradnja Bayesovih mrež

#### Izbor algoritma za gradnjo Bayesovih mrež

Pri avtomatski gradnji se moramo odločiti za primeren algoritem, ki ga bomo uporabili za gradnjo strukture Bayesove mreže ali učenje Bayesove mreže iz podatkov. V metodologiji uporabljam v ta namen algoritme, ki smo jih teoretično predstavili v 4. poglavju in so za gradnjo strukture povzeti v naslednji shemi 6.10.



Slika 6.10: Algoritmi avtomatske gradnje BN.

## 6.6 Optimizacija in učenje parametrov

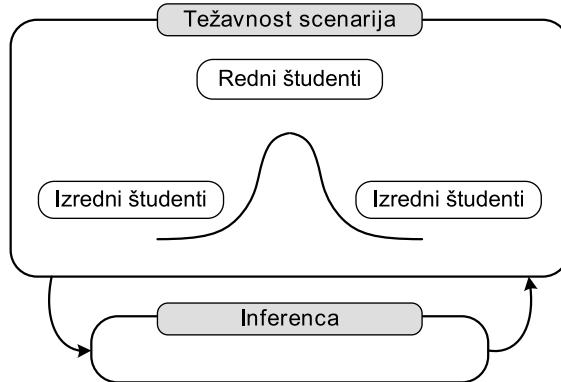
V poglavju 4 smo natančno zapisali postopek učenja Bayesovih mrež. Metodologija CASGen izhaja pri optimizaciji mreže in učenju mreže iz podatkov iz teoretičnih zasnov in pri tem določa primerno izbiro algoritma učenja.

## 6.7 Integracija Bayesovih mrež v scenarij

Posamezne BN, razvite za stanje v scenariju, povežemo v scenarij s pomočjo diagramov vpliva. Kot smo zapisali v arhitekturi metodologije CASGen, diagrami vpliva predstavljajo mehanizem, s pomočjo katerega lahko učinkovito ocenimo koristi posameznih aktivnosti, in na tak način scenarij povežemo v celoto. V integraciji stanj se v scenariju upoštevajo tudi invariantne spremenljivke, ki omogočijo prenos določenih vrednosti spremenljivk iz enega v drugo stanje ob določenem pogoju in na neki način povezujejo spremenljivke posameznih Bayesovih mrež med seboj, sicer v ne-vzročno posledičnem, temveč invariantnem smislu.

## 6.8 Uporaba inference v scenariju

Inferenca, sklepanje na podlagi verjetnosti v Bayesovi mreži, je lastnost BN, ki v metodologijo CASGen vnaša izboljšavo pri upravljanjem s scenarijem na določeni ciljni skupini. S pomočjo postavitev gotovosti lahko v realnem času generiramo različne scenarije za



Slika 6.11: Izbira težavnosti scenarija.

posamezen problem, ki ga urimo na simulatorju. Kot smo zapisali v poglavju o inferenci, uporabljamo v ta namen različne algoritme, v našem primeru metodologije uporabljamo najbolj razširjen inferenčni algoritem EM [95].

### 6.8.1 Težavnost scenarija

Težavnost scenarija pride v poštev pri uporabi scenarija za določeno ciljno skupino študentov (zaposleno izkušeno osebje iz bolnišnice, študentje brez kliničnih izkušenj). Glede na ciljne skupine, lahko s pomočjo inference in postavitev gotovosti v posameznem stanju avtomatsko omogočimo primerno zahtevnost scenarija za posamezno skupino, kar je prikazano na shemi 6.11.

## 6.9 Zapis podatkov za strojno obdelavo

Metodologija CASGen predvideva zraven opisanih korakov tudi postopek s katerim lahko podatke iz realnega okolja zbiramo za primeren način, ki je uporaben v metodologiji. V primeru, da na nimamo na voljo realnih podatkov na podlagi katerih bi lahko izdelali strukturo Bayesove mreže za posamezno stanje v zapisanem scenariju ali omogočili optimizacijo mreže na podlagi realnih podatkov in smo zato primorani uporabiti ročno gradnjo Bayesovih mrež, v metodologiji CASGen podajamo postopek za zbiranje podatkov za stanja scenarijev, ki jih lahko v prihodnje generiramo na podlagi primerov iz realnega okolja in tako uporabimo metodologijo CASGen za generiranje posameznih stanj scenarija.

Da bi ekspertom pri gradnji scenarijev za simulator omogočili uporabo realnih študij, v tem podoglavlju podajamo napotke za zbiranje podatkov, ki temeljijo na splošnih in specifičnih dejstvih, izhajajočih iz uporabe metod strojnega učenja, v našem primeru Bayesovih mrež, na podlagi katerih je mogoča učinkovita uporaba metod strojnega učenja na zbranih podatkih. Pri tem so zaželene naslednje lastnosti:

- identifikacija relevantnih spremenljivk za podatkovno zbirko
- ovrednotenje posameznih spremenljivk za posamezen primer (nezaželeni manjkajoči podatki)
- reprezentativna vrednost zbranega vzorca

### 6.9.1 Identifikacija relevantnih spremenljivk za podatkovno zbirko

Za zbiranje realnih podatkov na podlagi katerih je mogoče izdelati posamezno stanje scenarija je treba zagotoviti identifikacijo vseh relevantnih spremenljivk, za katere bomo v zbirki hranili vrednosti - glede na diagnozo. Naloga eksperta je v tem primeru torej izbira tiste množice simptomov, ki bi lahko vplivali na diagnozo, kot tudi potencialne množice simptomov, za katero bi bilo mogoče, da imajo določen vpliv. Seveda je pri tem dobro upoštevati strukturo simulatorja in njegovih spremenljivk za posamezne scenarije, saj lahko na podlagi tega sestavimo učinkovito podatkovno zbirko na podlagi katere bo mogoče zgraditi posamezno stanje v simulatorju. Pri tem je treba poudariti, da vsaka spremenljivka oziroma simptom v Bayesovi mreži zrcali prirejeno vozlišče s povezavami. Zato je treba zagotoviti primerno število parametrov, sicer lahko Bayesova mreža zavzame preveliko vozlišč in postane nepregledna, s tem pa tudi težje uporabna za inštruktorja, ki bo njen strukturo uporabljal v simulatorju.

V primeru velikega števila zbranih simptomov lahko zato posežemo po tehnikah izbire ali selekcije atributov, kar predstavlja pomemben korak v podatkovnem rudarjenju in tako za Bayesovo mrežo na podlagi le-tega izberemo primerno število vozlišč, ki so primerna za uporabo v simulatorju. Pri tem se lahko poslužujemo različnih tehnik izbire parametrov, ki temeljijo na statističnih izračunih, kot so diskriminantna analiza, fraktalna kodiranja, uporaba valjčne transformacije, informacijska neodvisnost in analiza osnovnih komponent. Ta je med njimi najbolj zastopana in temelji na klasični statistiki in določitvi takšnih karakterističnih parametrov, ki opisujejo čim večjo možno razpršenost v podatkih z najmanjšim številom lastnosti.

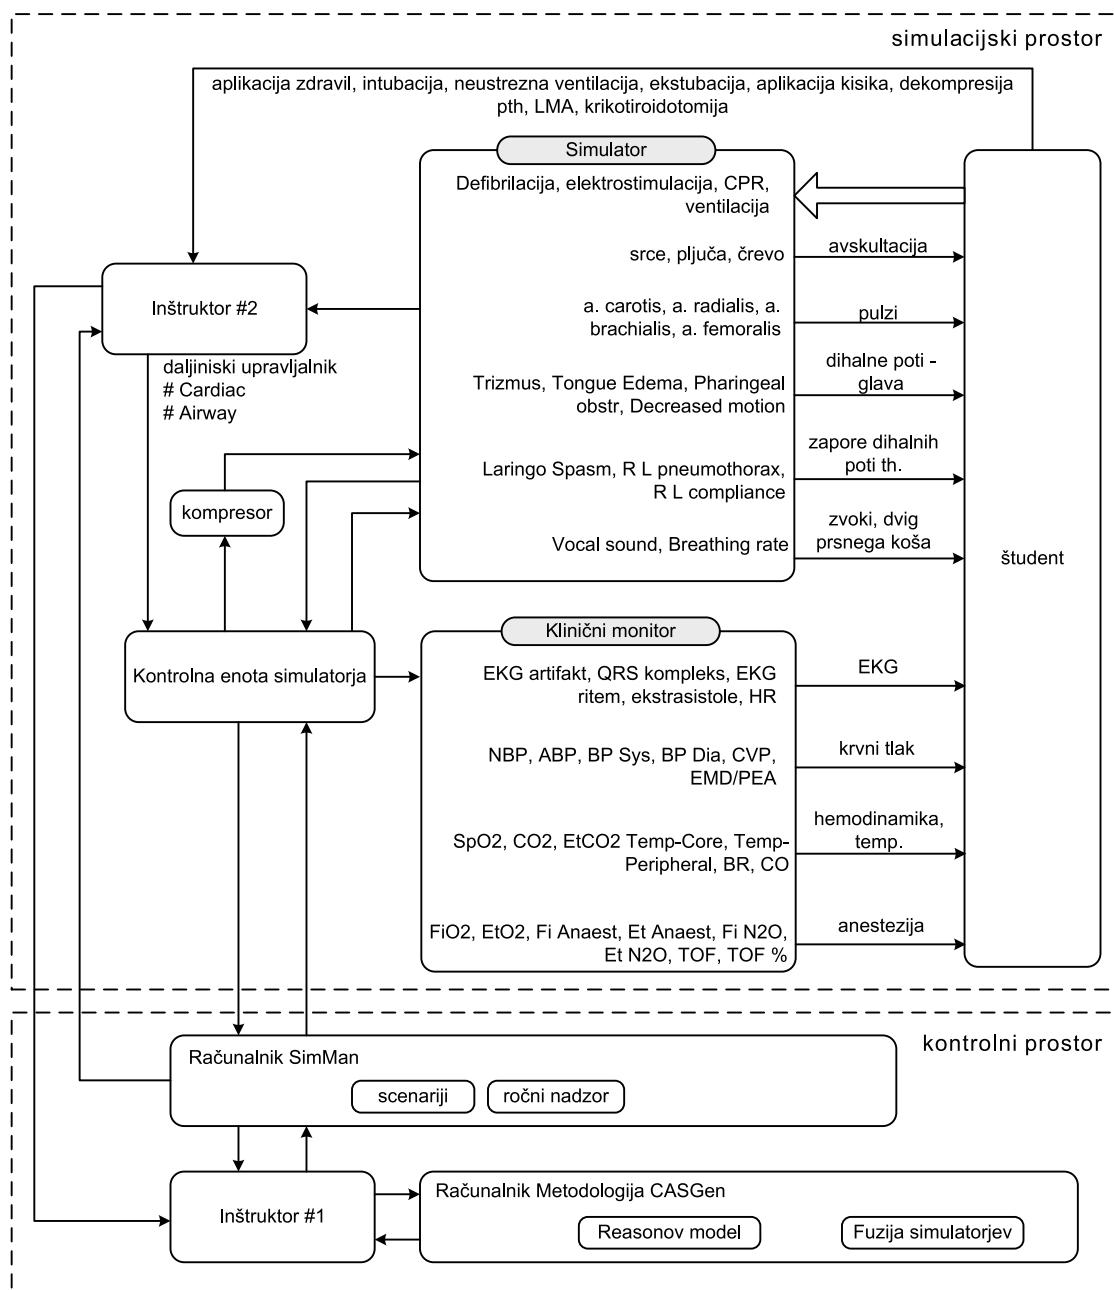
### 6.9.2 Reprezentativna vrednost zbranega vzorca

Le če bomo obravnavali dovolj velik vzorec izbranih primerov iz realnega okolja, bo posodobljena mreža na podlagi učenja parametrov ali mreža, katero strukturo in parametre smo se naučili iz podatkov, predstavljalna uporaben vzorec znanja, ki ga lahko uporablja ekspert kot pomoč pri gradnji scenarija. Po navadi je za statistično obdelavo in torej tudi obdelavo z metodami strojnega učenja minimalna zahtevana množica vzorcev velikosti trideset. Če imamo namreč opraviti z manjšim številom vzorcev, težje govorimo o zanesljivosti in prikazano znanje ne odraža slike v realnosti. Zato za število vzorcev priporočamo petdeset ali več izbranih primerov za posamezno stanje v scenariju, ki ga želimo doplniti na podlagi vrednosti iz realnega okolja.

Šele na podlagi omenjenih karakteristik lahko zbrane podatke integriramo v stanja scenarija z metodo Bayesovih mrež, saj nam bodo ob omenjenih predpostavkah pridobili dovolj kvalitetno predstavitev znanja, ki ga lahko uporabimo pri urjenju simulacij v simulacijskem okolju.

## 6.10 Umestitev metodologije CASGen v simulacijsko okolje.

Simulacije v medicini vključujejo uporabo simulatorjev, s katerimi posnemamo realno klinično okolje, v katerem je bolnik ali ponesrečenec. Simulacijsko okolje, kjer se izvajajo medicinske simulacije, predstavlja integracijo informacijsko-komunikacijskih tehnologij in realne medicinske opreme ter učnega procesa. Razvita metodologija CASGen za gradnjo hevrističnega scenarija za simulator se v simulacijsko ustrezno prostorsko okolje umešča kot člen 1), s pomočjo katerega lahko inštruktor hevristično generira scenarije za posamezen učni problem v kompleksnih diagnostičnih in terapevtskih postopkih v domeni anesteziologije, intenzivne nege in perioperativnega zdravljenja, in 2) tak scenarij potem v okolju tudi uporablja. Shema 6.12 predstavlja umestitev metodologije CASGen v simulacijski prostor, ki je sestavljen in simulatorja, kliničnega monitorja, kontrolne enote simulatorja, računalnika in programske opreme za SimMan ter inštruktorja-razvijalca, inštruktorja uporabnika in študentov. Iz predstavljene sheme je razvidna uporaba metodologije CASGen pri inštruktorju. Le-ta si s pomočjo metodologije izdela hevristično generiran scenarij, ki ga prenese v računalnik za simulator SimMan, ta komunicira s kontrolno enoto za simulator in kliničnim monitorjem, preko katerih se študentje urijo na izdelanem scenariju. Jasna je tudi ločitev simulacijskega prostora od kontrolnega prostora, kjer v slednjem nastajajo scenariji, na katerih se urijo študentje.



Slika 6.12: Umestitev metodologije v okolje.

## 6.11 Reasonov krizni model in metodologija CASGen

Pri kompleksnih medicinskih obravnavah obstaja velika verjetnost neželenih kriznih dogodkov. Pri takih dogodkih lahko pride do poškodb ali celo smrti bolnika. Ti nevarni dogodki po navadi ne nastopijo samo zaradi enega posameznega vzroka, ampak je vzrok več in si sledijo v določenem časovnem zaporedju. Skupino takih dogodkov lahko predstavimo z modelom, ki vsebuje posamezne lupine; vsaka lupina posebej predstavlja zaščitno plast pred opisanimi neželenimi dogodki. Takemu modelu pravimo Reasonov model in smo ga že omenili v poglavju 2.3.2 na shemi 2.16.

V tem modelu je obramba pred neželenimi škodljivimi učinki zgrajena iz več posameznih varnostnih plasti oziroma lupin. Vsaka plast skrbi za specifično obrambo pred neželenimi škodljivimi učinki. Napake na posamezni plasti so predstavljene v kontekstu lukenj švicarskega sira, kjer luknje v rezinah sira nastajajo zaradi morebitnih aktivnih in latentnih napak (pogojev).

Aktivne napake so nevarna dejanja, ki jih povzročijo zdravstveni delavci v neposrednem stiku z bolnikom. Zdravstveni delavci tako kot vsi ljudje delajo napake, spodrljajo, so lahko v zmoti ali pa so nerodni. Aktivne napake nastajajo na tako imenovanem "ostrem robu skalpela" in se takoj opazijo. Preobremenjeni zdravstveni delavci negativno vplivajo na varnost bolnikov [47].

Latentni pogoji so skrivne patogene napake na "topi strani skalpela", ki neprestano bivajo in živijo znotraj sistema. Latentne napake je težje odkriti in se jih večkrat niti ne zavedamo. Nastajajo iz nepopolne standardizacije postopkov, napak v samem načrtovanju varnostnih protokolov in v najvišji vodstveni strukturi delovne organizacije.

Luknje na posameznih stopnjah predstavljajo pomanjkljivosti, ki se s časom pojavijo ali pa izginejo. V idealno organiziranem zdravstvenem sistemu ni prisotnih nobenih lukenj. Luknje v sistemu sira se neprestano premikajo, odpirajo in zapirajo ter spreminjajo lokacijo. Prisotnost lukenj v eni plasti pa ne pomeni nujno tragične posledice, saj kratkoročno vplivajo na integriteto obrambnega sistema. Nevarni dogodek se zgodi, ko se luknje v nekem časovnem trenutku v vseh rezinah med seboj poravnajo in tvorijo trajektorijo. V takem spletu okoliščin nastopi nesrečni nevarni škodljivi učinek.

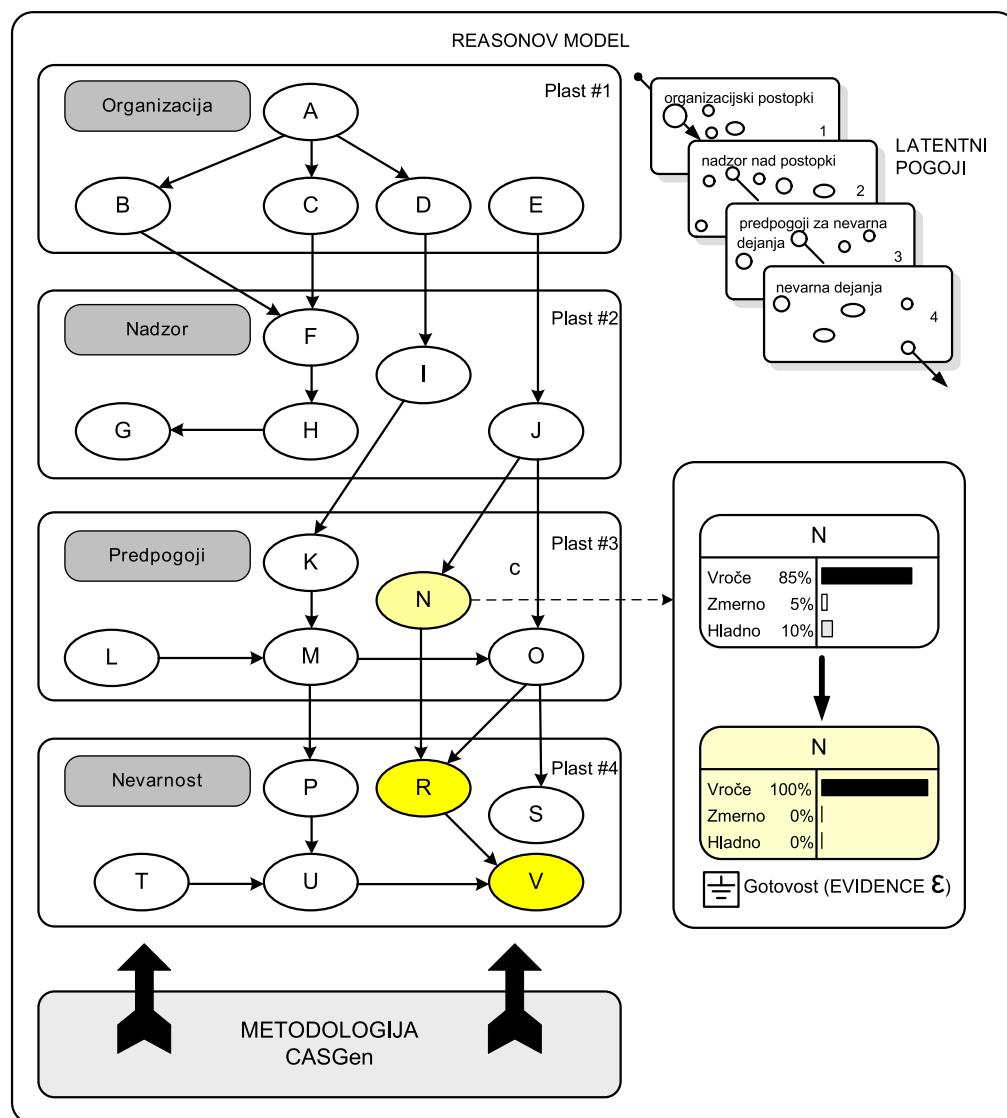
Na prvi plasti obrambe so organizacijski postopki, kjer se že vnaprej razmišlja, kako preprečiti napake z vidika organizacije dela. Druga plast predstavlja nadzor nad izvajanjem sprejetih kliničnih smernic in drugih standardov za varno delo. Na tretji plasti so predpogoji nastanka škodljivega učinka. Sem spadajo neustrezne razmere za delo (tem-

peratura, vlaga, osvetlitev). Na tej ravni moramo upoštevati tudi izgorevanje delavcev, nezainteresiranost za delo, utrujenost itn. Na četrti plasti so sistemi, ki imajo naloge preprečiti aktivne napake. Človeški faktor kirurga ali anesteziologa privede do aktivnih napak, ki pa živijo le kratek čas. Na tej ravni se pojavijo napake, kot so spodrsljaji, zmote, nerodnosti, nespretnosti in kršitve procedur in smernic. Varovalni sistemi na tem mestu so predvsem tehnične narave (alarmi, fizične pregrade, avtomatski izklopi).

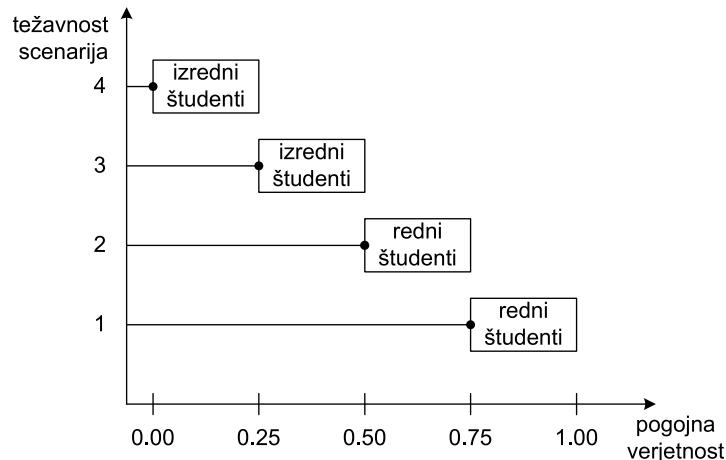
Na shemi 6.13 je predstavljena gradnja sekvenčnega Reasonovega modela nastanka škodljivega učinka po metodologiji CASGen. Vsaka plast vsebuje spremenljivke, ki jih po metodologiji CASGen obravnavamo kot Bayesovo mrežo (BN) s posameznimi vozlišči. Vozlišča so znotraj posamezne plasti med seboj povezana v smislu vzročno-posledičnih povezav, kot na primer vpliv odgovornega delavca na svojega pomočnika v organizacijski lupini. Določena vozlišča v lupini so nato povezana z drugimi vozlišči v naslednji lupini in tako tvorijo usmerjen aciklični graf. Celotno BN je najbolje zgraditi s pomočjo ekspertov in jo naučiti preko podatkovne baze, ki bi se lahko zbirala za ta namen. Pri izračunu inference in dobljenih apriornih vrednostih vseh spremenljivk bi se nato določila trajektorija škodljivega dogodka, upoštevajoč največje verjetnosti in njihove povezave skozi celotno strukturo Reasonovega varnostnega modela.

Pri izvedbi scenarija z vpeljavo Reasonovega modela je v fazi simulacije zanimiva umestitev inference po metodologiji CASGen, glede na gotovost (evidence), ki se pojavi med izvajanjem scenarija. Na sliki je prikazan primer vozlišča, označenega z N, ki je v lupini predpogojev za nevarna stanja. To vozlišče nam na primer predstavlja razmere za delo v operacijski dvorani, povezane s temperaturo prostora. Slike razberemo, da je 85% verjetnosti, da se bo temperatura v dvorani zelo dvignila, kar je posledica razmer oziroma pomanjkljivosti iz predhodnih lupin Reasonovega modela. Zaradi visoke verjetnosti postavimo to vozlišče kot gotov dogodek in v scenariju upoštevamo, da se je realno temperatura v delovnem prostoru dvignila in tako nastopijo mnogo teže razmere za delo, predvsem za kirurško ekipo. Nastane spodrsljaj, ko kirurg po pomoti aktivira elektrokirurški aparat na kovinskem delu operacijske mize, označen z vozliščem R. Tak spodrsljaj bi privadel do poškodbe bolnika in opeklina, če bi zatajil alarmni sistem, predstavljen z vozliščem V. Genezo oziroma nastanek alarma bomo v nadaljevanju tudi opisali, kratka predstavitev pa je podana v poglavju 2.3 na sliki 2.17.

Reasonov model se nam zdi smiseln vpeljati v sistem gradnje medicinskih scenarijev, saj moramo imeti pri procesu nastajanja scenarija v mislih holistični pristop. Kljub temu da je osrednja tematika doktorskega dela scenarij za visokonivojski simulator, je



Slika 6.13: Uporaba metodologije CASGen za gradnjo Reasonovega varnostnega modela.



Slika 6.14: Različne težavnostne stopnje scenarija.

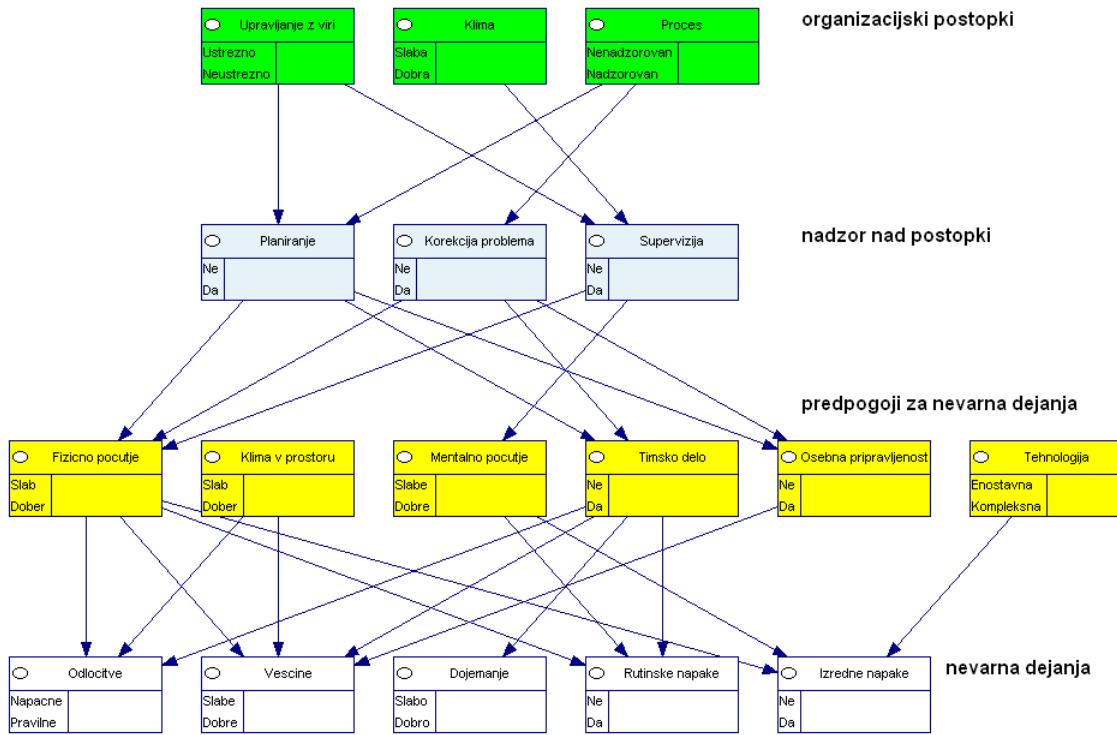
treba razmišljati v celovitem kontekstu vseh mogočih vplivov, ki se pojavijo v realnem življenju. Bistvo simulacijskih scenarijev pa je ravno v tem, da se čim bolj približajo realnim okoliščinam.

## 6.12 Nadaljnje delo

### 6.12.1 Težavnostne stopnje scenarija

Bayesove mreže (BN) obravnavajo problemsko domeno gradnje medicinskih scenarijev z vidika pogojnih verjetnostnih porazdelitev, ki jih moramo transformirati v ustrezne dogodke v scenariju. Na shemi 6.14 so predstavljene štiri težavnostne stopnje scenarija, ki jih lahko izluščimo iz BN. Rednim študentom generiramo scenarije v mejah pogojnih verjetnostih med 0,75 in 1 oziroma med 0,50 in 0,75. Ti dve področji določata dve vrsti scenarijev: za študente brez kakršnih koli izkušenj se scenariji začnejo v mejah med 0,75 in 1, medtem ko se za študente, ki so se že urili v scenarijih na prejšnjih mejah, te meje na novo postavimo med 0,5 in 0,75. Verjetnosti posameznih stanj scenarija so pogojno odvisne od vseh ostalih vrednosti, ki nastopajo v BN. Za izredne študente uporabljamo redka stanja, ki so s konteksta verjetnosti v BN med 0 in 0,25 oziroma med 0,25 in 0,50.

Pri gradnji scenarija smo se omejili na diskretne spremenljivke, medtem ko simulator SimMan večinoma manipulira z numeričnimi spremenljivkami, ki so predstavljene v tabelah v 2. poglavju. Vendar se je v doktorskem delu pokazala druga dobra plat uporabe BN, in sicer pri gradnji opisnih scenarijev, ki so pravzaprav eno raven višje od



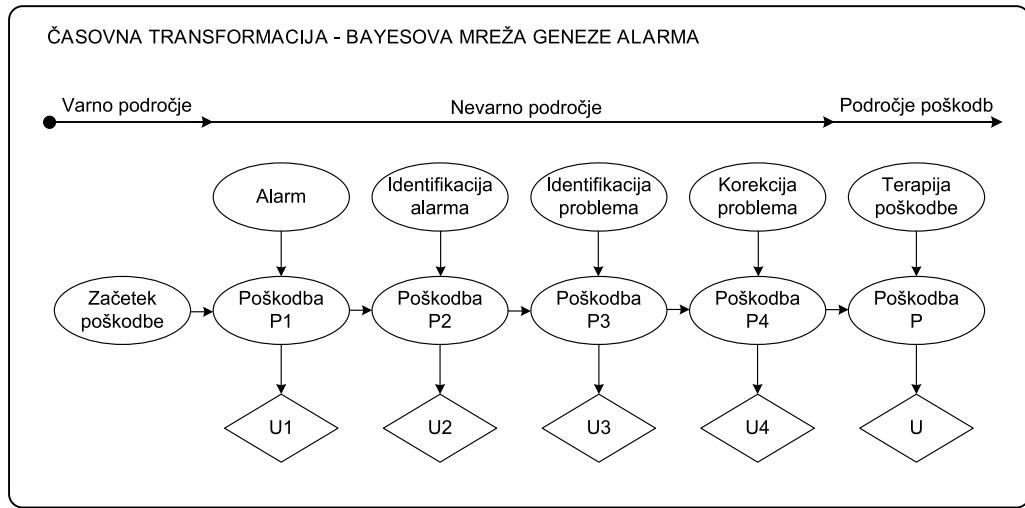
Slika 6.15: Reason BN.

konkretnega scenarija, ki poteka na simulatorju. To je priprava simulacijskega okolja, izbira bolnika ali ponesrečenca in ciljna težavnost oziroma enostavnost scenarija.

### 6.12.2 Gradnja Reasonovega modela

Na shemi 6.17 je prikazan primer, kako se pripravi krizni scenarij z uporabo Reasonovega kriznega modela, že opisanega v prejšnjih poglavjih. Model se po metodologiji CASGen razdeli na lupine, kjer vsaka lupina vsebuje spremenljivke posamezne varnostne stopnje. Povezava spremenljivk se izvede s pomočjo ekspertov. Prav tako je mogoča gradnja celotne strukture BN s podporo že objavljenih znanstvenih prispevkov, ki obravnavajo Reasonov model. Tak pristop smo tudi uporabili pri gradnji našega modela, prikazanega na shemi Reasonovega modela. Raziskovanja, ki so za to potrebna, morajo potekati v smeri, kako izluščiti CPT tabele na podlagi podatkov klasične statistike, ki jih predstavljajo avtorji prispevkov Reasonovega modela.

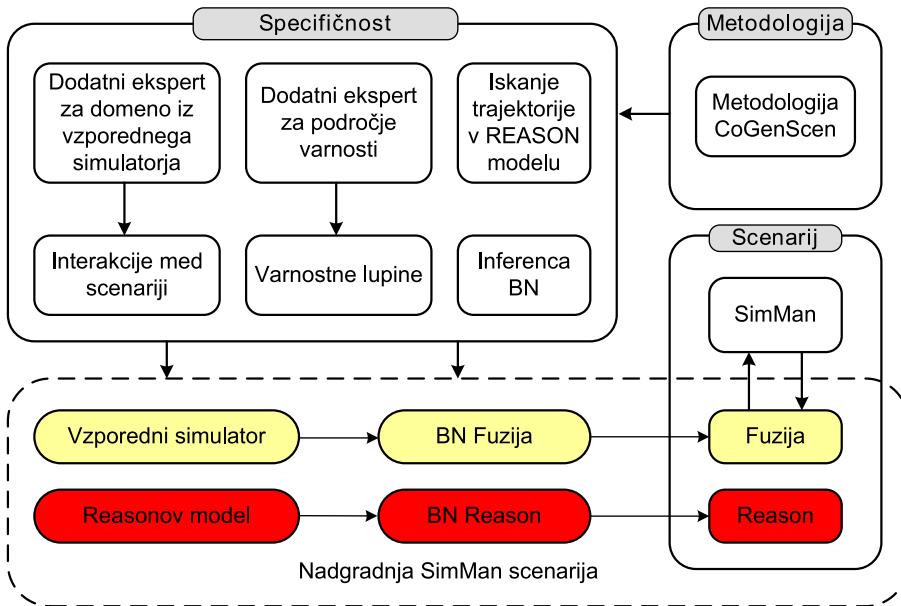
Na zadnji lupini Reasonovega modela so tudi varnostni alarmni sistemi, ki neposredno ščitijo bolnika pred nevarnimi stanji. Pri gradnji medicinskih scenarijev nam je to področje zanimivo zato, da lahko ovrednotimo in posledično simuliramo reakcije udeležencev



Slika 6.16: Predstavitev geneze alarma z BN.

tečaja na potencialne poškodbe. Geneza alarmra je bila v predhodnih poglavjih že opisana. Ko se začne poškodba, scenarij prehaja z varnega področja v nevarno in, če ni ustreznega ukrepanja, v področje poškodb. Nastanek alarmra smo modelirali z BN, ki je predstavljena na shemi 6.16.

Kljub temu da gre pri nastanku alarmra za dinamičen proces, smo ga modelirali s klasično BN, kjer smo stopnjevali poškodbo. Novo stanje poškodbe je pogojno odvisno od stopnje prejšnje poškodbe oziroma intervencij, ki jih izvedejo (ali jih ne izvedejo) udeleženci tečaja. Ta koncept časovne transformacije Bayesove mreže je predstavil Heckerman [8], ki ga je pozneje s sodelavcem tudi izboljšal [10]. Pri tem scenariju alarmra vsako odločitev oziroma ignoriranje alarmra ovrednotimo s funkcijami koristi, ki predstavljajo diagram vpliva, s katerim smo nadgradili osnovno Bayesovo mrežo. Uporaba takšne časovne transformacije pride v poštev, kadar imamo vzročno-posledične relacije, ki si sledijo v časovnem zaporedju. Udeleženec tečaja je na primer slabo pozoren na nastavitev aparata, kjer ja alarm onemogočen ali pa je sam udeleženec pozabil preveriti, ali je alarm omogočen ali onemogočen. Poškodba P1 nato vpliva na poškodbo P2, ki pa je odvisna od tega, kako hitro bo udeleženec identificiral alarm. V naslednjih fazah mora udeleženec identificirati problem in ga korigirati. Če je udeleženec tečaja spregledal alarm, in je bolnik utrpel hujšo poškodbo, je le-ta odvisna od terapije, ki jo izvajajo udeleženci. Spremenljivka poškodbe ima v tem primeru enak prostor vrednosti, saj gre le za stopnjevanje mehanizma poškodb.



Slika 6.17: Fuzija simulatorjev.

### 6.12.3 Fuzija simulatorjev

Univerzalnega simulatorja, ki bi pokrival širok spekter medicinskih domen, danes ne bomo našli na tržišču. Simulatorji so specifični na primer za kirurgijo, anestezijo ali intenzivno medicino in pokrivajo samo ozko področje specifičnega uporabnika. Zaradi potrebe po komunikaciji in skupnem vzajemnem delovanju različnih ekip, ki sodelujejo v zdravljenju, je iskanje ustreznih rešitev na tem področju velik izzik. V številnih raziskavah je že bilo pokazano, kako je pomembno sodelovanje različnih timov, predvsem, ko gre za zelo intenzivno in invazivno zdravljenje, kot so na primer težki kirurški posegi. V takih primerih je danes edina rešitev postavljanje dveh simulatorjev v eno simulacijsko okolje. Enostaven primer, ki ga izvajamo na izobraževanju študentov je že bil prikazan na slikah 2.10 in 2.11. Endoskopski simulator postavimo v neposredno bližino simulatorja anestezije in izvajamo vzporedne simulacije. Te simulatorje smo v drugem poglavju poimenovali kot fuzijo simulatorjev. Izgradnja Bayesovih mrež je v teh primerih nekoliko zahtevnejša zaradi specifičnosti, ki smo jih pokazali na shemi 6.17.

Za fuzijo simulatorjev potrebujemo dva eksperta, ki morata biti usklajena zaradi prepletanja obeh področij. Povezavo med dvema simulatorjema napravimo tako preko BN, ki deluje kot povezava med scenariji obeh simulatorjev. Če vpeljemo še Reasonov model kontrole nad kriznimi situacijami, dobimo simulacije, ki so že dosti bližje realnim razmeram.

#### 6.12.4 Integracija metodologije v METI simulator

Pomembna lastnost METI simulatorja je, da ga lahko kadar koli preklopimo v tako imenovan *ročni način*. V tem načinu je omogočeno, da vse parametre simulatorja ročno spremenjamo ali nastavljamo začetne in končne vrednosti spremenljivk ter dinamiko sprememb. S tega stališča je metodologija uporabna zaradi inference, ki je bistvo BN. Preko inference, kjer za gotovosti vzamemo že opravljene aktivnosti študentov, gledamo, kako bomo vodili scenarij. Na ločenem računalniku, ki je bil predstavljen na sliki umestitve scenarijev v simulacijski prostor, izvajamo te aktivnosti ob podpori več BN, ki tečejo vzporedno, kar je prikazano na shemi 6.18.

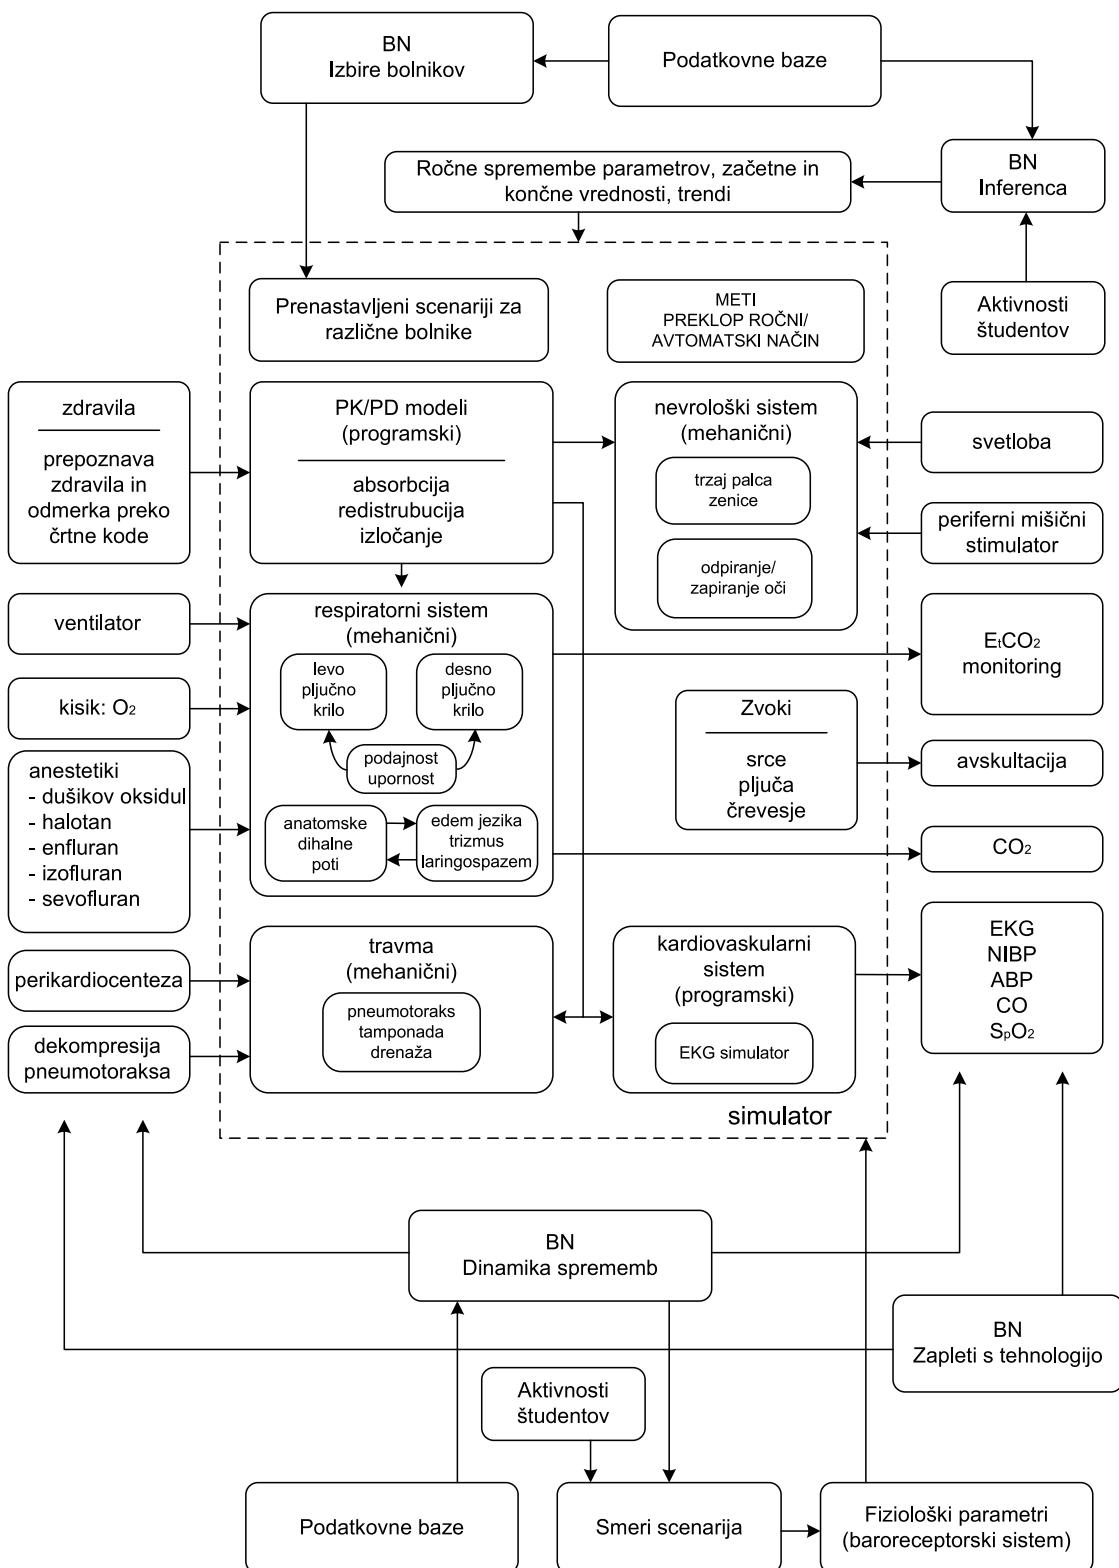
Bayesova mreža nima prevelikega uspeha za podrobno modeliranje vzročno-posledičnih spremenljivk celotnega simulacijskega sistema. Takšno delo bi predstavljalo zelo kompleksen pristop in vprašanje je, če bi bil sploh smiseln. Simulator METI ima na primer večino fizioloških modelov že integriranih in delujejo dobro. Regulacija krvnega tlaka pa v METI simulatorju modelirana preko baroreceptorskega sistema, ki smo ga opisali v poglavju empirične študije anafilaktične reakcije. V človeškem organizmu so regulacijski mehanizmi sklenjene zanke po navadi z negativnimi povratnimi vezavami, kar pa ni dovoljeno pri gradnji BN, saj gre za usmerjene aciklične povezave, kjer so cikli prepovedani. Takšne zanke lahko edino prekinemo in modeliramo samo posamezne veje, kar smo tudi storili na primeru baroreceptorjev pri regulaciji arterijskega tlaka. Bayesove mreže nam v teh primerih lahko služijo kot pokazatelj, v katero smer se bo usmeril določen fiziološki podmodel. V ročnem načinu je mogoče namreč nastaviti stopnjo proženja akcijskih potencialov, ki jih oddajajo baroreceptorji ali različne zaplete, povezane s tehnologijo.

Bayesove mreže v generiranju scenarijev nam pomagajo pri izvajanju globalnih scenarijev, nujno potrebnih za realno simulacijo. Profil izbire bolnika na METI simulatorju, bi glede na različne pogoje, določili s pomočjo BN. Enostaven koncept tega primera smo že podali na empirični študiji srčnega zastoja. METI simulator ponuja že nekaj konfiguriranih scenarijev, ki predstavljajo bolnike različnih starosti, fizioloških parametrov, zgodovino bolezni in spolov:

- 33-letni moški, zdrav, brez bolezni,
- 29 let starca ženska, 40 tednov noseča,
- 70-letna ženska, kadilka, hipertenzija,
- 61-letni moški, alkoholik, kadilec, bolezni koronark in KOPB,

- 18-letni moški, zdrav, hipertermičen, hipermetaboličen in dehidriran zaradi intenzivne fizične aktivnosti.

Profili bolnikov so stabilni, dokler jih ne spremeni inštruktor ali na njih vpliva študent s svojimi posegi/aktivnostmi. Uporabnik lahko spreminja preko 100 fizioloških parametrov (na primer sistemski žilni upor, volumen krvi v obtoku, itd). V vsaki časovni točki simulacije se lahko stanje posname in se kasneje uporabi kot nov bolnik. Z BN je mogoče iskati ustrezni scenarij iz parametrov posnetih delnih scenarijev in ustvariti adaptivni učni sistem. Metodologijo prav tako lahko uporabimo pri simultanih simulacijah več bolnikov, kot je primer oddelek intenzivne nege ali množične nesreče.



Slika 6.18: Bayesove mreže kot podpora METI simulatorju.



## Del IV

# Rezultati



## Poglavlje 7

# Validacija CASGen na scenariju predbolnišnične reanimacije

### 7.1 Predstavitev

V tem scenariju simuliramo srčni zastoj, ki se pojavi zunaj bolnišničnega okolja. Ekipte nujne medicinske pomoči, ki prispejo na mesto dogodka, morajo čim prej začeti s posebnimi postopki reanimacije, ki v osnovi vključujejo masažo srca, ventilacijo, defibrilacijo in terapijo z zdravili.

### 7.2 Analiza problema

Problemska domena spada v področje urgentne medicine, ki je zelo dobro pokrita s smernicami [45]. Prognoza preživetja bolnikov s srčnim zastojem je zelo slaba, visoko preživetje je doseženo le pri začetnem srčnem ritmu prekatne fibrilacije (VF), kjer se hitro začne s temeljnimi postopki oživljanja (TPO) in z dodatnimi postopki oživljanja (ACLS). Pomembno vlogo pri preživetju imajo priče dogodka, še večje možnosti za preživetje pa ima bolnik oziroma ponesrečenec, ki mu te priče nudijo postopke kardiopulmonalne reanimacije (CPR).

### 7.3 Opis podatkovne zbirke

Realna podatkovna baza, ki smo jo uporabljali za učenje strukture BN, vsebuje 737 zapisov, zbranih v Centru za urgentno medicino, Zdravstvenega doma Maribor. Spremenljivke, ki nastopajo v scenariju v Genie okolju, smo prikazali na shemi 7.2. Podatkovno bazo teh 10 spremenljivk smo podrobnejše opisali v prospektivni v študiji [89], kjer je bil glavni poudarek na prognostičnih vrednostih ogljikovega dioksida na koncu izdiha ( $E_tCO_2$ ).

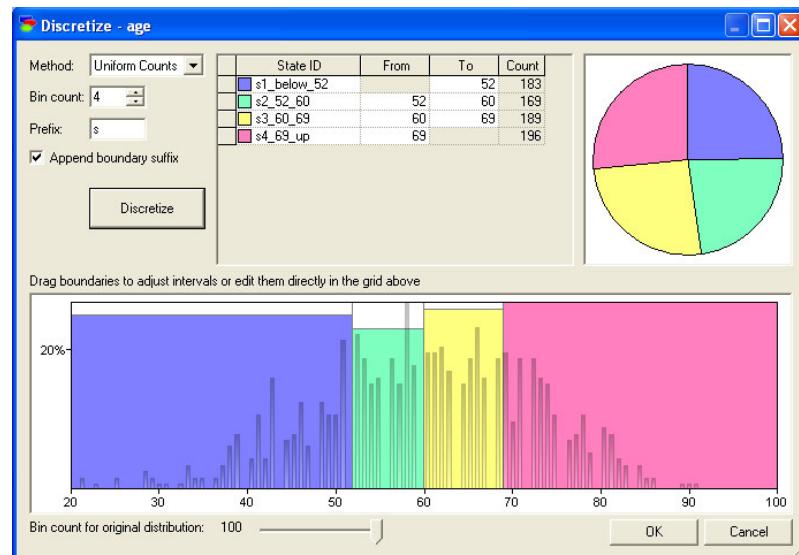
Spremenljivke podatkovne baze smo razdelili v tri skupine: informacijske, problemske in simptomske. Med 6 informacijskih spremenljivk spadajo: spol, starost, priče pri zatoju, nudenje kardiopulmonalnega oživljanja (CPR), vzrok srčnega zastoja in čas prihoda ekipe nujne medicinske pomoči (NMP). Očividci so bili prisotni v 64% primerov, vendar jih je žal samo 24% nudilo CPR. Večina bolnikov oziroma ponesrečencev je bilo moškega spola (67%).

Obravnavamo dve problemski spremenljivki, ki ju udeleženci tečaja lahko spremljajo na monitorju simulatorja. Prva kategorična spremenljivka je EKG, ki je razdeljena na prekatno fibrilacijo (VF), prekatno tahikardijo brez pulza (VT), asistolijo (ASY) in električno aktivnost srca brez tipnega pulza (PEA). Druga numerična spremenljivka predstavlja ogljikov dioksid na koncu izdiha ( $EtCO_2$ ), izmerjen preko kapnometrije. Simptomski spremenljivki sta povratek spontane cirkulacije (ROSC – Return of Spontaneous Circulation) in preživetje (Survive). Povratek spontane cirkulacije pomeni, da ekipe NMP na terenu vzpostavijo spontano cirkulacijo, dobijo tipne pulze, stabilizirajo bolnika in ga ga prepeljejo do bolnišnice. Od stopnje poškodbe oziroma bolezni in bolnišničnega zdravljenja pa je odvisno, ali bo bolnik preživel ali ne. Ta kategorična spremenljivka je označena kot preživetje.

### 7.4 Diskretizacija

V scenariju nastopajo tri numerične spremenljivke, ki jih je bilo treba diskretizirati za potrebe BN. Starost smo razdelili v 4 skupine, intervale pa smo določili glede na enakomerno zastopano število primerov (Uniform Counts). Razdelitev je predstavljena pod oznako a) na shemi 7.1.

Za tako diskretizacijo smo se odločili zato, ker to omogoča programsko okolje GENE. Razdelitev v grobem ustrezava 4 pasovom v Gaussovi porazdelitvi, kjer centralna



a)



b)

Slika 7.1: Diskretizacija spremenljivke starost (a) in časa prihoda ekipe NMP (b).

dva pasova predstavljata starost znotraj enkratnega standardnega odstopanja. Ostala dva pasova sta na bočnih pasovih Gaussove krivulje. Razdelitev je v skladu z gradnjo scenarijev za redne in izredne študente omenjene v prejšnjih poglavjih. Bolnikov starih pod 52 let, je bilo 25%, bolnikov nad 69 let pa 27%.

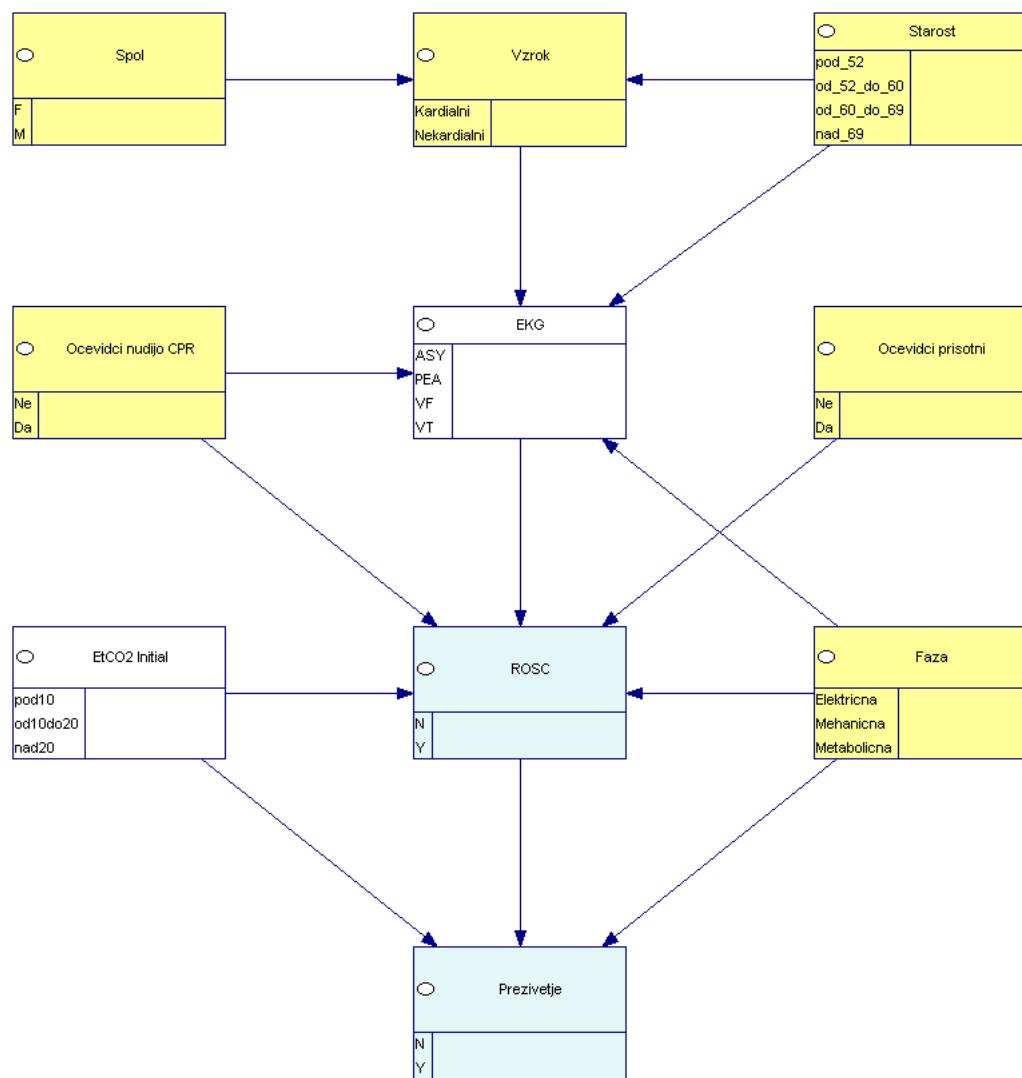
Drugače smo se lotili diskretizacije časa prihoda ekipe NMP. Glede na najnovejše trende pri obravnavi srčnega zastoja [64], smo čas prihoda razdelili v tri faze. Čas trajanja od 0 do 5 minut smo označili kot električno fazo, čas od 5 do 10 minut kot mehanično fazo in čas nad 10 minut kot metabolično fazo. Omenjena razdelitev je povezana s prekatno fibrilacijo (VF). V električni fazi je pomembna čim prejšnja defibrilacija, medtem ko je za mehanično fazo pomembnejša začetna masaža srca in nato defibrilacija. Za metabolično fazo še ni ustreznih terapijskih postopkov in so potrebna dodatna raziskovanja za ta časovni okvir, kjer so preživetja izredno majhna.

Diskretizacijo ogljikovega dioksida na koncu izdiha smo naredili glede na prejšnje študije, kjer smo iskali napovedne vrednosti EtCO<sub>2</sub>. Vrednosti smo razdelili v tri skupine: pod 10 mm Hg, med 10 in 20 mm Hg in nad 20 mm Hg [80, 2]

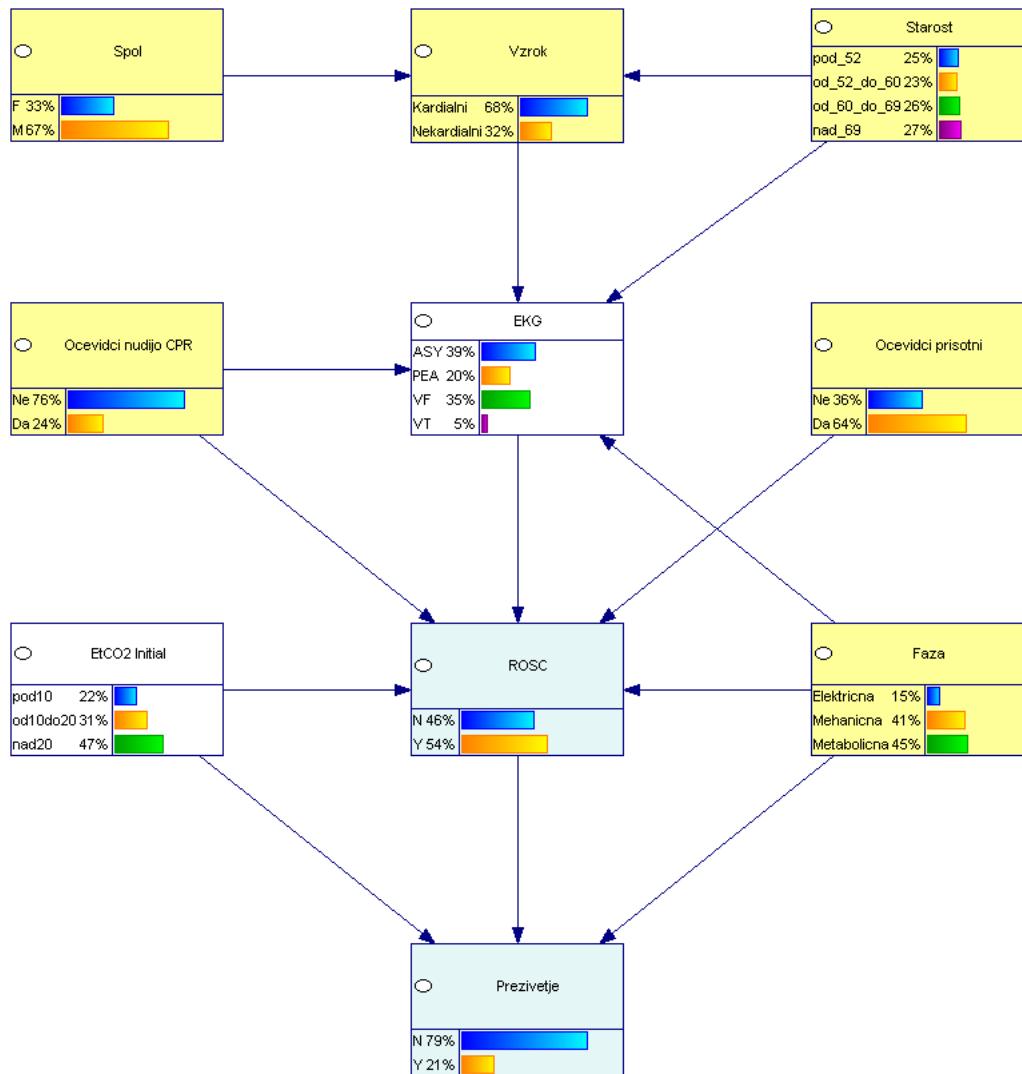
## 7.5 Kvalitativni del BN

Kvalitativni del BN je zgradil ekspert na podlagi vzročno-posledičnih povezav med spremenljivkami.

Starost in spol vplivata na vzrok srčnega zastoja, ki je lahko kardialni ali nekardialni. Mlajši moški so na primer dovetnejši za nekardialni vzrok srčnega zastoja. Ker gre za aktivno delovno populacijo, so v njej pogosteje delovne nezgode in nesreče. Od vzroka srčnega zastoja je odvisno, kakšen EKG ritem se bo razvil, prav tako od starosti bolnika. Prisotnost očividcev na kraju dogodka pomeni takojšnje obveščanje centra 112 in v veliki meri vpliva na uspešnost oživljjanja na terenu (ROSC – povratek spontane cirkulacije). Zelo pomembna komponenta, ki vpliva tako na razvoj EKG ritma kot na uspešnost oživljjanja, je izvajanje temeljnih postopkov oživljjanja, ki jih nudijo očividci. Električna, mehanična in metabolična faza srčnega zastoja je ekvivalentna prihodu reševalne ekipe in vpliva na ROSC, preživetje in na EKG ritem. Ogljikov dioksid na koncu izdiha je dober napovednik ROSC in preživetja. ROSC je neposredno povezan s preživetjem. To pomeni, da, če na terenu ne vzpostavimo povratka cirkulacije (ROSC), je posledično tudi preživetje odpusta iz bolnišnice nemogoče.



Slika 7.2: Povezava spremenljivk v Bayesovo mrežo.



Slika 7.3: Apriorna inferenca, izračunana na 737 primerih iz podatkovne baze.

## 7.6 Inferenca

Pri scenarijih v domeni predbolnišnega oživljanja bomo v tem poglavju več pozornosti namenili inferenci in njeni uporabnosti pri gradnji scenarijev. Na sliki 7.3 vidimo apriorne verjetnosti vseh spremenljivk v podatkovni bazi.

Apriorne verjetnosti BN smo učili na vseh 737 primerih, brez manjkajočih vrednosti. Če želimo pripraviti scenarij za že utečeno medicinsko osebje, bomo upoštevali vrednosti spremenljivk z manjšimi verjetnostmi; pri rednih študentih, pa upoštevamo najverjetneše scenarije, kar je bilo omenjeno že v prejšnjih poglavjih. Bayesove mreže (BN) na ta način

ne uporabljamo samo za najverjetneše scenarije, kot je običajno pri aplikaciji BN, ampak tudi za redke primere – krizne situacije. V nadaljevanju sledi opis scenarijev za izredne in za redne študente.

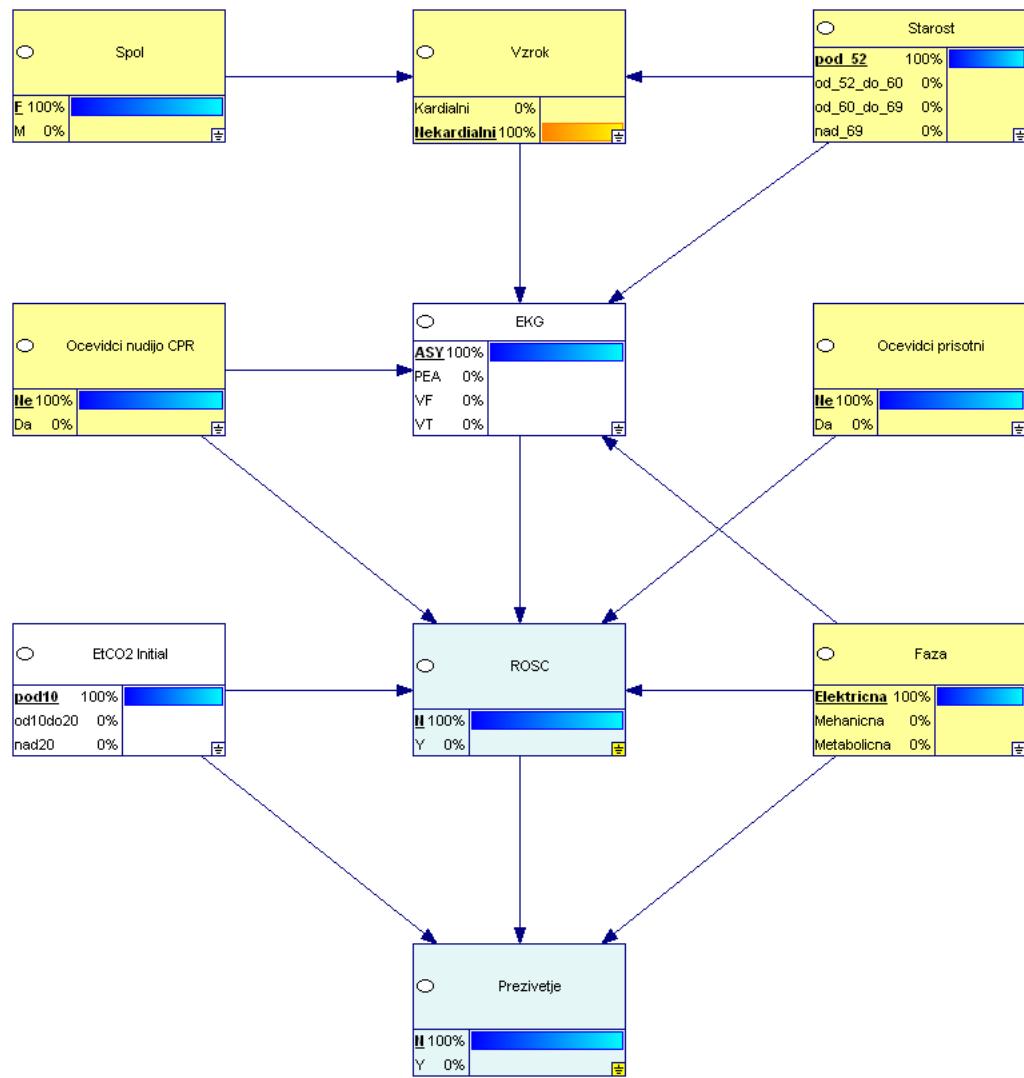
### Scenarij za izredne študente

Bolnik, ki ga bomo obravnavali je ženskega spola (apriori  $p=0,33$ ). Izberemo gotovost, da je bolnica mlajša od 52 let ( $p=100\%$ ). Starost smo namreč diskretizirali v štiri enakomerno porazdeljene razrede. Izredni študentje obravnavajo bolnike v bočnih pasovih Gaussove krivulje. V našem primeru ali pod 52 ali nad 69 let. Vzrok srčnega zastoja bo nekardialnega izvora (asfiksija, poškodbe, itd) z vrednostjo  $p=0,29$ . Očividci niso prisotni ( $p=0,36$ ) torej ne bodo nudili kardiopulmonalnega oživljjanja (gotovost,  $p=100\%$ ). Reševalci bodo na teren prispeli v času znotraj 5 minut ( $p=0,15$ ) in zatečen električni ritem bo asistolija (ASY) z verjetnostjo  $p=0,22$ . Začetni EtCO<sub>2</sub> bo pod 10 mm Hg ( $p=0,22$ ), kar bo vodilo v stanje, da bolnice reševalci ne bodo oživeli na terenu (ROSC=NE,  $p=100\%$ ) in posledično tudi ne bo preživetja (SURVIVE=NE,  $p=100\%$ ). Inferenca je predstavljena na sliki 7.4.

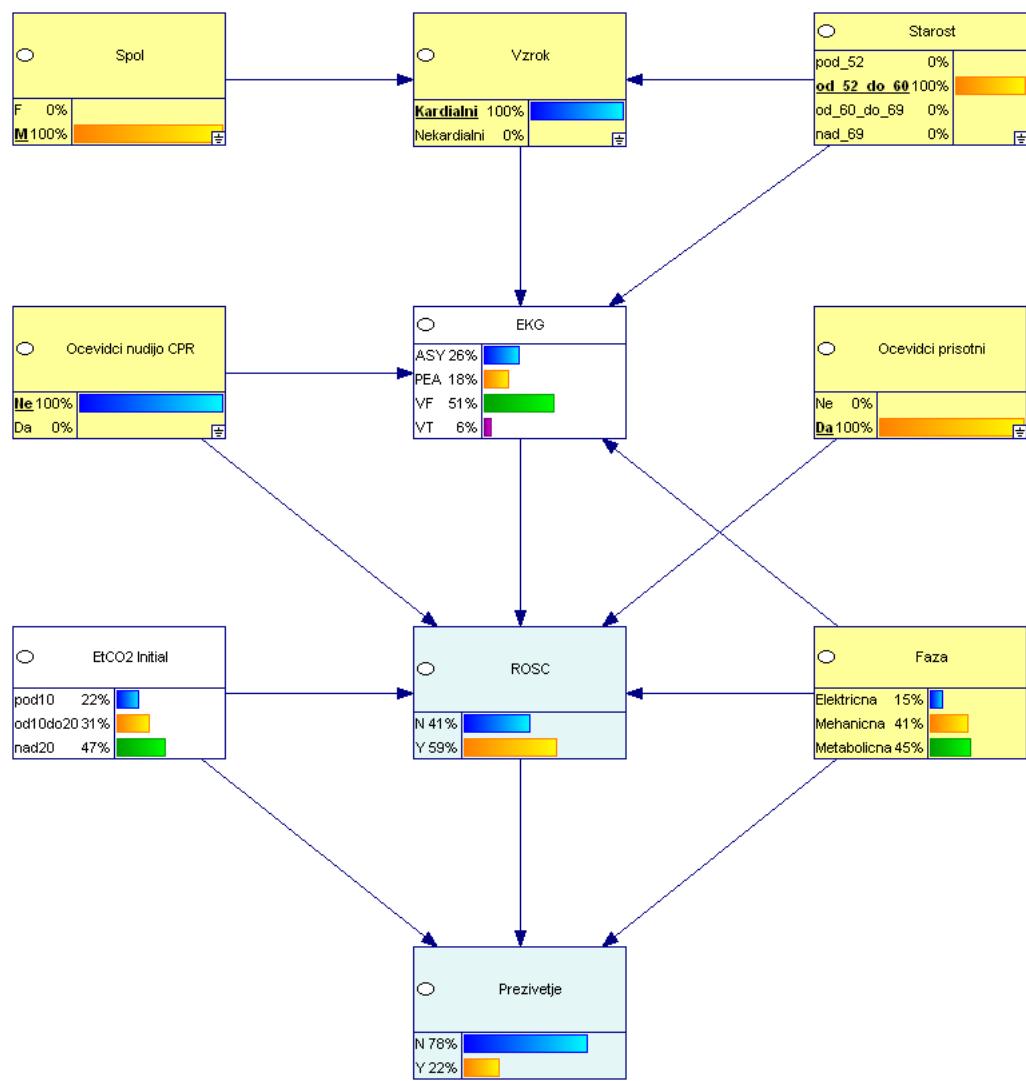
### Scenarij za redne študente

Scenarij, v nasprotju od prejnjega, išče najverjetnejše dogodke oziroma stanja, glede na verjetnosti posameznih spremenljivk. Rednim študentom namreč ne smemo ponuditi preveč redkih situacij, ampak tisto, kar je najverjetnejše, da bodo doživelii prvi dan v novi službi. Apriori verjetnost, da bo bolnik ali ponesrečenec moškega spola je  $p=0,67$ . Študentom na simulaciji zato najprej predstavimo, da gre za moškega, starega 60 let. Povprečna starost glede na podatkovno bazo je namreč 60 let. V naslednji fazi gradnje scenarija zato postavimo obe vrednosti na gotove - spol=M (gotovost,  $p=100\%$ ) in starost med 52 in 60 let ( $p=100\%$ ). Vzrok za srčni zastoj je najverjetnejše kardialni ( $p=0,83$ ). Očividci bodo prisotni na mestu dogodka ( $p=0,64$ ), vendar ne bodo nudili CPR ( $p=0,76$ ). Reševalci prispejo na mesto dogodka v času več kot 10 minut ( $p=0,45$ ). Dosedanje sekvenčne korake predstavljamo v shemi 7.5.

Najverjetnejši EKG ritem bo prekatna fibrilacija (VF) ( $p=0,46$ ). Na kapnometru bomo izmerili vrednosti tlaka ogljikovega dioksida na koncu izdiha nad 20 mm Hg ( $p=0,47$ ). Tako visoka vrednost ogljikovega dioksida zelo vpliva na verjetnost vzpostavitve spontane cirkulacije (ROSC) na terenu ( $p=0,86$ ). Verjetnost preživetja bolnikov pa bo



Slika 7.4: Scenarij za izredne študente.



Slika 7.5: Scenarij za redne študente.

## 170 POGLAVJE 7. VALIDACIJA CASGEN NA SCENARIJU PREDBOLNIŠNIČNE REANIMACIJE

samo 9 (odpust iz bolnišnice). Zanimiv primer dobimo, če postavimo nižjo vrednost EtCO<sub>2</sub> na vrednost med 10 in 20 mm Hg (gotov dogodek). Tedaj se nam pričakovano izboljša ROSC iz prejšnjega 86 na 64, vendar se preživetje dvigne iz 9 na 12.

V nadaljevanju opišemo primer uporabe zgrajene in naučene Bayesove mreže na trifaznem časovnem modelu kardiopulmonalnega oživljanja (CPR) pri prisotni prekatni fibrilaciji (VF).

### Scenariji trifaznega modela zastoja srca pri prekatni fibrilaciji

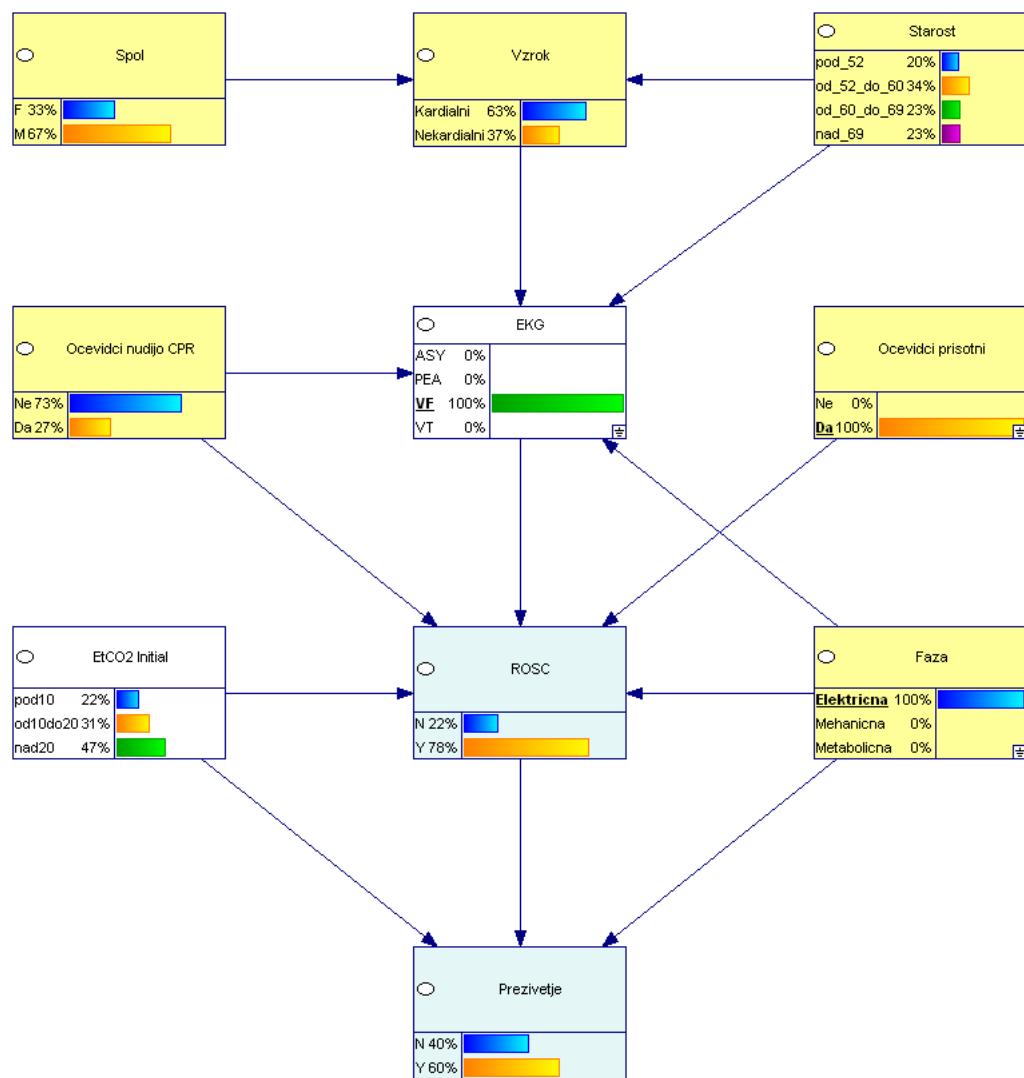
Trifazni časovni model zastoja srca obravnava časovno zaporedje dogodkov, povezanih s srcem pri patološkem ritmu ventrikularne fibrilacije (VF). Model je že bil omenjen pri diskretizaciji spremenljivke prihoda ekipe nujne medicinske pomoči. Model razdelimo v naslednje tri časovne faze:

- električna,
- mehanična,
- metabolična.

#### Električna faza

Električna faza traja prvih pet minut po pojavu prekatne fibrilacije (VF). Predpostavljam, da očividci srčnega zastoja takoj kličejo dispečerski center na telefonsko številko 112, ki takoj napoti ekipo na teren. Scenarij električne faze je predstavljen na shemi 7.6. V scenariju se osredotočimo na tri ključne spremenljivke, ki bodo definirale scenarij električne faze. Ker gre za scenarij, kjer je dejstvo *EKG* ritem v obliki prekatne fibrilacije, postavimo gotovost VF=100%. Druga spremenljivka, kjer moramo postaviti gotovost (evidence), je prisotnost očividcev (*Očividci* prisotni: DA 100%). Zadnja spremenljivka, kjer moramo postaviti gotov dogodek, je prihod ekipe NMP znotraj prvih 5 minut. Ta spremenljivka je označena z imenom *Faza* in jo postavimo na vrednost *Električna*=100%. Iz scenarija potem odčitamo vrednosti za povratek spontane cirkulacije (ROSC), ki znaša 0,78. Preživetje je v tem primeru 0,60. Najverjetnejša vrednost ogljikovega dioksida na koncu izdiha *E<sub>t</sub>CO<sub>2</sub>* bo nad 20 mmHg, kar razberemo s sheme 7.6.

Električna faza je s kliničnega vidika izredno pomembna. Znotraj te faze moramo izvesti takojšnjo defibrilacijo. V tem časovnem okvirju je po novejših raziskavah dokazana



Slika 7.6: Scenarij električne faze VF srčnega zastoja.

## 172 POGLAVJE 7. VALIDACIJA CASGEN NA SCENARIJU PREDBOLNIŠNIČNE REANIMACIJE

prednost defibrilacije pred umetno masažo srca (CPR), zato so izrednega pomena namenitve avtomatskih defibrilatorjev za laično uporabo na mestih kjer se zbira veliko ljudi. Sama namestitev seveda ni dovolj, ampak se morajo ljudje naučiti uporabe teh aparatov. Srčno tkivo je v električni fazi še dovolj dovetno za defibrilacijske tokove in morfologija fibrilacijskih valov je takšna, da napoveduje uspešno defibrilacijo, kar je v našem scenariju tudi potrjeno zaradi visokih vrednosti ROSC.

### Mehanična faza

Mehanično fazo imenujemo tudi cirkulatorna ali hemodinamska faza srčnega zastoja. Ta faza ustreza časovnemu okvirju med 5 in 10 minut, ko postane ključnega pomena dobava kisika in drugih hranil v vitalna tkiva žrtve. Pri mehanični fazi nastavljamo gotovosti podobno kot pri prej opisani električni fazi. Očividci morajo biti prisotni, EKG ritem mora biti postavljen na prekatno fibrilacijo (VF). Zahtevan prihod reševalcev je v času med 5 in 10 minut. Scenarij mehanične faze je prikazan na shemi 7.7.

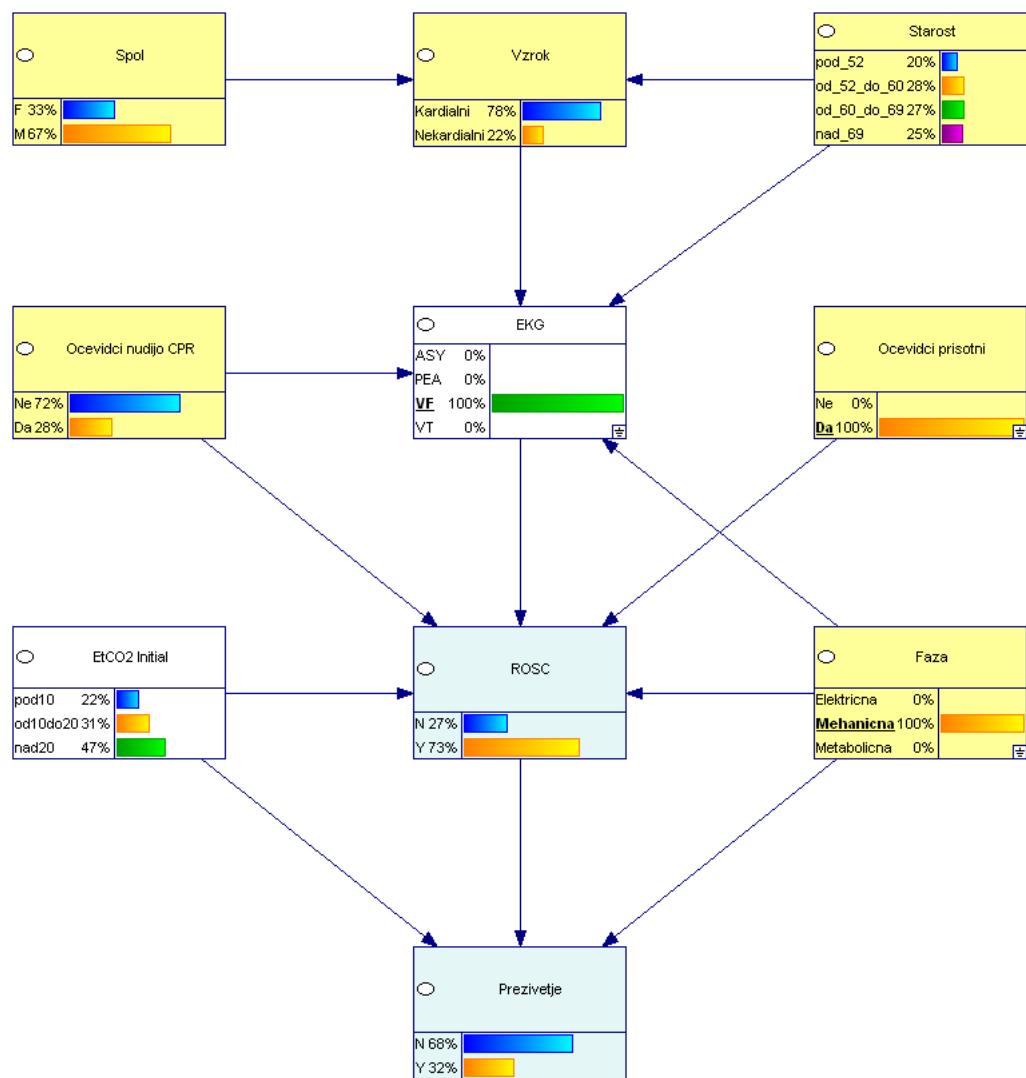
### Metabolična faza

Metabolična faza se začne po preteklu približno 10 minut od nastanka srčnega zastoja. Tedaj močno pade učinkovitost defibrilacije in zunanje masaže. Nadaljnji razvoj dogodkov je odvisen predvsem od čim boljše ohranitve srčnega in možganskega ter drugih tkiv ob nadaljevanju izvajanja kardiopulmonalnega oživljanja. Ni še jasno, ali je uspešnost oživljanja v tej fazi odvisna od učinka določenih, predvsem ireverzibilnih, telesnih mehanizmov, ali pa od neuspešnosti ukrepov oživljanja, verjetno pa gre za kombinacijo obojega. Shema 7.8 prikazuje scenarij metabolične faze. Gotovosti so nastavljene enako kot v prejšnjih dveh scenarijih, le spremenljivka prihoda ekipe NMP zavzame vrednost časovnega okvirja nad 10 minut.

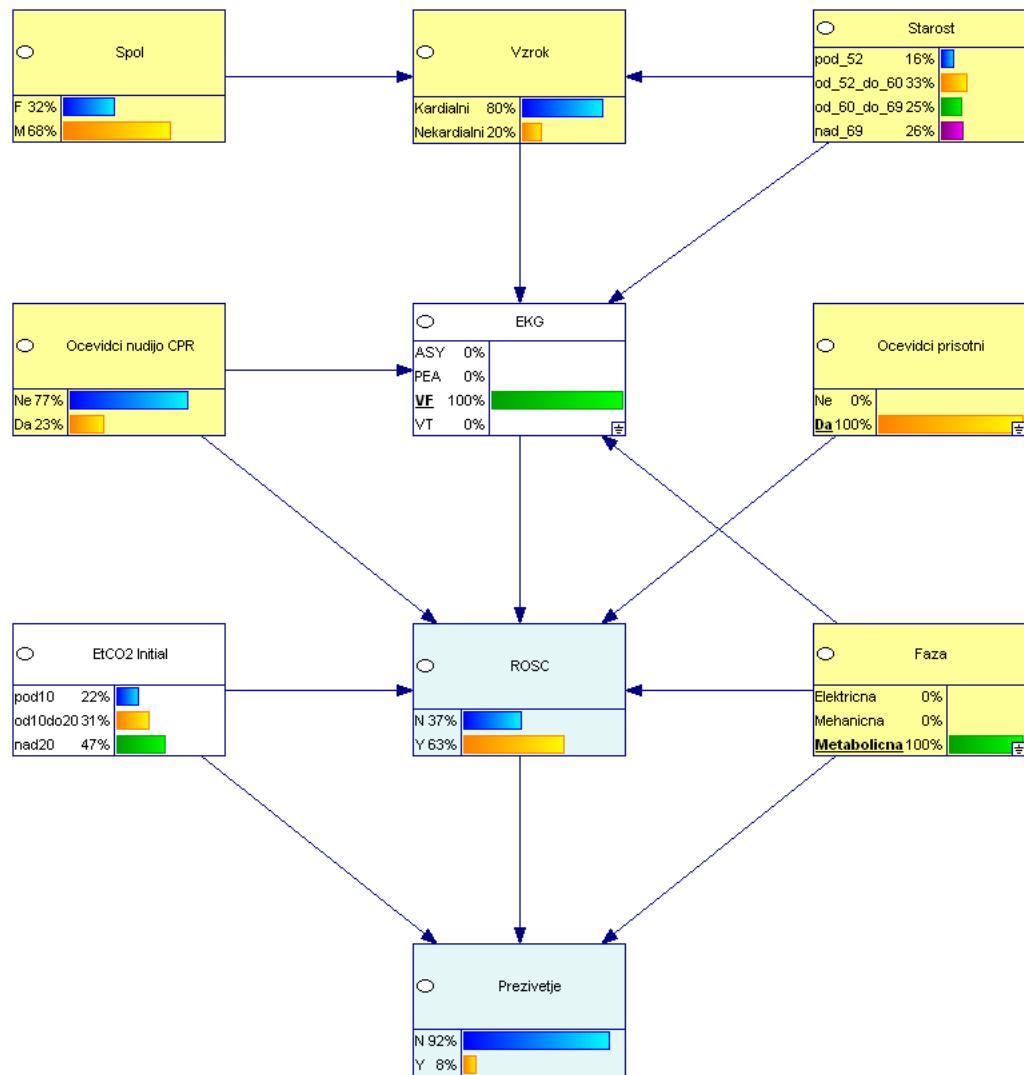
Iz vseh treh scenarijev vidimo, kako se zmanjšuje ROSC in preživetje, ko se pomikamo od električne preko mehanične do metabolične faze. Preživetje se zmanjša iz začetnih 60% v električni fazi na samo 8% v metabolični fazi. Padec ROSC-a ni tako izrazit, saj se vrednost 78% v električni fazi zmanjša na 63% v metabolični fazi. Vse tri faze lahko predstavimo s pomočjo IF THEN stavkov, ki jih določimo iz Bayesove mreže vseh treh scenarijev:

**ELEKTRIČNA FAZA - IF** *Očividci* so priče zastoja in EKG=VF in reševalci pridejo znotraj 5 minut **THEN** ROSC=0,78 in sledi PREŽIVETJE=0,60.

**MEHANIČNA FAZA - IF** *Očividci* so priče zastoja in EKG=VF in reševalci pridejo v času med 5 in 10 minut **THEN** ROSC=0,73 in sledi PREŽIVETJE=0,32.



Slika 7.7: Scenarij mehanične faze VF srčnega zastoja.



Slika 7.8: Scenarij metabolične faze VF srčnega zastoja.

**METABOLIČNA FAZA - IF** *Očividci* so priče zastoja in EKG=VF in reševalci pridejo v času nad 10 minut THEN ROSC=0,63 in sledi PREŽIVETJE=0,08.

Prikazana je uporaba inference, ki smo jo aplicirali za gradnjo scenarijev predbolnišnične reanimacije. Iz podanih schem je razvidna rekonfiguracija stanj posameznih spremenljivk, glede na podano gotovost predvsem informacijskih spremenljivk, kar omogoča učinkovite nastavitev variant posameznega scenarija v učnem procesu. Prednost, ki jo Bayesove mreže vnašajo v gradnjo scenarijev, je uporaba inference pri njihovi uporabi. Instruktor v simulacijskem okolju lahko namreč s pomočjo inference v Bayesovi mreži v posameznem stanju scenarija učinkovito nastavi drugačne inicializacijske razmere s postavitvijo gotovosti na informacijske spremenljivke v posameznem stanju. Klasičen scenarij zahteva nastavitev vseh spremenljivk, s hevrističnim pristopom Bayesovih mrež pa nam inferenca omogoča kreiranje različnih stanj, glede na gotovosti, ki jih podamo v posamezno stanje.



## Poglavlje 8

# Validacija CASGen na scenariju anafilaktične reakcije

### 8.1 Opis problema

Anafilaksa ali anafilaktična reakcija je takojšnja preobčutljivostna reakcija na tujo alergeno snov. Vnos alergenih snovi je pogost preko pika žuželk, kot so mravljje, čebele, ose, sršeni in čmrlji. Piki žuželk so najpogosteji vzrok smrti zaradi živalskega strupa, zato je pomembna hitra in dobra diagnoza ter hiposenzibilizacija.

Anafilaktična reakcija je redek, a zelo hud zaplet, ki se lahko pojavi tudi po transfuziji samo nekaj ml krvi. Nastane, ko prejemnik nima dovolj *IgA* protiteles ali pa so ta odsotna. Takrat dajalčeva *IgA* protitelesa delujejo kot antigeni. Ob nastanku imunskega kompleksa se močno aktivira imunski sistem, posledica pa je izločanje velike količine citokinov, ki povzročijo rdečico, kašelj, bronhospazem, težave z dihanjem, slabost, bruhanje, hipotenzijo, nezavest, šok, lahko tudi smrt.

Pogoste anafilaktične reakcije srečamo tudi pri aplikaciji zdravil, predvsem penicilina. Reakcije ne reagirajo vedno na glavno kemično zmes zdravila ampak tudi na snovi, ki so dodane zdravilu.

Simptomi anafilaktične reakcije so lahko izpuščaji, srbenje, ovirano požiranje ali težko dihanje. Reakcija se lahko razvije v anafilaktični šok, ki povzroči življensko ogrožajoče nevarnosti, kot so padec krvnega tlaka, srčne aritmije, bronhialno obstrukcijo in nenazadnje tudi zastoj srca. Preko IgE antiteles se sproži masivno sproščanje citokinov iz

## 178 POGLAVJE 8. VALIDACIJA CASGEN NA SCENARIJU ANAFILAKTIČNE REAKCIJE

mastocitov in bazofilcev, kar povzroči znižanje sistemskega žilnega upora (SVR), tekočina prehaja v drug prostor (intersticij), kar sproži padec tlaka. Te fiziološke mehanizme smo modelirali v naši Bayesovi mreži. Dodali smo baroreceptorski refleks, ki se sproži kot odgovor na padec tlaka.

Terapija je odvisna od vrste anafilaktične reakcije, pri sistemski anafilaksiji pa je bolnik hospitaliziran. Pri lažjih primerih se uporablajo kortikosteroidi in antihistaminiki, pri težjih reakcijah pa se aplicira adrenalin.

V ZDA umre vsako leto približno 500 ljudi zaradi anafilaksije, pri tem je 75% smrti zaradi alergije na penicilin.

### 8.2 Analiza problema

V prvi fazi gradnje Bayesovih mrež moramo definirati posamezna relevantna stanja in znotraj njih določiti nastopajoče spremenljivke. Anafilaktično reakcijo smo definirali na sedmih stanjih, ki jih podrobno opisujemo v naslednjih alinejah:

1.
  - **INICIALIZACIJA:** Normalni sistemski žilni upor (SVR), normalni pljučni žilni upor (PVR), normalna upornost dihalnih poti (AIRWAY), normalna venska kapaciteta, SpO<sub>2</sub>=98%, HR=68, BP=114/54, BR=12 bpm.
  - **POGOJ:** Počakati, da študentje vstopijo v simulacijski prostor, kamor jih pokliče inštruktor (call for help) in prehod v stanje 2.
2.
  - **ZAČETEK ANAFILAKSIJE:** Težko dihanje, delež žilnega šanta 15%, vzdilatacija - padec žilnega upora (SVR), pljučni žilni upor (PVR) faktor 1,25, upornost dihalnih poti povečana, SpO<sub>2</sub>=95%, HR=80, BP=100/50, BR=18 bpm.
  - **POGOJ:** Če je apliciran *adrenalin* prehod v stanje 5, SICER po preteku časa (2-4 min) prehod v stanje 3.
3.
  - **BLAGA ANAFILAKSIJA:** Povečanje deleža šanta na 25%, upornost dihalnih poti faktor 20 (srednja restrikcija), stridor, venska kapaciteta 1,05, SpO<sub>2</sub>=94%, HR=94, BP=100/40, BR=24 bpm.
  - **POGOJ:** Če je apliciran, *adrenalin* prehod v stanje 6, SICER po preteku časa (2-4 min) prehod v stanje 4.

4. • **POSLABŠANJE ANAFILAKSIJE:** Povečanje deleža šanta na 35%, upor dihalnih poti 40,0 (težka restrikcija), venska kapaciteta faktor 1,15, SpO<sub>2</sub>=90%, HR=102, BP=90/40, BR=30 bpm.
- **POGOJ:** Če je apliciran *adrenalin*, prehod v stanje 6, SICER po preteku časa (4-6 min) prehod v stanje 5.
5. • **HUDA ANAFILAKSIJA:** Obstrukcija dihalnih poti, povečanje deleža šanta na 45%, venska kapaciteta faktor 1,2, SpO<sub>2</sub>=87%, HR=125, BP=80/40, BR=36.
- **POGOJ:** Če je apliciran *adrenalin*, prehod v stanje 6, SICER po preteku časa (6-10 min) v stanje 7.
6. • **APLIKACIJA ADRENALINA:** Upor dihalnih poti normalen (0,81), zmanjšanje deleža šanta na 0,02, faktor pljučnega žilnega upora (PWR) na 1,1, sistemski žilni upor na faktor 0,95, SpO<sub>2</sub>=97%, HR=66, BP=102/50, BR=20
7. • **ANAFILAKTIČNI ŠOK:** Zaprte dihalne poti, SpO<sub>2</sub>=0%, HR=0, BP=0/0.

Scenarij začnemo s stanjem, poimenovanim *inicializacija*. Bolnika, starega 24 let, sprejmejo v urgentno ambulanto zaradi pika več čebel. V anamnezi je ugotovljeno, da je bolnik astmatik in da je že bil zaradi astme hospitaliziran. Bolnik pove, da ima v zadnjem času tudi težave s srcem. Stanje bolnika je stabilno, srčna frekvenca (HR - Heart Rate) je 68  $\frac{1}{min}$ , nasičenost krvi s kisikom ( $S_pO_2$ ) je 98%. Bolnik diha (BR - Breathing Rate) normalno, s frekvenco 12  $\frac{1}{min}$ , krvni tlak (BP) je 114/54. Ker mora ekipa (inštruktorji), ki so bolnika sprejeli v ambulanto, nujno na drugo delovišče, pokliče pomoč. V tem trenutku pristopijo udeleženci tečaja, ki prevzamejo bolnika. Takrat se scenarij pomakne v novo stanje: *začetek anafilaksije*. Na shemi 8.1 so prikazane spremenljivke, ki jih je določil ekspert za domeno anafilaktične reakcije.

V zgornjem delu sheme 8.1 so mediatorske spremenljivke, ki predstavljajo fiziološke oziroma patofiziološke procese. To so spremenljivke, ki regulirajo spremembe arterijskega tlaka in spremenljivke, povezane z delovanjem srca in ožilja. V sredini so problemske spremenljivke, ki jih lahko simuliramo na simulatorju SimMan. K tem spremenljivkam spada večina spremenljivk, izmerjenih s kliničnim monitorjem, kot so saturacija, EKG, kapnometrija in krvni tlak. S stetoskopom avskultiramo motnje v dihanju - stridor, medtem ko z opazovanjem bolnika določimo frekvenco dihanja. Zaporu dihalnih poti je opaziti v težkem dihanju, otekanju dihalnih poti in posledično v neuspešni intubaciji. Na spodnjem delu slike 8.1 pa so informacijske spremenljivke, ki jih pridobimo z anamnezo in vplivajo na problemske spremenljivke simulatorja.

## 180 POGLAVJE 8. VALIDACIJA CASGEN NA SCENARIJU ANAFILAKTIČNE REAKCIJE

### FIZIOLOŠKE/PATOFIZIOLOŠKE SPREMENLJIVKE - MEDIATORSKE SPREMENLJIVKE

<input type="radio"/> Baroreceptorji	<input type="radio"/> Vazomotorični center	<input type="radio"/> Kardiovaskularni center	<input type="radio"/> Zilni sast (intersticij)
Inhibicija		Inhibicija	
Inervacija		Inervacija	
<input type="radio"/> Simpatikus	<input type="radio"/> Parasimpatikus	<input type="radio"/> Utripi volumen (SV)	<input type="radio"/> Sistemski upor (SVR)
Inhibicija		Nizek	
Inervacija		Normalen	
		Visok	
<input type="radio"/> Sproscanje CITOKINOV	<input type="radio"/> Pljučna upornost (PVR)	<input type="radio"/> Popuscanje srca	
Ne		Ne	
Da		Da	

### SPREMENLJIVKE SIMULATORJA SimMan - PROBLEMSKE SPREMENLJIVKE

<input type="radio"/> Minutni iztis srca (CO)	<input type="radio"/> Srcna frekvence (HR)	<input type="radio"/> Krvni tlak (Sys)	<input type="radio"/> Krvni tlak (Dia)
Nizek		Nizek	
Normalen		Normalen	
Visok		Visok	
<input type="radio"/> SpO2	<input type="radio"/> Zapora dihalnih poti	<input type="radio"/> Frekvence dihanja (BR)	<input type="radio"/> Stridor
Normalna		Nizka	
Nizka		Normalna	
		Visoka	
<input type="radio"/> EKG ritem			
SIN			
ASY			
PEA			
VF			
VT			

### ANAMNEZA - INFORMACIJSKE SPREMENLJIVKE

<input type="radio"/> Bolezen srca	<input type="radio"/> Astma
Ne	
Da	

Slika 8.1: Spremenljivke anafilaktične reakcije v orodju GeNIe.

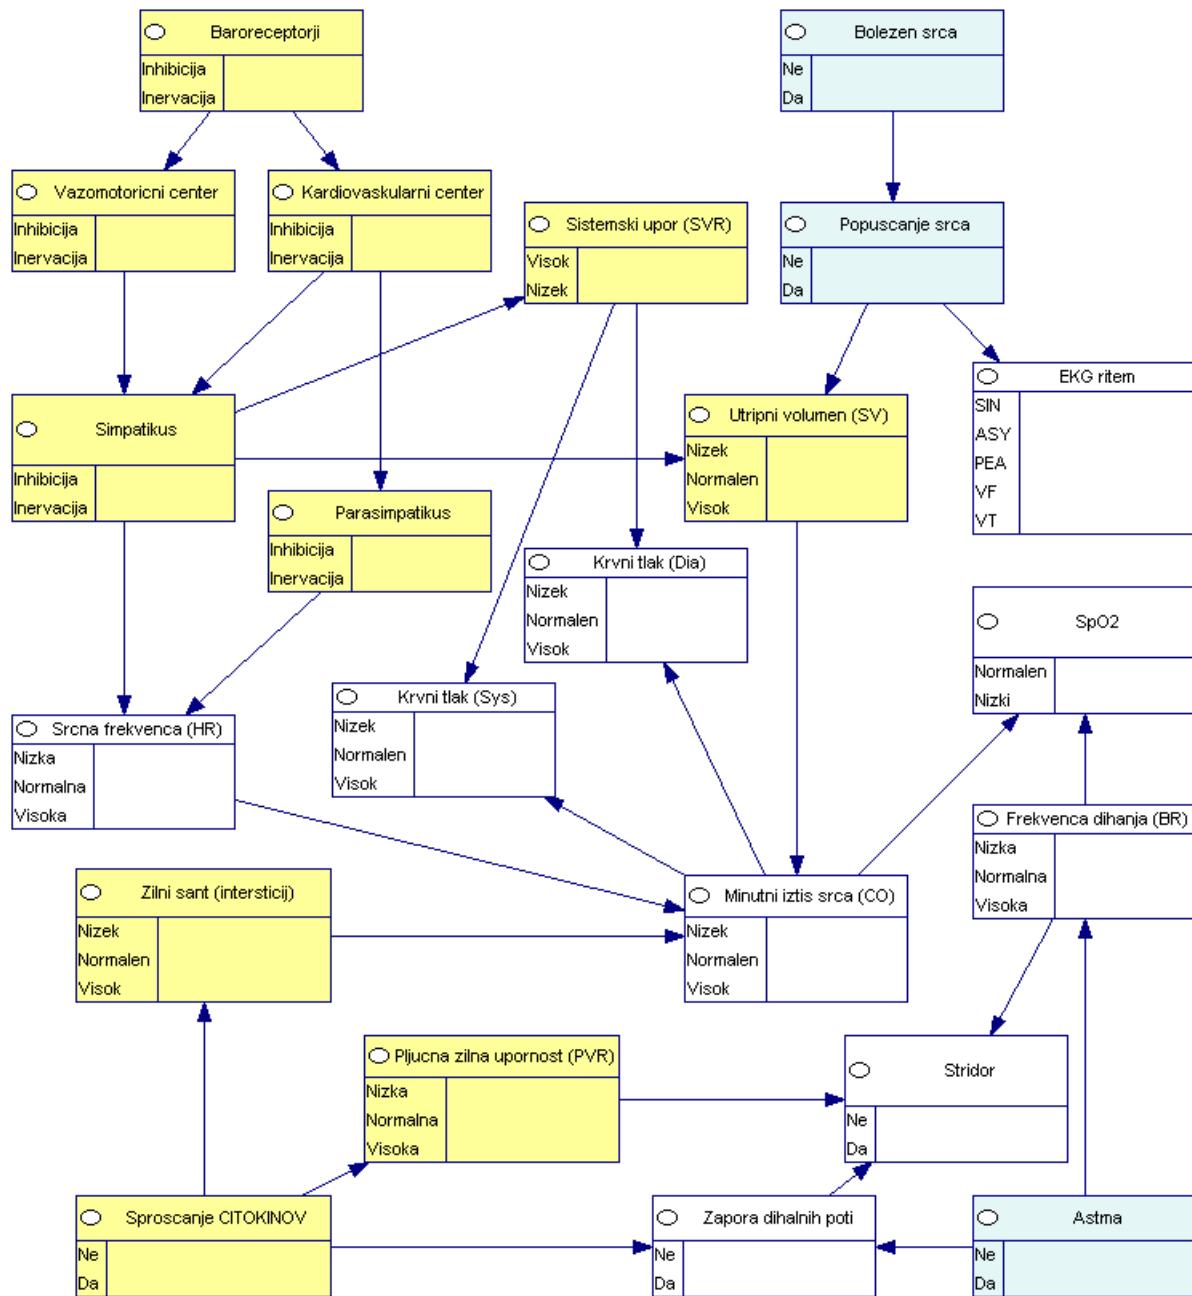
Zraven stanj v delu analize identificiramo in ugotovimo tudi tipe spremenljivk, ki jih potrebujemo za posamezno stanje, glede na metodologijo CASGen (poglavje 8).

Ko je strokovnjak identificiral in analiziral domeno problema, sledi naslednji korak CASGen - gradnja Bayesovih mrež.

### 8.3 Ročna gradnja Bayesovih mrež

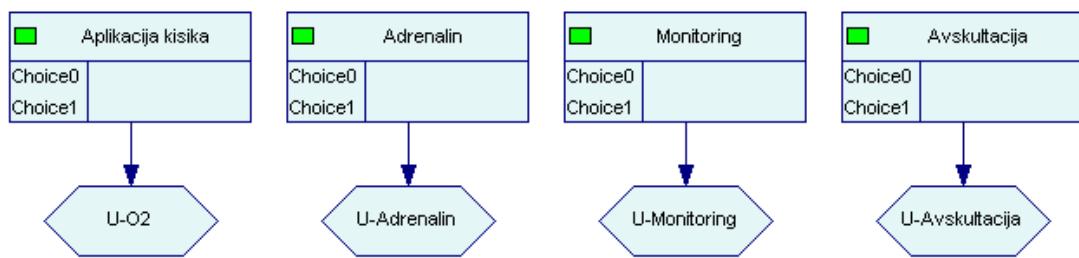
V primeru anafilaktične reakcije nismo razpolagali s podatkovnimi zbirkami, zato imamo po metodologiji CASGen pri gradnji posamezne Bayesove mreže opraviti z ročno gradnjo Bayesove mreže. Sledi torej identifikacija informacijskih odvisnosti med določenimi spremenljivkami, ki zagotavljajo kvalitativen del modela, pri čemer je treba imeti v mislih iterativen proces, ki vključuje testiranje spremenljivk in odvisnih ter neodvisnih kriterijev ter preverjanje usmerjenih povezav, od koder se nastavijo vrednosti posameznih parametrov. Na podlagi teh odvisnosti se določijo pogojne CPT tabele. Shema 8.2 prikazuje povezave med spremenljivkami, ki smo jih identificirali v prvem koraku CASGen.

Pri testiranju povezav smo upoštevali vzročno-posledične relacije med spremenljivkami. Pri povečanju krvnega tlaka se karotidna arterija in aorta raztegneta, kar vpliva na baroreceptorje, kjer se poveča bazalna vrednost akcijskega potenciala. Akcijski potencial se prevaja preko glasofaringealnega živca in vagusa v kardioregulatorni in vazomotorični center v Meduli oblongati. Kot rezultat povečane stimulacije (inervacije) baroreceptorjev, kardiovaskularni center poveča parasimpatično inervacijo srca, ki zmanjša srčno frekvenco (HR). Prav tako kot rezultat povečane inervacije iz baroreceptorjev kardiovaskularni center zmanjša simpatično stimulacijo srca, kjer se zmanjšata srčna frekvenca in utripni volumen (SV). Vazomotorični center zmanjša simpatično stimulacijo stene krvnih žil in povzroči vazodilatacijo. Vazodilatacija poleg zmanjševanja srčne frekvence in zmanjšanja utripnega volumena zmanjšuje krvni tlak. Produkt srčne frekvence in utripnega volumena je minutni volumen srca, ki nadalje vpliva na tlak in saturacijo s kisikom. Bolezen srca vpliva na EKG in moč levega dela srca, ki se izraža v popuščanju srca. Zaradi tega se zmanjšuje utripni volumen (SV - Stroke Volume). Težave bolnika zaradi astme se zrcalijo v hitrejši zapori dihanja in vplivu na zvoke na pljučih, kot je stridor. Citokini, ki se sproščajo zaradi anafilaktične reakcije, povečujejo pljučno-žilno upornost (PVR - Pulmonary Vascular Resistance) in zmanjšujejo sistemsko žilno upornost (SVR - Systemic Vascular Resistance). Ker tekočina prehaja iz sistemske cirkulacije v zuna-



Slika 8.2: Povezovanje spremenljivk v BN. Povezovanje vključuje testiranje kriterijev in preverjanje povezav in je v osnovi iterativni postopek - stanje je prikazano v orodju GeNIE.

### DIAGRAMI VPLIVA - ODLOCITVE IN KORISTNOSTI



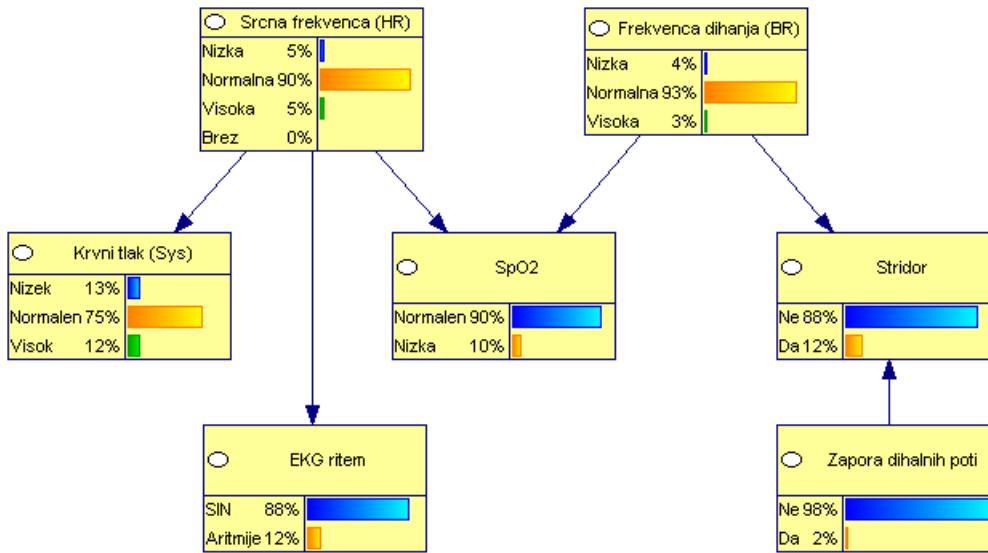
Slika 8.3: Diagrami vpliva

jcelični (ekstracelularni) prostor, se povečuje delež žilnega šanta. Vzročno-posledične relacije so kot vidimo zelo kompleksne narave.

## 8.4 Diagrami vpliva in odločitve

V naslednji fazi gradnje BN je treba določiti pogoje za prehode med posameznimi stanji anafilaktične reakcije. Reakcija se začne z blago anafilaksijo, ki se stopnjuje do hude anafilaksije. Če se ne ukrepa ustrezno, nam scenarij gre v smeri anafilaktičnega šoka. Pogoji med prehodi iz enega stanja v drugo se modelirajo z diagrami vpliva, prikazanimi na shemi 8.3.

Predstavljene so štiri odločitev, ki so ovrednotene s funkcijo koristi. Osrednja odločitev je aplikacija zdravila adrenalina, ki je najpomembnejša. Adrenalin deluje na ožilje tako, da skrči žile, nakar se poveča krvni tlak. Najvišjo korist dodelimo odločitvi v čim prejšnji aplikaciji adrenalina. Korist nato upada, ko se stopnjuje komplikacija anafilaktične reakcije. Odločitev o aplikaciji kisika sicer ni pogoj za prehod iz enega v drugo stanje, ampak je pomembna komponenta v terapiji. Kisik se mora prav tako kot adrenalin aplicirati čim prej. Največjo korist dobi odločitev o aplikaciji kisika v 2. stanju, potem pa se korist zmanjšuje. V primeru, da na bolnika ni priključen klinični monitor, ga je treba priključiti. Če ni monitoringa, potem ni izmerjenih spremenljivk in udeležencem onemogočimo pregled nad spremenljivkami. Avskultacija prinaša dodatne točke v skupni koristi, saj se le na ta način ugotovijo patofiziološki zvoki na pljučih.



Slika 8.4: Stanje inicializacije v scenariju anafilaktične reakcije

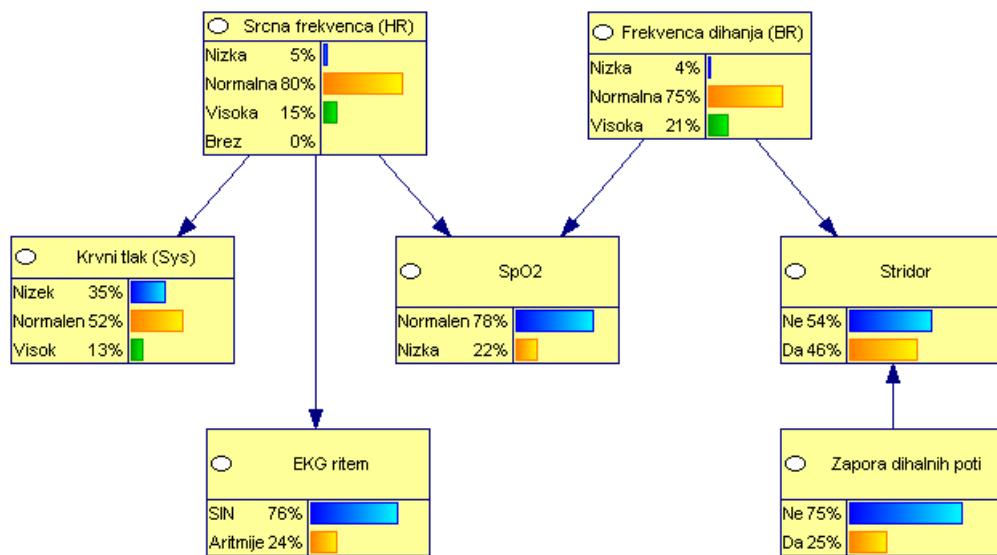
## 8.5 Redukcija vozlišč

Zaradi izredno zapletene zgradbe BN smo se odločili za redukcijo vozlišč. Kompleksna zgradba zahteva namreč zelo zahtevne pogojne CPT tabele. Na primer, vozlišče, ki predstavlja minutni iztis srca (CO), bi zahtevalo vnos 54 vrednosti v pogojno CPT tabelo, glede na kombinacije vseh vrednosti starševskih vozlišč (utripni volumen, srčna frekvenca in žilni šant). Vsaka od treh spremenljivk ima po tri diskretne vrednosti, kar poveča dimenzijo CPT tabele. Nova stanja smo zato sestavili iz samo sedmih spremenljivk (srčna frekvenca, frekvenca dihanja, krvni tlak, saturacija, stridor, EKG ritem in zapora dihalnih poti).

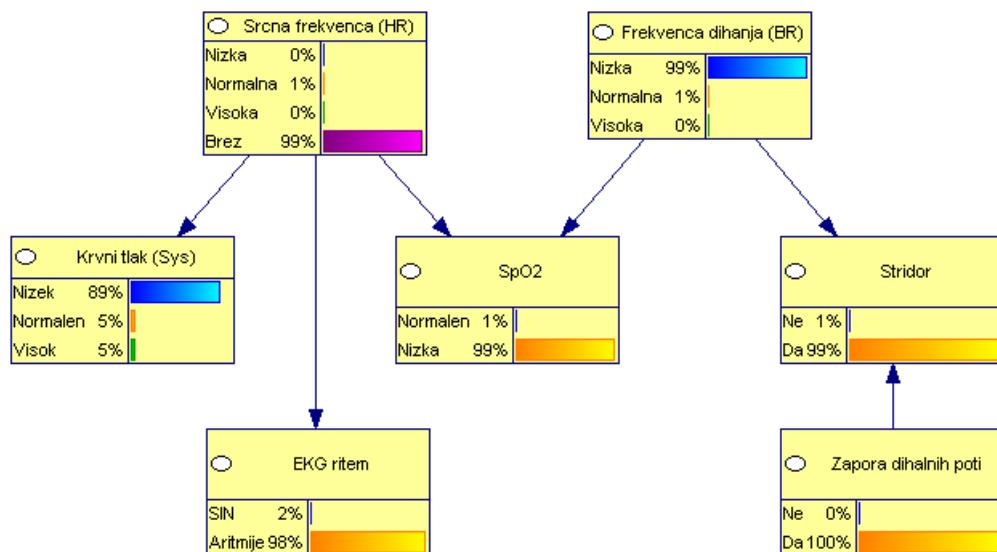
V nadaljevanju bomo prikazali tri stanja, ki smo jih zgradili iz Bayesovih mrež v okolju GeNIE. Začetno stanje inicializacije je prikazano na sliki 8.4. Kot vidimo, so vrednosti vseh spremenljivk v normalnih vrednostih.

V Bayesovi mreži, prikazani na shemi 8.5, je prikazano poslabšanje anafilaktične reakcije.

Na shemi 8.6 je prikazano stanje anafilaktičnega šoka. V tem stanju bolnik ne diha, EKG ritem je v fazi prekatne fibrilacije (VF), srčne frekvence ni prisotne, zapora dihalnih poti, krvni tlak pa je enak nič.

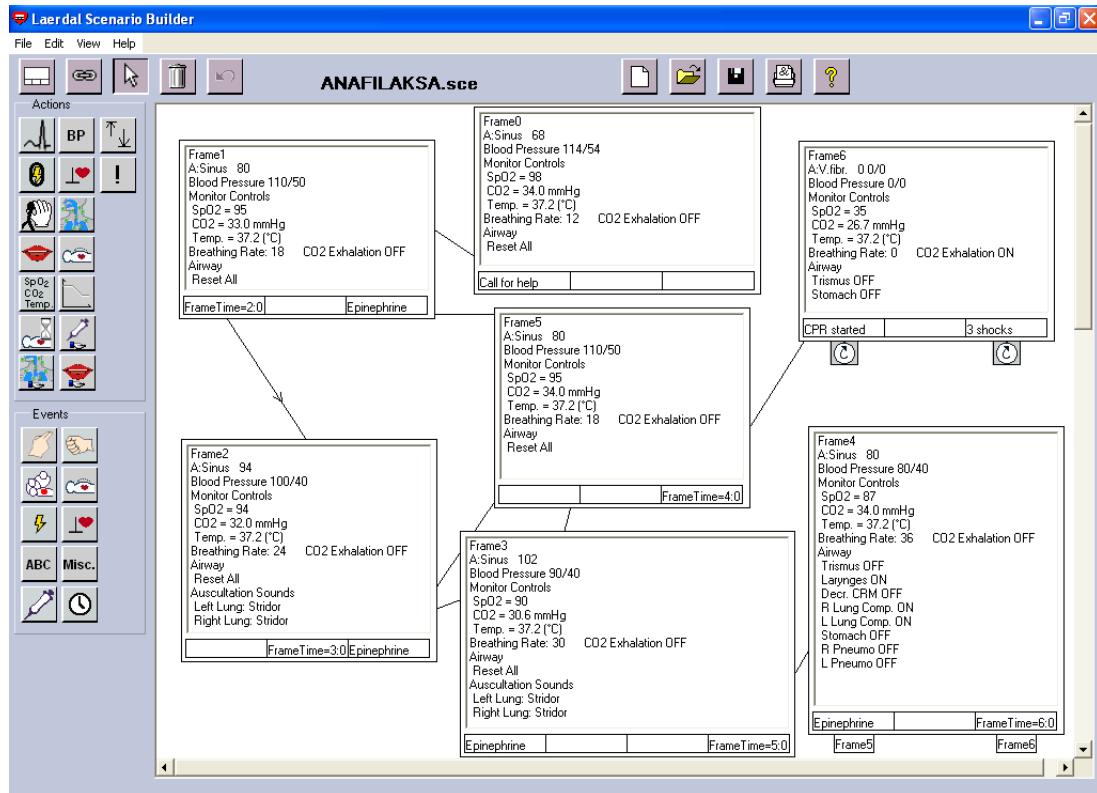


Slika 8.5: Stanje poslabšanja anafilaktične reakcije.



Slika 8.6: Stanje anafilaktičnega šoka.

## 186 POGLAVJE 8. VALIDACIJA CASGEN NA SCENARIJU ANAFILAKTIČNE REAKCIJE



Slika 8.7: Shematski prikaz scenarija SimMan v povezavi z ogrodjem GeNIE in metodologijo CASGen.

## 8.6 Izdelan scenarij za simulator SimMan

Za vsako stanje izdela strokovnjak, glede na metodologijo CASGen Bayesoo mrežo, ki predstavlja vzročno-posledične relacije med posameznimi spremenljivkami v stanju, kot smo to prikazali v prejšnjih dveh sekcijah. Izdelan scenarij predstavlja kombinacijo omenjenih korakov, in sicer povezavo vseh stanj, ki so ponazorjena z Bayesovimi mrežami v obliki diagrama vpliva, kot smo ga predstavili na shemi 8.7

Pri validaciji metodologije smo ugotovili, da predstavlja zahteven postopek za eksperta določitev CPT tabel. Zato predlagamo, da se CPT tabele oziroma učenje parametrov določa avtomatsko na podlagi strojnega učenja Bayesove mreže. Možne rešitve predstavljajo razcepitev podatkovne zbirke na posamezne dele, kjer vsak del predstavlja eno stanje v scenariju. Praktično bi takšno idejo lahko implementirali na podatkovni zbirki anestezijskega informacijskega sistema AIMS RECALL Univerzitetnega kliničnega centra Maribor. Omenjeni informacijski sistem zajema podatke vitalnih funkcij v intervalih 30 sekund. Zajemajo se vse vitalne funkcije iz kliničnih monitorjev in anestezijskega

aparata. Omogočen je vnos posebnih dogodkov v sistem, kot je na primer začetek intubacije ali aplikacija določenega zdravila. Pravilne nastavitev sistema nam omogočajo želene prereze podatkovne zbirke, ki jih lahko uporabimo za posamezno stanje v scenariju.

188 POGLAVJE 8. VALIDACIJA CASGEN NA SCENARIJU ANAFILAKTIČNE REAKCIJE

## Poglavlje 9

# Preverjanje metodologije CASGen

Metodologijo CASGen smo preverili kvalitativno, saj smo jo zaenkrat preizkusili na dveh scenarijih, ki smo ju predstavili v prejšnjih dveh poglavjih 7 in 8. Kvalitativna analiza izdelane metodologije je zajemala predstavitev metodologije in končnih scenarijev ekspertom - strokovnjakom na različnih področjih medicine. Strokovnjaki so v intervjujih podali odgovore, s katerimi smo ocenili uporabo CASGen orodja za podporo gradnje medicinskih scenarijev.

### 9.1 Predstavitev metodologije ekspertom

Metodologijo smo predstavili 11 ekspertom, ki se zraven rednega dela ukvarjajo tudi z izobraževanjem zdravstvenih delavcev. Povprečna starost strokovnjakov je bila  $41 \pm 6$  let. Strokovnjaki so pokrivali področja urgentne medicine, anestezije, kirurške intenzivne terapije, internistične intenzivne terapije, nevrologije in pediatrične intenzivne medicine. En ekspert je bil diplomirani zdravstvenik z ERC licenco in izkušnjami v izobraževanju nujne medicinske pomoči. Večina strokovnjakov je bila moškega spola ( $n=9$ ). Z eksperti smo opravili intervjuje za pridobitev naslednjih mnenj: 1) ovrednotenje razumevanja in namena metodologije za gradnjo scenarija, 2) prednosti uporabe Bayesovih mrež za gradnjo scenarijev, 3) uporabnost metodologije pri izdelavi scenarija, 4) uporabnost metodologije pri uporabi scenarijev v simulacijskem okolju, 5) časovna zahtevnost pri implementaciji metodologije in 6) preprostost uporabe metodologije in možne izboljšave v prihodnosti. Mnenja strokovnjakov smo predstavili z Likertovo štiristopenjsko lestvico, in sicer nezadovoljivo (1), zadovoljivo (2), dobro (3) in zelo dobro (4). Strokovnjaki so podali tudi

<b>Binomial Test</b>					
		Category	N	Observed Prop.	Test Prop.
Primernost metodologije	Group 1	Poz	10	,91	,50
	Group 2	Neg	1	,09	
	Total		11	1,00	

Slika 9.1: Rezultati statističnega eksaktnega binomskega testa.

mnenja o izboljšavi razvoja metodologije v prihodnje.

Splošno pozitivno mnenje o ustreznosti metodologije je podalo 10 ekspertov, eden pa je podal negativno mnenje o primernosti metodologije za scenarij, kar smo prikazali tabelarično na shemi 9.1. Uporabili smo eksakten binomski test, kjer smo naše odgovore primerjali z enakomerno porazdelitvijo ( $\alpha = 0,5$ ). Razlika je bila statistično signifikantna  $p = 0,012$ .

V naslednjem odstavku so predstavljene oporne točke v obliki vprašanj, na katere smo želeli dobiti odgovore z namenom podrobnejšega ovrednotenja metodologije. Odgovore smo statistično obdelali tako, da smo med seboj primerjali ključna vprašanja o metodologiji CASGen. V nadaljevanju so predstavljeni sklopi vprašanj.

### **DEL I - jasnost opisa metodologije CASGen**

1. Kako razumljivo je podan postopek uporabe BN v CASGen pri gradnji scenarija?
2. Jasnost identifikacije in nastavitev spremenljivk za BN.
3. Jasnost ročne gradnje Bayesovih mrež.
4. Jasnost gradnje Bayesovih mrež iz podatkov.
5. Jasnost in namen diagrama vpliva za povezavo stanj v scenariju.

### **DEL II - prednosti Bayesovih mrež za gradnjo scenarija**

1. Prednost inference pri uporabi scenarija v okolju.
2. Prednost uporabe realnih podatkovnih zbirk za gradnjo scenarija.
3. Preprostost uporabe podatkovnih zbirk v orodju GeNIE za potrebe gradnje BN v stanjih scenarija.

4. Jasnost razlage zahtev za zbiranje podatkovnih zbirk za gradnjo scenarija.

### **DEL III - uporabnost CASGen pri izdelavi scenarija**

1. Uporabnost orodja GeNIE in BN pri izdelavi scenarija.

### **DEL IV - uporabnost CASGen pri uporabi v simulacijskem okolju**

1. Prednost inference in orodja GeNIE pri uporabi izdelanega scenarija.

2. Uporabnost GeNIE z grafičnim vmesnikom simulatorja SimMan.

### **DEL V - časovna zahtevnost osvojitve metodologije**

1. Osvojitev metodologije za gradnjo scenarijev.

### **DEL VI - preprostost metodologije in predlogi možnih izboljšav**

1. Preprostost uporabe metodologije v primerjavi s klasično gradnjo scenarija.

2. Razvoj CASGen s podporo Reasonov kriznega modela.

V naslednjih tabelah so predstavljeni rezultati, glede na sklope vprašanj, ki smo jih postavljali ekspertom. Tabeli sledi mnenje strokovnjakov in njihov pogled na uporabo metodologije ter potencialne izboljšave za prihodnost.

I	Št.	II	Št.	III	Št.
1.1	$3,00 \pm 0,4$	2.1	$3,9 \pm 0,3$	3.1	$3,6 \pm 0,7$
1.2	$2,27 \pm 0,9$	2.2	$3,8 \pm 0,4$	-	
1.3	$2,09 \pm 0,5$	2.3	$2,7 \pm 0,8$	-	
1.4	$3,09 \pm 0,5$	2.4	$2,9 \pm 0,5$	-	
1.5	$2,82 \pm 0,7$	-		-	

IV	Št.	V	Št.	VI	Št.
4.1	$3,6 \pm 0,7$	5.1	$1,9 \pm 0,3$	6.1	$2,7 \pm 0,8$
4.2	$2,0 \pm 0,4$	-		6.2	$2,8 \pm 0,7$
-		-		-	
-		-		-	
-		-		-	

Tabela 9.1: Rezultati skloporječja vprašanj.

Kot lahko razberemo iz tabele 9.1, so metodologijo in njene sklope strokovnjaki v večini primerov, ocenili pozitivno (vrednosti povprečij in odstopanj pri točkah na posamezno vprašanje so bili v vseh primerih večji od 2 po štiristopenjski Likertovi lestvici). Med najnižje ocnjene vrednosti so v sklopih, kjer se govorji o jasnosti in zahtevnosti osvojitve metodologije Bayesovih mrež, kar kaže, da ne gre za preprost koncept, ki bi bil ekspertom medicinskega področja dovolj blizu, na kar smo že opozorili. Kljub temu se je uporabnost orodja, ki zahteva nekaj truda, izkazala za pozitivno, zato smo naredili še dodatne primerjave. Zanimala nas je predvsem razumljivost postopka uporabe Bayesovih mrež pri gradnji scenarija in prednost Bayesovih mrež pri gradnji scenarija. Vprašanja smo zato med seboj statistično primerjali. Tako smo preverili obstoječe korelacije za 1. in 2. vprašanje v I. sklopu. Pri tem smo ugotovili korelacijo razumljivosti in identifikacije spremenljivk postopka ( $p = 0,02$ ), kar potrdi že opisano dejstvo, da sta pri gradnji Bayesovih mrež ključni dobra identifikacija in nastavitev spremenljivk. Pri prednosti uporabe inference Bayesovih mrež pri gradnji scenarija se je pokazalo, da je le ta odvisna od zbiranja podatkov in priprave podatkovnih zbirk ( $p < 0,024$ ), kar ponovno potrjuje ključno prednost inference in integracije realnih podatkov v scenarij, ki jo prinaša metodologija CASGen. Zraven tega je prednost inference korelirala tudi z uporabnostjo orodja GeNIE, ki je v doktorskem delu uporabljen kot podporno ogrodje za delo z Bayesovimi mrežami ( $p < 0,003$ ). Omenjene korelacije in potrditev vprašanj, ki smo jih predstavili v tabeli, potrjujejo našo osnovno hipotezo uporabe Bayesovih mrež, kot orodja za gradnjo hevrističnih scenarijev. Eksperti računajo na pomoč strokovnjakov IT v implementaciji tehnologije ter predvsem v zbiranju in pripravi podatkov.

## 9.2 Podano mnenje ekspertov

Strokovnjaki so pri uporabi metodologije poudarili naslednje stvari:

- Metodologija CASGen je na prvi pogled zapletena za nekoga, ki nima izkušenj z Bayesovimi mrežami, zato strokovnjak priporoča izdelavo nekaj preprostih študij primerov za Bayesove mreže, s katerimi bi si uporabnik naredil pregled nad verjetnostnimi mrežami.
- Izdelava in opis gradnikov scenarija v povezavi z metodologijo sta kvalitetno zastavljena.

- Za uporabnika, ki že ima občutek o uporabi Bayesove mreže, je CASGen primerno zasnovana, saj lepo sledi vrstnemu redu in se ozira na predpostavke, ki jih je treba zajeti.
- Orodje GeNIE je dobro in učinkovito orodje s preprostim grafičnim vmesnikom za uporabo v CASGen, vendar bi bila zaželena integracija z uporabniškim vmesnikom simulatorja, kjer bi v ta namen lahko implementirali tudi podpora orodja za uporabo Bayesovih mrež. Podpora orodja bi tako omogočala nekatere pogosto zastopane vzročne povezave za gradnjo mreže pri fizioloških in informacijskih spremenljivkah.
- Avtomatizacija diskretizacije spremenljivk za lažje delo z diskretnimi Bayesovimi mrežami bi bila dobrodošel dodatek, če bi CASGen v prihodnje uspeli integrirati v uporabniški vmesnik SimMan.
- CASGen bi bilo primerno izdelati v obliki krajšega spletnega priročnika.

CASGen smo ocenili kvalitativno na podlagi mnenja strokovnjakov iz prakse. Izdelan je bil sklop vprašanj, v katerem smo želeli izvedeti odziv na izdelani študiji in uporabnost orodja. V šestih sklopih vprašalnika se je metodologija CASGen pokazala kot uporabna, vendar zaradi omejitev simulatorja, ki ne dovoljuje integracije orodja Bayesovih mrež v uporabniški vmesnik, za prvi korak sicer nekoliko zapletena, še posebej za uporabnika strokovnjaka iz medicinske stroke, ki nima izkušenj z metodami strojnega učenja. V ta namen so strokovnjaki priporočali izdelavo krajših spletnih študij primerov Bayesovih mrež in prihodnjo integracijo orodja v sam simulator. Pri delu z metodologijo so strokovnjaki poudarili zahtevnost zbiranja podatkov, kar je precej zahtevno zaradi narave dela.

Eksperti predlagajo v določenih primerih stopenjsko gradnjo scenarijev, zaradi njihove podobne narave dela. Anamneza se namreč obravnava v prvem stiku z bolnikom, nakar sledijo diferencialne diagnoze, glede na znake in simptome. Vse faze v diagnostičnem in terapevtskem postopku potekajo od enostavnih splošnih postopkov, vse do specifičnih diagnostičnih postopkov, če se ne odkrije pravi vzrok bolezni oziroma zapleta.

Nemalokrat se eksperti znajdejo v težavah pri poteku izobraževanja, ki ga izvajajo. Scenarij jim lahko zaide v področje, ko več ne vedo, ali se kaj takega sploh lahko zgodi v realnem kliničnem primeru. Posledično prihaja do slabe volje pri udeležencih tečaja, ki menijo, da se takšen splet dogodkov ne more zgoditi. Zato vidijo eksperti prednost v orodju Bayesovih mrež, kjer poteka sklepanje po korakih, glede na dejstva, ki jih postavlja v Bayesovi mreži.

Na področju pediatrije je zbiranje podatkov precej kompleksno, saj vsak poseg v nedonošenčka, novorojenčka ali otroka pomeni zanj visoko tveganje. Težava pri zbiranju so redki primeri, ki se zgodijo nekajkrat letno, zato bi bilo treba pri zbiranju podatkov vključiti tudi druge zdravstvene institucije po Sloveniji ali zunaj nje. Pri zbiranju podatkov bi najmanj težav imeli eksperti na področju anestezije, ki imajo že vzpostavljen anestezijski informacijski sistem (AIMS). Zanje predstavlja edino težavo transformacija podatkov iz AIMS-a v podatkovno bazo, primerno za gradnjo scenarija s pomočjo Bayesovih verjetnostnih mrež.

## Poglavlje 10

# Sklepne misli in razprava

Simulacije v medicini predstavljajo pomemben vidik in orodje v izobraževalnem procesu, pri čemer je še posebej pomembno podajanje znanja iz realnega okolja. Zato današnji novi pristopi v edukaciji težijo k z dokazi podprtji medicini (Evidence Based Medicine) [53], kjer je posebej v zadnjem času čutiti potrebo po orodjih za analizo uskladiščenega znanja, ki se skrbno skladišči v bolnišničnih informacijskih sistemih. Pri uporabi tega znanja se v medicini srečujemo z dejstvom, da zaposleni zdravstveni delavci, ki opravljajo vlogo posredovanja učnih vsebin študentom in specializantom, še nimajo dovolj večin s področja sofisticirane analize podatkov, saj se strojno učenje danes v medicini pogosto uporablja le za predikcijske namene in namene diagnostike [72, 51].

Anestezija, intenzivna medicina in urgentna medicina so še posebej problematična področja medicine, saj se posebej v domeni urgentne medicine sprejemajo hitre in natančne odločitve, ki so ključnega pomena za preživetje bolnika. Problem, s katerim se na tem področju soočajo edukatorji pri izobraževanju, je tako predvsem, kako učinkovito naučiti zdravstveno osebje, da prepozna problem in ustrezno ukrepa v kriznih primerih, ki se lahko pojavijo med obravnavo bolnika, pri čemer nastajajo težave med novozaposlenimi, saj se zaradi širokega nabora različnega znanja, pridobljenega v rednem izobraževanju, na delovnem mestu ne znajdejo takoj. Hkrati se lahko v podobnih situacijah znajde tudi ciljna skupina zaposlenega zdravstvenega osebja, ki večino postopkov dela že rutinsko, težje pa prepozna redke in krizne situacije, ki predstavljajo visoko stopnjo tveganja za bolnika.

Za premostitev omenjenih težav se danes pri izobraževanju medicine in zdravstvenega osebja v ta namen uporabljajo različni simulatorji, na katerih je moč konstruirati različne

scenarije, na podlagi katerih lahko urimo zdravstveno osebje. V doktorski nalogi smo posebej predstavili zgradbo in gradnjo scenarija za simulator SimMan podjetja Leader, ki ga uporabljamo na področju anastesije, urgentne medicine in intenzivne medicine za edukacijo ciljnih skupin. Za izdelavo scenarija omenjenega simulatorja je tako potreben usposobljen strokovnjak s področja medicine, ki scenarij kreira s pomočjo programskega orodja Simulatorja. Ta pa kljub sofisticiranosti ne omogoča uporabe realnih podatkov in metod strojnega učenja, ki se sicer danes v medicini že precej uporablja za namene diagnostike in predikcije.

V doktorski nalogi smo tako raziskali možnost uporabe metod strojnega učenja za hevristično gradnjo scenarija za simulator SimMan. Pri tem smo pri izbiri metod strojnega učenja posegli po modelu verjetnostnih mrež, ki predstavljajo model za predstavitev znanja, hkrati pa omogočajo verjetnostno sklepanje, kar jih razlikuje od drugih simboličnih metod strojnega učenja. Zaradi zahtevnega procesa gradnje scenarija in omejitve programske opreme, kot tudi zahtevnosti uporabe modela Bayesovih mrež, smo se pri raziskovalnem delu omejili z nekaterimi danimi predpostavkami in tako zaradi zaprte programske kode simulatorja izdelali rešitev za uporabo verjetnostnih mrež, ki teče v orodju GeNIE. Pri tem smo se zaradi zahtevnosti gradnje scenarija omejili na uporabo diskretnih Bayesovih mrež ter v ta namen razvili metodologijo CASGen, ki smo jo uporabili v realnem okolju. Glavni cilj naloge je tako predstavljena metodologija CASGen, ki nam omogoča uporabo Bayesovih mrež za potrebe hevristične gradnje scenarijev v medicini. Pri tem smo ugotovili, da uporaba Bayesovih mrež za potrebe izdelave scenarijev prinaša dve poglavitni izboljšavi, in sicer:

- možnost uporabe realnih podatkovnih zbirk iz realnega okolja,
- uporabo verjetnostnega sklepanja Bayesovih mrež pri uporabi scenarija.

Ker gre pri gradnji scenarija za zapleten problem, ki ne sme dopuščati napak, je iluzorno pričakovati, da bi lahko z uporabo modela strojnega učenja avtomatizirali postopek gradnje scenarija. Realneje je pričakovati, da bomo z uporabo modela lahko razvili orodje, ki bo strokovnjakom služilo za podporo pri gradnji scenarija, podobno kot za to služijo računalniško podprtci odločitveni modeli za podporo diagnostiki in predikciji. Zato smo razvito metodologijo tudi poimenovali CASGen (Computer Aided Scenario Generation), saj se je izkazala kot orodje, ki lahko strokovnjaku služi v podporo pri kreiranju scenarijev. Izdelano metodologijo, ki jo pogojujejo dobre prakse, postopki in lastnosti uporabe modela Bayesovih mrež, prav tako specifična struktura zgradbe scenarija sestavlja več

pomembnih korakov, specifična pa je tudi predlagana arhitektura, ki jo predstavlja doktorsko delo. Zaradi zapletene strukture scenarija smo model Bayesovih mrež aplicirali na dveh različnih ravneh, in sicer 1) v posameznih stanjih bolnika in 2) v povezavi teh stanj v scenarij, kar omogoča razširjeni model Bayesovih mrež, tako imenovan diagram vpliva. Metodologijo smo potem uporabili na dveh realnih pilotnih študijah, kjer smo Bayesove mreže uporabili na oba načina, ki ju predvideva CASGen, in sicer na podlagi ročne kot tudi avtomatske gradnje mrež. Pri tem prav bistveno prednost prinaša avtomatska gradnja Bayesovih mrež, ki jo lahko s pomočjo metodologije uporabimo v scenariju.

Metodologijo CASGen smo ocenili s pomočjo kvalitativne raziskave, ki nam jo je izdelal neodvisni strokovnjak. Na tak način smo obravnavali hipotezo doktorskega dela in raziskovalno vprašanje, ki pravita:

**Hipoteza** *Bayesove verjetnostne mreže kot metode v strojnem učenju predstavljajo primeren model za podporo gradnje scenarijev za simulator na področju medicine.*

**Raziskovalno vprašanje** *Ali je izdelana metodologija CASGen primerno in uporabno orodje za uporabo Bayesovih mrež pri gradnji scenarijev za strokovnjake s področja medicine, ki se srečujejo z izdelavo scenarijev za izobraževalne namene?*

Hipotezo doktorske naloge smo lahko v celoti potrdili, saj so se Bayesove mreže v posameznem stanju scenarija izkazale kot učinkovit model, s katerim lahko v scenarij vnašamo podatke iz realnega okolja, kar omogoča, da lahko posamezna stanja v scenariju na tak način kvalitetno dopolnimo. Zato potrebujemo dobro pripravljene podatkovne zbirke, ki jih posebej za to ni veliko in jih je zato treba najprej pripraviti iz že obstoječih podatkovnih zbirk ali posebej za to načrtovati v prihodnje, kar je dobro definirano v CASGen in je bilo tudi prikazano na pilotnih študijah. Glede na zapisano, lahko potrdimo hipotezo, saj Bayesove mreže predstavljajo učinkovit model za podporo pri gradnji scenarijev; pri tem je seveda treba poudariti, da ne gre za vsesplošno magično rešitev, temveč zahteva taka uporaba precej sofisticiranega znanja in upoštevanja nekaterih predpostavk, ki jih ima model verjetnostnih mrež, kar smo podrobno definirali v metodologiji CASGen.

Raziskovalno vprašanje smo uspeli preveriti le na podlagi izdelanih študij primerov in mnenja strokovnjakov, ki bi lahko metodologijo uporabljali pri svojem delu. Drugače tudi nismo mogli, saj je že izdelava same metodologije zahtevala veliko laboratorijskega dela in preizkusov. Na tej podlagi smo razvili predstavljen model, na podlagi katerega

bomo lahko učinkovito orodje zgradili in dopolnili ter ocenili šele s širšo uporabo v praksi. To presega postavljene raziskovalne okvirje doktorskega dela, kjer smo postavili primeren model in ga uspešno potrdili, kar nam nudi dobra izhodišča za delo v prihodnje. Tako nameravamo metodologijo razviti in integrirati v uporabniški vmesnik simulatorja, saj smernice tudi pri razvoju programske opreme na splošno že integrirajo različne metode inteligentnih sistemov za lažje delo in podporo uporabnikom, kar smo v naši raziskavi vsekakor pokazali za model verjetnostnih mrež. Pri tem je treba osvetliti tudi konstruktivne napotke uporabnika strokovnjaka pri uporabi metodologije, kjer se je pokazalo, da bi bila za gradnjo scenarijev dobrodošla tudi avtomatska diskretizacija spremenljivk. Zaenkrat je nismo automatizirali, zahteva pa to deloma zgradba simulatorja in opazovanih spremenljivk, ki pogosto lahko vsebujejo zvezne vrednosti. V prihodnje nameravamo postopek diskretizirati, hkrati pa nam dobro postavljena osnova nudi možnost uporabe tudi zveznih Bayesovih mrež, ki pa jih zaradi omejitev, potrebnih za obvladovanje problema in razvoj metodologije, v prvi fazi v delu nismo upoštevali.

Za prihodnje predstavlja dobro razvojno možnost tudi uporaba metodologije z Reasonovim kriznim modelom, kakor smo predstavili, zato nameravamo tudi CASGen prilagoditi za dobro integracijo in uporabo s kriznim modelom, kar bo zraven predstavljenih izboljšav prineslo nove kvalitete, predvsem na področju urgentne medicine.

Na podlagi možnosti uporabe Bayesovih mrež za namene gradnje scenarijev, ki smo jih podrobno raziskali v doktorskem delu, in na podlagi izkušenj ter kvalitativne ocene strokovnjaka za razvito CASGen, lahko sklenemo, da predstavlja metodologija dobro osnovo za nadaljevanje razvoja orodja za hevristično podporo pri gradnji scenarijev. Tako orodje ima dobre potencialne razvoje v prihodnje, kjer gre predvsem za nadaljevanje izpopolnjevanja metodologije CASGen v smeri realizacije metodologije v sam programski paket simulatorja. Omenjena možnost je zaenkrat še nedostopna, a vendar predstavlja glede na smernice in potrditve raziskovalnega dela ter empiričnih študij dobro smer, v kateri se bodo lahko programski vmesniki izpopolnjevali z vključitvijo metod intelligentnih sistemov v prihodnje. Še posebej velja slednje pri gradnji scenarija za verjetnostne mreže, za katere smo pokazali in empirično tudi preizkusili, da predstavljajo učinkovit model v pomoč pri gradnji scenarijev. Pomembna je predvsem novost vključevanja strojnega učenja pri scenarijih, kjer na prvi ravni arhitekture CASGen Bayesove mreže omogočajo efektivno pot uporabe realnih podatkovnih zbirk za gradnjo scenarija za simulator. Na tak način scenarij še bolj približamo realnim okoliščinam, kar igra pomembno vlogo pri izobraževanju na področju medicine.

Metodologijo CASGen bomo z zapisanimi smernicami tudi v prihodnje razvijali postopoma in iterativno, kakor smo to izdelali v doktorski disertaciji. To je zahtevalo precej laboratorijskega dela in več obravnav možnih rešitev. V prihodnje bomo tako z zapisanimi smernicami ter realno uporabo metodologije pri izobraževanju na fakulteti z več strokovnjaki iz medicine, CASGen razvijali v zastavljeni smeri in tako približevali in širili uporabo modela verjetnostnih mrež na področju medicine. Natančneje bomo metodologijo uporabljali kot orodje za hevristično gradnjo medicinskih scenarijev za različne simulatorje, kar izboljšuje izobraževanje na področju medicine s sofisticiranimi in tehnološko zahtevnimi simulatorji; v sodobni medicini igrajo prav ti vedno pomembnejšo vlogo, saj prehajajo tudi v učne načrte [26].

Rdeča nit, ki nas je vodila skozi celotno doktorsko delo, je izboljšava pedagoškega procesa. Osnova pri vsakem izobraževanju je, da študentje popolnoma razumejo podano snov in pridobijo znanje za reševanje podobnih primerov, ki jih pozneje srečajo v praksi. Za razumevanje osnovnega delovanja določenih medicinskih pripomočkov smo v drugem poglavju prikazali eno od možnih simulacij, kjer smo simulirali delovanje Venturi maske (slika 2.12). Prav tako smo napravili zelo enostaven simulator, ki modelira diagnostiko pozitronske emisijske tomografije (slika 2.5). Simulatorji bolnika so danes najbolj izpopolnjen način izobraževanja, ob katerih se medicinsko osebje uri v kontroliranem simulacijskem okolju. Simulatorji so brez scenarijev neuporabni, zato smo razvili metodologijo, kjer s pomočjo Bayesovih mrež in diagramov vpliva modeliramo scenarije za različne ciljne skupine. Na koncu smo predstavili nekoliko idej, predvsem za prihodnje raziskave, kot so Reasonov krizni model in fuzija simulatorjev.

Predstavljen holistični pristop nedvomno prispeva h kvalitetnejšemu pridobivanju znanja, le-to pa je pogoj za suvereno in precizno delo medicinskega kadra in predstavlja pot do boljših rezultatov v diagnostiki in terapiji bolnikov.



# Literatura

- [1] Ziv A, Wolpe PR, Small SD, and Glick S. Simulation-based medical education: a ethical imperative. *Acad Med*, 78:7838, 2003.
- [2] Sanders AB, Kern KB, and Otto CW. End-tidal carbon dioxide monitoring during cardiopulmonary resuscitation: A prognostic indicator for survival. *JAMA*, 262:1347, 1989.
- [3] Garden AL, Robinson BJ, Arancibia CU, Carron TJ, Monk S, Vollmer J, Heinrichs W, Grube C, Graf M, and Johnson EB. Unrecognized malfunction in computerized patient simulators,. *British Journal of Anaesthesia*, 93:873–875, 2004.
- [4] Christian B and Rudolf K. *Graphical models methods for data analysis and mining*. J. Wiley New York Chichester, 2002.
- [5] Issenberg BS, McGaghie WC, Petrusa ER, Gordon DL, and Scalese RJ. Features an uses of high-fidelity medical simulations that lead to effective learning: a bem systematic review. *Med Teach*, 27:1028, 2005.
- [6] Friedman CP. The marvelous medical education machine or how medical education can be unstuck in time. *Acad Med*, 75:137–42, 2000.
- [7] Baker D, Prince C, Shrestha L, Oser R, and Salas E. Aviation computer games for crew resource management training. *International Journal of Aviation Psychology*, 3:143–156, 1993.
- [8] Heckerman D. Causal independence for knowledge acquisition and inference. *Proceedings of the Ninth Conference on Uncertainty in Artificial Intelligence*, pages 122–127, 1993.

- [9] Heckerman D. A tutorial on learning with bayesian networks. *Technical Report. MSR-TR-95-06 Microsoft Research Advanced Technology Division Microsoft Corporation Redmond WA 98052*, 1996.
- [10] Heckerman D and Breese JS. A new look at causal independence. *Proceedings of the Tenth Conference on Uncertainty in Artificial Intelligence*, pages 286–92, 1994.
- [11] Murray D. Clinical simulation: measuring the efficacy of training. *Curr Opin Anaesthesiol*, 18:645–8, 2005.
- [12] Heckerman DE, Horvitz EJ, and Nathwani BN. Towards normative expert systems 1 the pathfinder project. *Meth Inform Med*, 31:90–1, 1992.
- [13] Heckerman DE, Horvitz EJ, and Nathwani BN. Towards normative expert systems 2 probability-based representations for efficient knowledge acquisition and inference. *Meth Inform Med*, 31:106–16, 1992.
- [14] Via DK, Kyle RR, Trask JD, Shields CH, and Mongan PD. Using high-fidelity patient simulation and an advanced distance education network to teach pharmacology to second-year medical students. *Journal of Clinical Anesthesia*, 16:144–151, 2004.
- [15] Gaba DM and DeAnda A. A comprehensive anesthesia simulation environment: re-creating the operating room for research and training. *Anesthesiology*, 69:387–94, 1988.
- [16] Gaba DM, Fish KJ, and Howard SK. *Crisis Management In Anesthesiology*. Churchill Livingstone New York, 1994.
- [17] Gaba DM, Howard SK, Fish KJ, Brian E, Smith BE, Yasser A, and Sowb YA. Simulation-based training in anesthesia crisis resource management (acrm): A decade of experience. *Simulation & Gaming*, 32:175–193, 2001.
- [18] Wilhelm DM, Ogan K, Roehrborn CG, Cadeddu JA, and Pearle MS. Assessment of basic endoscopic performance using a virtual reality simulator. *Journal of the American College of Surgeons*, 195:675–81, 2002.
- [19] Woodrum DT, Andreatta PB, Yellamanchilli RK, Feryus L, Gauger PG, and Minter RM. Construct validity of the lapsim laparoscopic surgical simulator. *The American Journal of Surgery*, 191:28–32, 2006.

- [20] Charles E, Kahn CE, Linda M, Roberts LM, Katherine A, Shaffer KA, and Had-dawy P. Construction of a bayesian network for mammographic diagnosis of breast cancer. *Computers in Biology and Medicine*, 27:19–29, 1997.
- [21] Eugene Grois E, Hsu WH, Voloshin M, and Wilkins DC. Bayesian network models for generation of crisis management training scenarios. *Proceedings of the Tenth Innovative Applications of Artificial Intelligence Conference (IAAI-98)*, pages 1113–1120, 1998.
- [22] Giulio E, Fregonese D, Casetti T, Cestari R Chilovi F, DAmbra G, Matteo G, Ficano L, and Fave GD. Training with a computer-based simulator achieves basic manual skills required for upper endoscopy: a randomized controlled trial. *Gastrointestinal Endoscopy*, 60:196–200, 2004.
- [23] ECRI. A clinician's guide to surgical fires: how they occur, how to prevent them, how to put them out. *Health Devices*, 32:5–24, 2003.
- [24] Jackie EH. Building a national agenda for simulation-based medical education. *Advanced initiatives in medical simulation*, pages 1–40, 2004.
- [25] Richards EP and Walter C. Engineering and the law-how is an anesthesia machine like a lawnmower? the problem of the learned intermediary. *IEEE Eng Med Biol Mag*, 8:55–7, 1989.
- [26] Binstadt ES, Walls RM, White BA, Nadel ES, Takayesu JK, Barker TD, Nelson SJ, and Pozner CN. A comprehensive medical simulation education curriculum for emergency medicine residents. *Ann Emerg Med*, 49:1–11, 2007.
- [27] Burnside ES. Bayesian networks: Computer-assisted diagnosis support in radiology. *Academic Radiology*, 12:422–430, 2005.
- [28] Meller G. A typology of simulators for medical education. *J Digit Imaging*, 10:194–6., 1997.
- [29] Nackman GB, Bermann M, and Hammond J. Effective use of human simulators in surgical education. *Journal of Surgical Research*, 115:214–218, 2003.
- [30] Cooper GF and Herskovits E. A bayesian method for the induction of probabilistic networks from data. *Machine Learning*, 9, 1992.

- [31] Chin HL and Cooper GF. Case-based tutoring from a medical knowledge base. *Computer Methods and Programs in Biomedicine*, 30:185–198, 1989.
- [32] Kononenko I. Inductive and bayesian learning in medical diagnosis. *Applied Artificial Intelligence*, 7:317–337, 1993.
- [33] Kononenko I. Machine learning for medical diagnosis: History, state of the art and perspective, invited paper. *Artificial Intelligence in Medicine*, 23:89–109, 2001.
- [34] Kononenko I, Bratko I, and Kukar M. *Application of machine learning to medical diagnosis*. John Wiley & Sons, 1997.
- [35] Maglogiannis I, Zafropoulos E, Platis A, and Lambrinoudakis C. Risk analysis of a patient monitoring system using bayesian network modeling, journal of biomedical informatics, 2005. *Journal of Biomedical Informatics*, 2005.
- [36] Kononenko Igor. *Strojno uje*. Fakulteta za raalnitvo in informatiko Ljubljana, 2005.
- [37] Witten IH and Frank E. *Data Mining Practical machine learning tools and techniques 2nd Edition*. Morgan Kaufmann San Francisco, 2005.
- [38] Pearl J. Bayesian networks a model of self-activated memory for evidential reasoning. *Proceedings of the 7th Conference of the Cognitive Science Society University of California Irvine CA*, pages 329–334, 1985.
- [39] Pearl J. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference, Series in Representation and Reasoning*. Morgan Kaufmann Publishers San Mateo CA, 1988.
- [40] Pearl J. *Causality: models, reasoning, and inference*. Cambridge University Press, 2000.
- [41] Vozenilek J, Huff S, Reznek M, and Gordon JA. See one do one teach one: Advanced technology in medical education. *Acad Emerg Med*, 11:1149–1154, 2004.
- [42] Vozenileka J, Kharascha M, Wanga E, Aitchisona P, and Pearlmana M. High fidelity simulations can evoke strong physical and emotional stress responses but participants want more. *Annals of Emergency Medicine*, 48:114, 2001.
- [43] Doyle JD. Simulation in medical education: Focus on anesthesiology. *Med Educ Online*, pages 7–16, 2002.

- [44] Larsson JE, Hayes-Roth B, Gaba DM, and Smith BE. Evaluation of a medical diagnosis system using simulator test scenarios. *Artificial Intelligence in Medicine*, 11:119–140, 1997.
- [45] Nolan JP, Deakin CD, Soar J, Bttiger BW, and Smith G. European resuscitation council. european resuscitation council guidelines for resuscitation 2005. section 4. adult advanced life support. resuscitation. *Resuscitation*, 67:S39–86, 2005.
- [46] Adlassnig K. The section on medical expert and knowledge-based systems at the department of medical computer sciences of the university of vienna medical school. *Artificial Intelligence in Medicine*, 21:139–146, 2001.
- [47] Fletcher K, Davis SQ, Underwood W, Mangrulkar RS, McMahon LF, and Saint S. Systematic review: effects of resident work hours on patient safety. *Ann Intern Med*, 7:851–7, 2004.
- [48] Korb KB and Nicholson AE. *Bayesian Artificial Intelligence*. CHAPMAN & HALL/CRC A CRC Press Company Boca Raton London New York Washington, D.C., 2004.
- [49] Uffe B Kjaerulff and Anders L Madsen. *Bayesian Networks and Influence Diagrams: A Guide to Construction and Analysis*. Springer, 2008.
- [50] Kobayashi L, Shapiro M, Hill A, Suner S, and Jay G. Creating a mess (multiple encounter simulation scenario) for medical error reduction and enhanced medical education. *Academic Emergency Medicine*, 11:896, 2004.
- [51] Ohno Machado L, Resnic FS, and Matheny ME. Prognosis in critical care. *Annu Rev Biomed Eng.*, 8:567–99, 2006.
- [52] Laerdal. Simman advanced patient simulator. [www.laerdal.com](http://www.laerdal.com).
- [53] Reamer LE. Is there an evidence-based approach to anesthesia education? *Best Pract Res Clin Anaesthesiol*, 19:137–52, 2005.
- [54] Kohn LT, Corrigan JM, and Donaldson MS, editors. *To Err is Human: Building a Safer Health System*. National Academy Press, 1999.
- [55] Ahmed M, Meech JF, and Timoney A. Virtual reality in medicine. *Br J Urol*, 80:46–52, 1997.

- [56] Beaubien M and Baker DP. The use of simulation for training teamwork skills in health care: how low can you go? *Qual. Saf. Health Care*, 13:51–56., 2004.
- [57] Frydenberg M. The chain graph markov property. *Scandinavian Journal of Statistics*, 17:333353, 1989.
- [58] Krizmaric M and Grmec S. Assessment of single breath volume in emergency needle conicotomy. *Urgentna medicina izabrana poglavja 2007 Slovensko zdruenje za urgentno medicino*, pages 261–265., 2007.
- [59] Lee Peter M. *Bayesian statistics an introduction*. New York Oxford University Press London, 1989.
- [60] Weidenbach M, Trochim S, Kreutter S, Richter C, Berlage T, and Grunst G. Intelligent training system integrated in an echocardiography simulator. *Computers in Biology and Medicine*, 34:407–425, 2004.
- [61] METI. Medical education technologies. [www.meti.com](http://www.meti.com).
- [62] Gilbart MK, Hutchison CR, Cusimano MD, and Regehr G. A computer-based trauma simulator for teaching trauma management skills. *The American Journal of Surgery*, 179:223–228, 2000.
- [63] Hegarty MK and Bloch MB. The use of simulators in intensive care training. *Current Anaesthesia and Critical Care*, 13:194–200, 2002.
- [64] Weisfeldt ML. A three phase temporal model for cardiopulmonary resuscitation following cardiac arrest. *Trans Am Clin Climatol Assoc*, 115:115–22., 2004.
- [65] Graham MM and Metter DF. Evolution of nuclear medicine training: past, present, and future. *J Nucl Med*, 48:257–68, 2007.
- [66] Gordon MS, Ewy GA, DeLeon AC, Waugh RA, Felner JM, Forker AD, Gessner IH, Mayer JW, and Patterson D. "harvey,"the cardiology patient simulator: Pilot studies on teaching effectiveness. *The American Journal of Cardiology*, 45:791–796, 1980.
- [67] Shiratori N and Okude N. Bayesian networks layer model to represent anesthetic practice systems. *Man and Cybernetics ISIC IEEE International Conference*, pages 674–679, 2007.

- [68] Wermuth N and Lauritzen SL. On substantive research hypotheses, conditional independence graphs and graphical chain models. *Journal of the Royal Statistical Society Series*, 52:2150, 1990.
- [69] Medvedeva O and Crowley R. Reasoning in a tutoring system: Transforming knowledge to teaching. *Workshop on Prot and Reasoning Bethesda Maryland*, 2004.
- [70] Antal P, Fannes G, Timmerman D, Moreau Y, and De Moor B. Bayesian applications of belief networks and multilayer perceptrons for ovarian tumor classification with rejection. *Artificial Intelligence in Medicine*, 29:39–60, 2003.
- [71] Haddawy P, Jacobson J, Charles E, and Kahn E. Banter: a bayesian network tutoring shell, artificial intelligence in medicine. *Artificial Intelligence in Medicine*, 10:177–200, 1997.
- [72] Szolovits P, Patil RS, and Schwartz WB. Artificial intelligence in medical diagnosis. *Annals Of Internal Medicine*, 108:80–87, 1998.
- [73] Klaus PA. The section on medical expert and knowledge-based systems at the department of medical computer sciences of the university of vienna medical school. *Artificial Intelligence in Medicine*, 3:139–146, 2001.
- [74] Weinstock PH, Kappus LJ, Kleinman ME, Grenier B, Hickey P, and Burns JP. Toward a new paradigm in hospital-based pediatric education: the development of an onsite simulator program. *Pediatr Crit Care Med*, 6:712–3, 2005.
- [75] Lucas PJF, Boot H, and Taal BG. Computer-based decision-support in the management of primary gastric non-hodgkin lymphoma. *Meth Inform Med*, 37:20619, 1998.
- [76] Lucas PJF, De Brujin NC, Schurink K, and Hoepelman IM. A probabilistic and decision-theoretic approach to the management of infectious disease at the icu. *Artif Intell Med*, 19:25179, 2000.
- [77] Crowley R and Medvedeva O. *A General Architecture for Intelligent Tutoring of Diagnostic Classification Problem Solving*. Proceedings of the Annual AMIA Symposium, 2003.
- [78] Howard R and Matheson J. Influence diagrams. *Readings in Decision Analysis*, page 763771, 1981.

- [79] Kinshuk R, Lewis K, Akahori R, Kemp T, Okamoto L, and Henderson Lee CH. Does intelligent tutoring have future. *Proceedings of the International Conference on Computers in Education Los Alamitos CA IEEE Computer Society*, 2002.
- [80] Levine RL, Wayne MA, and Miller CC. End-tidal carbon dioxide and outcome of out-of-hospital cardiac arrest. *NEW ENGL J MED*, pages 301–337.
- [81] Satava RM. Emerging medical applications of virtual reality: A surgeon's perspective. *Artificial Intelligence in Medicine*, 6:281–288, 1994.
- [82] Christian RP. *The Bayesian choice a decision-theoretic motivation.* New York Springer, 1996.
- [83] Holzman RS, Cooper JB, and Gaba D. Anesthesia crisis resource management: real-life simulation training in operating room crises. *J Clin Anesth*, 7:67587, 1995.
- [84] Acida S, Camposa LM, Fernandez Lunab JM, Rodriguezc S, Rodriguezc JM, and Salcedoc JL. A comparison of learning algorithms for bayesian networks: a case study based on data from an emergency medical service. *Artificial Intelligence in Medicine*, 30:215232, 2004.
- [85] Andreassen S, Riekehr C, Kristensen B, Schonheyder HC, and Leibovici L. Using probabilistic and decisiontheoretic methods in treatment and prognosis modeling. *Artif Intell Med*, 15:12134., 1999.
- [86] Andreassen S, Jensen FV, and Olesen KG. Medical expert systems based on causal probabilistic networks. *International Journal of Biomedical Computing*, 28:1–30, 1991.
- [87] Andreassen S, Woldbye M, Falck B, and Andersen SK. Munin a causal probabilistic network for interpretation of electromyographic findings. *Proceedings of the 10th International Joint Conference on Artificial Intelligence*, pages 366–72, 1987.
- [88] Dawson S and Gould DA. Procedural simulations developing role in medicine. 369:1671–1673, 2007.
- [89] Grmec S, Krizmaric M, Lesnik B, and Kozelj T. Utstein stile. *Resuscitation*, 2007.
- [90] Sadeghi S, Barzi A, Sadeghi N, and King B. A bayesian model for triage decision support. *International Journal of Medical Informatics*, 75:403–411, 2006.

- [91] Suebnukarn S and Haddawy P. Collaborative intelligent tutoring system for medical problem-based learning. *Proceedings of the 9th conference on intelligent user interfaces*, pages 14–21, 2004.
- [92] Suebnukarn S and Haddawy P. A bayesian approach to generating tutorial hints in a collaborative medical problem-based learning system. *Artificial Intelligence in Medicine*, 2005.
- [93] Beyea SC. Preventing fires in the or - patient safety first. *AORN Journal*, 4:11–23, 2003.
- [94] Galan SF, Aguado F, Diez FJ, and Mira J. Nasonet: joining bayesian networks and time to model nasopharyngeal cancer spread. *Proceedings of the Eighth International Conference on Artificial Intelligence in Medicine in Europe (AIME 2001) Lecture Notes in Artificial Intelligence (LNAA) Springer-Verlag*, pages 207–16, 2001.
- [95] Lauritzen SL. The em algorithm for graphical association models with missing data. *Computational Statistics & Analysis*, 19:191201, 1995.
- [96] Lauritzen SL, Dawid AP, Larsen BN, and Leimer HG. Independence properties of directed markov fields. *Networks*, 20:491–505, 1990.
- [97] AORN Guidance Statement. Fire prevention in the operating room. *Standards, Recommended Practices, and Guidelines, AORN*, page Standards, 2005.
- [98] Murray T. Authoring intelligent tutoring systems: An analysis of the state of the art. *International Journal of Artificial Intelligence in Education*, 10:98–129, 1999.
- [99] Massoud TF and Gambhir SS. Integrating noninvasive molecular imaging into molecular medicine: an evolving paradigm. *Trends Mol Med*, 13:183–91, 2007.
- [100] VA Palo Alto Health Care System Stanford University. Simulation center for crisis management training in health care. [http://anesthesia.stanford.edu/VA\\_Simulator/](http://anesthesia.stanford.edu/VA_Simulator/).
- [101] Murray WB and Foster PA. Crisis resource management among strangers: principles of organizing a multidisciplinary group for crisis resource management. *J Clin Anesth*, 12:633–8, 2000.
- [102] Cole WG. Understanding bayesian reasoning via graphical displays. *ACM SIGCHI Bulletin archive*, 20:381–386, 1989.

- [103] Thoman WJ, Lampotang S, Gravenstein D, and Jan van der A. A computer model of intracranial dynamics integrated to a full-scale patient simulator. *Computers and Biomedical Research*, 31:32–46., 1998.
- [104] Meurs WL, Good ML, and Lampotang S. Functional anatomy of full-scale patient simulators. *J Clin Monit*, 13:317–24, 1997.

# Bibliografija

COBISS Kooperativni online bibliografski sistem in servisi COBISS

MILJENKO KRIŽMARIĆ [25641] Osebna bibliografija za obdobje 1997-2009

ČLANKI IN DRUGI SESTAVNI DELI

1.01 Izvirni znanstveni članek

1. KRIŽMARIĆ, Miljenko, KOKOL, Peter, KAMENIK, Mirt, MIČETIĆ-TURK, Dušanka. Using neural networks for prediction of central venous pressure during open-heart surgery. WSEAS Trans. Comput., 2004, vol. 3, iss. 6, str. 2124-2127. [COBISS.SI-ID 9307926]
2. KOKOL, Peter, VERLIČ, Mateja, KRIŽMARIĆ, Miljenko. Modelling teens clothing fashion preferences using machine learning. WSEAS transactions on information science and applications, October 2006, vol. 3, iss. 10, str. 2054-2065. [COBISS.SI-ID 10959638]
3. KRIŽMARIĆ, Miljenko, GRMEC, Štefek. Numerični izračuni pričakovanih deležev kisika v vdiharem zraku (FI02) različnih sistemov za aplikacijo kisika = Numerical calculation of expected fractional inspired oxygen concentrations (FI02) for different oxygen delivery systems. Med. meseč.. [Tiskana izd.], 2007, letn. 3, št. 9, str. 282-292, ilustr. [COBISS.SI-ID 1328292]
4. GRMEC, Štefek, KRIŽMARIĆ, Miljenko, MALLY, Štefan, KOŽELJ, Anton, ŠPINDLER, Mateja, LEŠNIK, Bojan. Utstein style analysis of out-of-hospital cardiac arrest-Bystander CPR and end expired carbon dioxide. Resuscitation. [Print ed.], 2007, vol. 72, no. 3, str. 404-414. [COBISS.SI-ID 2569279] JCR IF: 2.55, SE (8/19), critical care medicine, x: 2.702, SE (2/12), emergency medicine, x: 1.437
5. KOLAR, Miran, KRIŽMARIĆ, Miljenko, KLEMEN, Petra, GRMEC, Štefek. Partial pressure of end-tidal carbon dioxide successful predicts cardiopulmonary resus-

citation in the field - a prospective observational study. Crit. care (Lond., Online), 2008, vol. 12, no. 5, str. R115 [1-13]. <http://ccforum.com/content/pdf/cc7009.pdf>, doi: 10.1186/cc7009. [COBISS.SI-ID 3030847] JCR IF (2007): 3.834, SE (4/19), critical care medicine, x: 2.702

#### 1.02 Pregledni znanstveni članek

6. KRIŽMARIĆ, Miljenko. Centralna dogma medicinske informatike = The central dogma of medical informatics. Med. meseč.. [Tiskana izd.], 2006, letn. 2, št. 10, str. 288-297, ilustr. [COBISS.SI-ID 1224612]

#### 1.04 Strokovni članek

7. TURK, Zmago, KRIŽMARIĆ, Miljenko, MIČETIĆ-TURK, Dušanka. Simulacija bolezni - nova oblika edukacije medicinskega kadra. Med. meseč.. [Tiskana izd.], 2005, letn. 1, št. 10-11, str. 35-38. [COBISS.SI-ID 2106431]

#### 1.05 Poljudni članek

8. TURK, Zmago, KRIŽMARIĆ, Miljenko, MIČETIĆ-TURK, Dušanka. Medicinski simulacijski center Visoke zdravstvene šole Univerze v Mariboru. Isis (Ljubl.), 2005, letn. 14, št. 7, str. 52-54. [COBISS.SI-ID 1985599]

9. BLAŽUN, Helena, KRIŽMARIĆ, Miljenko, KOKOL, Peter. Simulacijski centri - inovativni izobraževalni pristop pri zagotavljanju k pacientu usmerjene zdravstvene oskrbe. Isis (Ljubl.), 2008, leto 17, št. 2, str. 77-78, ilustr. [COBISS.SI-ID 1358244]

#### 1.06 Objavljeni znanstveni prispevek na konferenci (vabljeno predavanje)

10. LAH, Katja, GRMEC, Štefek, KRIŽMARIĆ, Miljenko. Analiza hitrega uvajanja v anestezijo v Centru za nujno medicinsko pomoč in reševalne prevoze Maribor = Analysis of rapid sequence intubation in the Center for emergency medicine Maribor. V: GRMEC, Štefek (ur.), KUPNIK, Dejan (ur.). Akutna stanja : znamenja, simptomi, sindromi, diferencialna diagnoza in ukrepanje : 3. strokovni seminar z mednarodno udeležbo : zbornik predavanj, Maribor, 4.-6. oktober 2007 : signs, symptoms, syndromes, differential diagnosis and management : 3rd International seminar on acute medicine : proceedings and algorithms, Maribor, 4.-6. oktober 2007, (Zbirka Acuta). Maribor: Zdravstveni dom dr. Adolfa Drolca, Center za nujno medicinsko pomoč in reševalne prevoza, 2007, str. 272-275. [COBISS.SI-ID 2764351]

#### 1.07 Objavljeni strokovni prispevek na konferenci (vabljeno predavanje)

11. KRIŽMARIĆ, Miljenko, JERENKO, Breda, REBERNIK-MILIĆ, Manica, BREZOVEC, Marija. Potencialni viri resnih neželenih škodljivih učinkov v prostorih operacijskega bloka. V: REBERNIK-MILIĆ, Manica (ur.). Zagotovimo varnost pacienta : zbornik XXI : Kongresni center hotela Mons v Ljubljani, 24. novembra 2006. [Ljubljana]: Sekcija medicinskih sester in zdravstvenih tehnikov v operativni dejavnosti, 2006, str. 60-77, ilustr. [COBISS.SI-ID 1226148]
12. KRIŽMARIĆ, Miljenko, JERENKO, Breda, REBERNIK-MILIĆ, Manica, BREZOVEC, Marija. Analiza varnostnih sistemov sodobne elektrokirurške opreme. V: REBERNIK-MILIĆ, Manica (ur.). Zagotovimo varnost pacienta : zbornik XXI : Kongresni center hotela Mons v Ljubljani, 24. novembra 2006. [Ljubljana]: Sekcija medicinskih sester in zdravstvenih tehnikov v operativni dejavnosti, 2006, str. 78-96, ilustr. [COBISS.SI-ID 1225892]
- 1.08 Objavljeni znanstveni prispevek na konferenci
13. TIČAR, Igor, KRIŽMARIĆ, Miljenko, KITAK, Peter, BIRÓ, Oszkar, PREIS, Kurt. Impact of surrounding conductive metal objects on specific absorption rate (SAR) in phantom head, caused by the radiation of mobile phones. V: WIAK, Sławomir (ur.), KRAWCZYK, Andrzej (ur.), TRLEP, Mladen (ur.). XI. International symposium on electromagnetic fields in electrical engineering, ISEF 2003, September 18-20, 2003, Maribor, Slovenia. Maribor: FERI, 2003, vol. 2, str. 913-918. [COBISS.SI-ID 8213014]
14. KRIŽMARIĆ, Miljenko, KOKOL, Peter, KAMENIK, Mirt, MIČETIĆ-TURK, Dušanka. Using neural networks for prediction of central venous pressure during open-heart surgery. V: GARCIA-PLANAS, M. I. (ur.), ANDINA, D. (ur.), BILBAO, J. (ur.), RAMOS, T. (ur.), MASTORAKIS, Nikos E. (ur.), MAURI, J. L. (ur.), ZORMAN, Milan (ur.). Proceedings of the WSEAS conferences: Applied informatics and communications (AIC'04), Signal processing, computational geometry artificial vision (ISCGAV'04), Systems theory and scientific computation (ISTASC'04), Puerto De La cruz, Tenerife, canary Islands, Spain, December 17-19, 2004. [S. l.]: WSEAS, 2004, [4] f. [COBISS.SI-ID 9305622]
15. POVALEJ, Petra, KRIŽMARIĆ, Miljenko, KOKOL, Peter, PEHNEC, Zlatko. Intelligent analysis of long-term patient survival after pacemaker implantation. V: MURRAY, Alan (ur.). Computers in cardiology 2005, September 25-28, 2005, Lyon, France, (Computers in cardiology, vol. 32). Piscataway: The Institute of Electrical and Electronics Engineers, cop. 2005, vol. 32, str. 251-254. [COBISS.SI-ID 10327318]

16. MERTIK, Matej, KRIŽMARIĆ, Miljenko, ZABAVNIK, Zoran, ZORMAN, Milan, ŠTIGLIC, Gregor, MIČETIĆ-TURK, Dušanka, KOKOL, Peter. Dynamic datamining with complexity theory - the case of prognosing sepsis. V: KNEPPO, Peter (ur.), HOZMAN, Jiří (ur.). European Medical and Biological Engineering Conference, November 20-25, 2005 Prague, Czech Republic. EMBEC'05 : proceedings, (IFMBE Proceedings, Vol. 11). Prague: EMBEC'05 IFMBE, 2005, [3] f. [COBISS.SI-ID 10048022]
17. KRIŽMARIĆ, Miljenko, ŽMAUC, Tanja, MIČETIĆ-TURK, Dušanka, ŠTIGLIC, Gregor, KOKOL, Peter. Time allocation simulation model of clean and dirty pathways in hospital environment. V: TSYMBAL, Alexey (ur.), CUNNINGHAM, Pádraig (ur.). Eighteenth IEEE symposium on computer-based medical systems, 23-24 June 2005, Dublin, Ireland. Proceedings, (Proceedings - IEEE Symposium on Computer-Based Medical Systems). Los Alamitos [etc.]: IEEE Computer society, cop. 2005, str. 123-127. [COBISS.SI-ID 9655830]
18. KRIŽMARIĆ, Miljenko, KOŽELJ, Anton. In vitro primerjava pretokov fiziološke raztopine skozi različne IV kanile v odvisnosti od hidrostatičnega tlaka = In vitro comparision of flow through different IV cannulae depending on hydrostatic pressure. V: GRIČAR, Marko (ur.), VAJD, Rajko (ur.), ŠTROMAJER, Draga (ur.), PRESTOR, Jože (ur.). Urgentna medicina : izbrana poglavja 2006 : zbornik : selected topics 2006 : proceedings. Ljubljana: Slovensko združenje za urgentno medicino: = Slovenian Society for Emergency Medicine, 2006, 2006, str. 478-481. [COBISS.SI-ID 1182372]
19. MIČETIĆ-TURK, Dušanka, KRIŽMARIĆ, Miljenko, BLAŽUN, Helena, KRČEVSKI-ŠKVARČ, Nevenka, KOŽELJ, Anton, KOKOL, Peter, GRMEC, Štefek, TURK, Zmago. Simulation in medicine and nursing - First experiences in simulation centre at Faculty of Health Sciences University of Maribor. V: JARM, Tomaž (ur.), KRAMAR, Peter (ur.), ŽUPANIČ, Anže (ur.). 11th Mediterranean Conference on Medical and Biological Engineering and Computing 2007, 26-30 June, 2007, Ljubljana, Slovenia, (IFMBE proceedings, vol. 16). New York: Springer: International Federation for Medical and Biological Engineering, 2007, [str. 716-718]; PDF (3 str.). [COBISS.SI-ID 1298084]
20. KRIŽMARIĆ, Miljenko. Nevarni uhajajoči električni tokovi med defibrilacijo = Alternative accidental electrical pathways during defibrillation. V: GRMEC, Štefek (ur.), KUPNIK, Dejan (ur.). Akutna stanja : znamenja, simptomi, sindromi, diferencialna diagnoza in ukrepanje : 3. strokovni seminar z mednarodno udeležbo : zbornik predavanj, Maribor, 4.-6. oktober 2007 : signs, symptoms, syndromes, differential diagnosis and management : 3rd International seminar on acute medicine : proceedings and algorithms,

Maribor, 4.-6. oktober 2007, (Zbirka Acuta). Maribor: Zdravstveni dom dr. Adolfa Drolca, Center za nujno medicinsko pomoč in reševalne prevoza, 2007, str. 262-265, ilustr. [COBISS.SI-ID 1322148]

21. KRIŽMARIĆ, Miljenko, JERENKO, Breda, GORIŠEK, Borut, REBERNIK-MILIĆ, Manica, MIČETIĆ-TURK, Dušanka. Alternativne metode simulacij v elektrokirurgiji - koagulacija jajčnega rumenjaka. V: REBERNIK-MILIĆ, Manica (ur.). Gradimo mostove znanj : zbornik XXIII, Gurmanski hram, Maribor, 23. in 24. november 2007. 1. izd. Ljubljana: Zbornica zdravstvene in babiške nege Slovenije, Zveza društev medicinskih sester, babic in zdravstvenih tehnikov Slovenije, Sekcija medicinskih sester in zdravstvenih tehnikov v operativni dejavnosti, 2007, str. 117-135, ilustr. [COBISS.SI-ID 1344164]

22. VERLIČ, Mateja, KRIŽMARIĆ, Miljenko, GRMEC, Štefek, KOKOL, Peter. Intelligent data analysis of out-of-hospital cardiac arrest. V: KOKOL, Peter (ur.), PODGORELEC, Vili (ur.), MIČETIĆ-TURK, Dušanka (ur.), ZORMAN, Milan (ur.), VERLIČ, Mateja (ur.). Twentieth IEEE International Symposium on Computer-Based Medical Systems, 20-22 June 2007, Maribor, Slovenia. Proceedings, (Proceedings - IEEE Symposium on Computer-Based Medical Systems, 1063-7125). Los Alamitos [etc.]: IEEE Computer Society, cop. 2007, str. 109-114. [COBISS.SI-ID 11494678]

23. KRIŽMARIĆ, Miljenko, GRMEC, Štefek. Ocena enkratnega dihalnega volumna pri izvajanju urgentne igelne konikotomije = Assessment of single breath volume in emergency needle conicotomy. V: GRIČAR, Marko (ur.), VAJD, Rajko (ur.). Urgentna medicina : izbrana poglavja 2007 : zbornik : selected topics : proceedings. Ljubljana: Slovensko združenje za urgentno medicino: = Slovenian Society for Emergency Medicine, 2007, str. 261-265. [COBISS.SI-ID 2692927]

24. VOZLIČ, Irena, KRIŽMARIĆ, Miljenko. Učinek odprtih in zaprtih gravitacijskih infuzijskih sistemov na čas IV infuzije iz fleksibilnih posod = The impact of open and closed gravitational infusion systems on time of intravenous infusion from flexible bags. V: GRIČAR, Marko (ur.), VAJD, Rajko (ur.). Urgentna medicina : izbrana poglavja 2007 : zbornik : selected topics : proceedings. Ljubljana: Slovensko združenje za urgentno medicino: = Slovenian Society for Emergency Medicine, 2007, str. 462-464. [COBISS.SI-ID 1297572]

25. KRIŽMARIĆ, Miljenko, VALENČIČ, Gabrijela. Projekcija indikatorjev kakovosti ameriškega sistema MEDICARE na Obalni dom upokojencev Koper. V: ŽARGI, Darinka (ur.). Biti boljši na poti do boljšega : zbornik referatov. Ljubljana: Slovensko združenje

za kakovost, 2008, str. 228-231. [COBISS.SI-ID 1435300]

26. KRIŽMARIĆ, Miljenko, MERTIK, Matej. Application of Bayesian networks in emergency medicine. V: AURER, Boris (ur.), BAČA, Miroslav (ur.), RABUZIN, Kornelije (ur.). 19th Central European Conference on Information and Intelligent Systems, September 24-26, 2008, Varaždin, Croatia. Conference proceedings. Varaždin: University of Zagreb, Faculty of Organisation and Informatics, 2008, str. 347-351. [COBISS.SI-ID 1435556]

27. VERŠNIK, Darja, KRIŽMARIĆ, Miljenko, GRMEC, Štefek. Zastrupitve - vedno aktualna aktualnost kdaj in kako ukrepati. V: PLANK, Darja (ur.). Izobraževanje medicinskih sester za varno in kakovostno zdravstveno nego : zbornik predavanj 9. strokovnega srečanja medicinskih sester in zdravstvenih tehnikov celjske regije, Celje, 09. 10. 2008. Celje: Društvo medicinskih sester, babic in zdravstvenih tehnikov, 2008, str. 27-31. [COBISS.SI-ID 1427876]

28. KRIŽMARIĆ, Miljenko, VALENČIČ, Gabrijela, HORVAT, Dean. Standardi ali smernice - statične ali dinamične strukture v znanstveno raziskovalnem delu = Standards or guidelines - static or dynamic structures in science research. V: SKELA-SAVIČ, Brigita (ur.), KAUČIČ, Boris Miha (ur.), RAMŠAK-PAJK, Jožica (ur.). 1st International Scientific Conference, September 25-26, 2008, Bled, Slovenia. Theory, research and practice - the three pillars of contemporary nursing care : proceedings of lectures with peer review : 1st international scientific conference : zbornik predavanj z recenzijo : 1. mednarodna znanstvena konferenca, September 25-26, 2008, Bled, Slovenia. Jesenice: College of Nursing: = Visoka šola za zdravstveno nego, 2008, str. 196-199. [COBISS.SI-ID 1419428]

29. JERENKO, Breda, KRIŽMARIĆ, Miljenko. Novi pristopi k izobraževanju v operacijskem bloku. V: REBERNIK-MILIĆ, Manica (ur.). Vseživljenjsko izobraževanje : zbornik XXIV, Bled (Hotel Kompas), 21. in 22. november 2008. 1. izd. Ljubljana: Zbornica zdravstvene in babiške nege Slovenije, Zveza strokovnih društev medicinskih sester, babic in zdravstvenih tehnikov Slovenije, Sekcija medicinskih sester in zdravstvenih tehnikov v operativni dejavnosti, 2008, str. 20-35, ilustr., graf. prikazi. [COBISS.SI-ID 1438884]

30. KRIŽMARIĆ, Miljenko, FEKONJA, Zvonka. Sistemski pristop v izobraževanju zaposlenih na kompleksnih področjih zdravstvene nege in terapije. V: RAJKOVIČ, Vladislav (ur.), JEREŠ, Eva (ur.), KERN, Tomaž (ur.), KLJAJIĆ, Miroljub (ur.), PAGON, Milan (ur.), VUKOVIČ, Goran (ur.). 27. mednarodna znanstvena konferenca

o razvoju organizacijskih znanosti, Slovenija, Portorož, 19.-21. marec 2008. Znanje za trajnostni razvoj : zbornik 27. mednarodne znanstvene konference o razvoju organizacijskih znanosti, Slovenija, Portorož, 19.-21. marec 2008 : proceedings of the 27th International Conference on Organizational Science Development, Slovenia, Portorož, March, 19th-21th, 2008. Kranj: Moderna organizacija, 2008, str. 1331-1336. [COBISS.SI-ID 1395364]

#### 1.09 Objavljeni strokovni prispevki na konferenci

31. KOŽELJ, Anton, KRIŽMARIĆ, Miljenko, MIČETIĆ-TURK, Dušanka. Predstavitev simulacijskega centra Visoke zdravstvene šole Univerze v Mariboru = The presentation of the simulation center of University college of nursing studies - University of Maribor. V: GRMEC, Štefek (ur.), KUPNIK, Dejan (ur.). Akutna stanja : znamenja, simptomi, sindromi, diferencialna diagnoza in ukrepanje : 2. strokovni seminar z mednarodno udeležbo : zbornik predavanj in algoritmov ukrepanja, Maribor, 6.-8. oktober 2005, (Zbirka Acuta). Maribor: Zdravstveni dom dr. Adolfa Drolca, Center za nujno medicinsko pomoč in reševalne prevoze: Univerza v Ljubljani, Medicinska fakulteta, Katedra za družinsko medicino, 2005, str. 218-220. [COBISS.SI-ID 2073151]

32. KOŽELJ, Anton, KRIŽMARIĆ, Miljenko. Uporaba stetoskopa v urgentnih stanjih za zdravstvene tehnike in diplomirane medicinske sestre / dipl. zdravstvenike = The use of stethoscope by nurses in urgent situations. V: BRUČAN, Andrej (ur.), GRIČAR, Marko (ur.), VAJD, Rajko (ur.), FINK, Andrej (ur.), ŠTROMAJER, Draga (ur.). Dvanajsti mednarodni simpozij o urgentni medicini, Portorož, Slovenija, 15.-18. junij 2005. Urgentna medicina : izbrana poglavja : zbornik : selected topics 2005 : proceedings. Ljubljana: Slovensko združenje za urgentno medicino: = Slovenian Society for Emergency Medicine, 2005, str. 395-397, ilustr. [COBISS.SI-ID 1060772]

33. MIČETIĆ-TURK, Dušanka, BLAŽUN, Helena, KRIŽMARIĆ, Miljenko, KRČEVSKI-ŠKVARČ, Nevenka, KOŽELJ, Anton, KOKOL, Peter, GRMEC, Štefek. Simulacije v medicini in zdravstveni negi - prve izkušnje v Simulacijskem centru Visoke zdravstvene šole Univerze v Mariboru. V: KODRIČ, N. (ur.). Zbornik predavanj. Ljubljana: Slovensko združenje za anestezijologijo in intenzivno medicino, Slovensko zdravniško društvo, 2005, 4 str. [COBISS.SI-ID 1080740]

34. KRIŽMARIĆ, Miljenko. Biomedical technology as a new opportunity in nursing research and education. V: MIČETIĆ-TURK, Dušanka (ur.), KOKOL, Peter (ur.). Developing research in nursing, social care education and multisectoral cooperation. Maribor: University College of Nursing Studies, 2006, str. 28-34, ilustr. [COBISS.SI-ID

1202596]

35. KRIŽMARIĆ, Miljenko. Medical device accidents and human error. V: MIČETIĆ-TURK, Dušanka (ur.), KOKOL, Peter (ur.). Developing research in nursing, social care education and multisectoral cooperation. Maribor: University College of Nursing Studies, 2006, str. 35-40, ilustr. [COBISS.SI-ID 1202852]

36. KOŽELJ, Anton, KRIŽMARIĆ, Miljenko, STRAUSS, Maja. Uporaba kisika in ravnanje s kisikovo jeklenko = Use of oxygen and handling with oxygen cylinder. V: GRIČAR, Marko (ur.), VAJD, Rajko (ur.), ŠTROMAJER, Draga (ur.), PRESTOR, Jože (ur.). Urgentna medicina : izbrana poglavja 2006 : zbornik : selected topics 2006 : proceedings. Ljubljana: Slovensko združenje za urgentno medicino: = Slovenian Society for Emergency Medicine, 2006, 2006, str. 436-439. [COBISS.SI-ID 1182628]

37. SLEMENJAK, Janja, KRIŽMARIĆ, Miljenko. Hemodinamski nadzor bolnika med operativnim posegom. V: REBERNIK-MILIĆ, Manica (ur.). Gradimo mostove znanj : zbornik XXIII, Gurmanski hram, Maribor, 23. in 24. november 2007. 1. izd. Ljubljana: Zbornica zdravstvene in babiške nege Slovenije, Zveza društev medicinskih sester, babic in zdravstvenih tehnikov Slovenije, Sekcija medicinskih sester in zdravstvenih tehnikov v operativni dejavnosti, 2007, str. 136-145, ilustr. [COBISS.SI-ID 1344420]

38. KRIŽMARIĆ, Miljenko. Tehnološko podprtne metode izobraževanja za kompleksna področja diagnostike in terapije. V: BABIČ, Darinka (ur.). Izobraževanje za zdravstveno nego - možnosti, priložnosti in ovire : zbornik predavanj strokovnega seminarja, Maribor, 30. 11. 2007. Maribor: Zbornica zdravstvene in babiške nege Slovenije, Sekcija medicinskih sester v vzgoji in izobraževanju, 2007, str. 52-61, ilustr. [COBISS.SI-ID 1343908]

39. MERTIK, Matej, KRIŽMARIĆ, Miljenko. Farmakokinetični in farmakodinamični fiziološki modeli - integralne informacijske enote v medicinskih simulatorjih. V: RODIČ, Blaž (ur.). Informatika v sodobni družbi : zbornik prispevkov 2. strokovnega posvetu Informatika v sodobni družbi, Novo Mesto, 22. september 2008. Novo mesto: Fakulteta za informacijske študije, 2008, str. 63-69. [COBISS.SI-ID 1431460]

40. HORVAT, Dean, VALENČIČ, Gabrijela, KRIŽMARIĆ, Miljenko. Tehnologija hiperbarične oksigenacije in oskrba težkih kroničnih ran gerontoloških bolnikov. V: SMRKE, Dragica (ur.), TRILLER, Ciril (ur.), NIKOLIČ, Janja (ur.), TRIFUNOVIČ, Dragana (ur.). [Kronična rana in bolečina : zbornik predavanj]. Ljubljana: Klinični oddelek za kirurške okužbe, Kirurška klinika, Univerzitetni klinični center, 2008, str. 76-80, ilustr.

[COBISS.SI-ID 1393828]

41. BEGANOVIC, Nevenka, VALENCIĆ, Gabrijela, KRIŽMARIĆ, Miljenko. Nujna stanja v domu upokojencev - opredelitev, oskrba in trend = Emergency cases in littoral nursing home Koper. V: GRIČAR, Marko (ur.), VAJD, Rajko (ur.). Petnajsti mednarodni simpozij o urgentni medicini, Portorož, 11.-14. junij 2008. Urgentna medicina : izbrana poglavja 2008 : zbornik : selected topics : proceedings. Ljubljana: Slovensko združenje za urgentno medicino: = Slovenian Society for Emergency Medicine, 2008, str. 423-425. [COBISS.SI-ID 1396388]

42. KRIŽMARIĆ, Miljenko. Medicinski simulatorji v procesih izobraževanja na področju anestezije. V: NUNAR PERKO, Andreja (ur.), KARDOŠ, Zorica (ur.). Varnost pacientov pred, med in po anesteziji : [zbornik predavanj]. Ljubljana: Sekcija medicinskih sester in zdravstvenih tehnikov v anesteziologiji, intenzivni terapiji in transfuziologiji, 2008, str. 83-87, ilustr. [COBISS.SI-ID 1393572]

#### 1.12 Objavljeni povzetek znanstvenega prispevka na konferenci

43. MIČETIĆ-TURK, Dušanka, KRIŽMARIĆ, Miljenko, BLAŽUN, Helena, KRČEVSKI-ŠKVARČ, Nevenka, KOŽELJ, Anton, KOKOL, Peter, GRMEC, Štefek, TURK, Zmago. Simulation in medicine and nursing. First experiences in Simulation centre at Faculty of Health Sciences University of Maribor. V: KRAMAR, Peter (ur.), JARM, Tomaž (ur.), ŽUPANIĆ, Anže (ur.), MIKLAVČIĆ, Damijan (ur.). 11th Mediterranean Conference on Medical and Biological Engineering and Computing - Medicon 2007, Ljubljana, June 26-30, 2007. Conference programme book of abstracts. 1. izd. Ljubljana: Fakulteta za elektrotehniko, 2007, str. 71-72. [COBISS.SI-ID 1291172]

44. PERDIJA, Željko, KRIŽMARIĆ, Miljenko. Primerjava treh vrst lokalnih anestezij pri bronhoskopiji z upogljivim instrumentom. V: KERN, Izidor (ur.). Book of abstracts. Golnik: University Clinic of Respiratory and Allergic Diseases, 2008, str. 145-147. [COBISS.SI-ID 24877017]

45. KRIŽMARIĆ, Miljenko. Biomedicinska tehnologija i simulatori u anesteziji i intenzivnoj medicini = Biomedical technology and simulators in anaesthesia and intensive care medicine. V: Zbornik sažetaka. [s.l.]: [s.n.], 2008, str. 66-67. [COBISS.SI-ID 1436324]

#### MONOGRAFIJE IN DRUGA ZAKLJUČENA DELA

##### 2.03 Univerzitetni ali visokošolski učbenik z recenzijo

46. MANOHIN, Aleksander, KRIŽMARIĆ, Miljenko. Temeljne fizikalne osnove v anesteziologiji, anestezijski aparat, anestezijski dihalni sistemi in anestezijski ventilator : [učbenik za fakultetni študij anesteziologije]. Maribor: Visoka zdravstvena šola, 2006. 128 str., ilustr. ISBN 961-6254-32-4. [COBISS.SI-ID 56141057]

#### 2.05 Drugo učno gradivo

47. KRIŽMARIĆ, Miljenko. Simulacije kot komplementarne metode v procesih izobraževanja : zbrano gradivo za interno uporabo : Simulacijski center Visoke zdravstvene šole Univerze v Mariboru. Maribor: [M. Križmarić], 2006. 64 f., ilustr. [COBISS.SI-ID 1224356]

#### 2.09 Magistrsko delo

48. KRIŽMARIĆ, Miljenko. Numerični izračun stopnje specifične absorpcije sevanja fantomskega modela glave pri mobilnem telefoniranju : magistrsko delo. Maribor: [M. Križmarić], 2000. IV, 94 f., graf. prikazi. [COBISS.SI-ID 5925910]

#### 2.25 Druge monografije in druga zaključena dela

49. KRIŽMARIĆ, Miljenko. Neionizirana sevanja in njihov vpliv na biološke sisteme : (uporaba numeričnih metod pri izračunu polj) : diplomska delo visokošolskega študija, (Fakulteta za elektrotehniko, računalništvo in informatiko, Diplomska dela visokošolskega študija). Maribor: [M. Križmarić], 1997. 91 f. + pril. (loč. pag.), graf. prikazi. [COBISS.SI-ID 2797078]

### IZVEDENA DELA (DOGODKI)

#### 3.15 Prispevek na konferenci brez natisa

50. KRIŽMARIĆ, Miljenko. Dihanje modre in bele kisikove jeklenke : [13. mednarodni simpozij o urgentni medicini, 14. - 17. junij 2006, Portorož]. Porotrož, 2006. [COBISS.SI-ID 1182884]

### SEKUNDARNO AVTORSTVO

#### Mentor pri diplomskega delih

51. ANGELINI, Kristina. Izdelava modela zagotavljanja varnosti pacientov in zdravstvenih delavcev v prostorih operacijskega bloka : diplomska delo. Maribor: [K. Angelini], 2008. V, 76 f., 5 f. pril., ilustr. [COBISS.SI-ID 1417124]

52. JERENKO, Breda. Priprava simulacijskega okolja operacijskega bloka za potrebe izobraževanja na področju biomedicinske tehnologije : diplomska delo. Maribor: [B.

Jerenko], 2008. IX, 75 f., [1] f. pril., 3 f. pril., ilustr. [COBISS.SI-ID 1386148]

53. ŠTUMPFL, Anita. Biomedicinska tehnologija zunajtelesne membranske oksigenacije (ECMO) pri otrocih : (diplomsko delo). Maribor: [A. Štumpfl], 2009. VII, 59 f., [2] f. pril., ilustr. <http://dkum.uni-mb.si/IzpisGradiva.php?id=9930>. [COBISS.SI-ID 1444516]

Komentor pri diplomskeih delih

54. ŽULJEVIČ, Ivana. Analiza podatkov IVZ RS o vzrokih za porast samomorilnosti pri otrocih in mladostnikih : diplomska naloga, (Visoka zdravstvena šola, Maribor, Diplomska dela, 1222). Maribor: [Ž. Ivana], 2005. 91 f., graf. prikazi. [COBISS.SI-ID 1011620]

55. KOŽELJ, Cvetka. Zdravstvena nega v luči medijev : diplomska naloga, (Visoka zdravstvena šola, Maribor, Diplomska dela, 1495). Maribor: [C. Koželj], 2006. [40] f., graf. prikazi. [COBISS.SI-ID 1204900]

56. CAJGER, Dejan. Vpliv vseživljenskega izobraževanja na poznavanje sodobnih tehnologij v enotah nujne medicinske pomoči : diplomsko delo. Maribor: [D. Cajger], 2007. [82] f., ilustr. [COBISS.SI-ID 1302692]

Pisec recenzij

57. KRAJNC, Ivan. Simulacijski postopki v medicini = Simulation procedures in medicine. V Mariboru: Medicinska fakulteta, 2008. ISBN 978-961-6739-04-7. [COBISS.SI-ID 61183745]

Zahteva za izpis bibliografije je bila poslana z računalnika: 164.8.136.69(164.8.136.69)  
Izpis bibliografskih enot: vse bibliografske enote Izbrani format bibliografske enote: ISO  
690



# Življenjepis in strokovna biografija

MILJENKO KRIŽMARIĆ

## ŽIVLJENJEPIS

Osnovno šolo je obiskoval in končal v Ormožu. Srednjo elektro računalniško šolo Maribor – SERŠ je končal leta 1989 na smeri elektronike. Po končani srednji šoli se je vpisal na Fakulteto za elektrotehniko, računalništvo in informatiko Maribor – smer elektronika. Na FERI je diplomiral leta 1997 z diplomskim delom Neionizirana sevanja in njihov vpliv na biološke sisteme (mentorstvo je prevzel prof. dr. Igor Tičar). Vojaško obveznost je leta 1997 odslužil v Vojašnici Celje. Magisterij je končal leta 2000, na področju sevanja mobilnih telefonov z naslovom magistrske naloge Numerični izračuni stopnje specifične absorpcije sevanja fantomskih modelov glave pri mobilnem telefoniranju. Mentor je bil prof. dr. Igor Tičar.

## STROKOVNA BIOGRAFIJA

Tovarna sladkorja Ormož, 1991. Delovna praksa. Študijska praksa. Avtomatika proizvodnje sladkorja, regulacije sistemov, krmiljenja sistemov, radioaktivno merjenje gostote fluidov, tovarniški tehnološki procesi.

Opekarna Ograd Ormož, 1997. Pripravnštvo. Strokovni izpit. Informacijski sistem preventivnega vzdrževanja tovarne, tehnologija priprave, mešanja, žganja opeke, SIEMENS PLC Simatic S5 programabilni logični krmilniki. Izvajanje del v sušilnici, priprave materiala za žganje, plinski gorilniki na peči, sodelovanje z INEA in inštitutom Jožef Stefan.

TeoTen Ljutomer, 1998. Projektant. Projekti na področju telekomunikacijskih rešitev, kabelskih sistemov, lokalna računalniška omrežja, električne inštalacije, avtomatika, inteligenčne instalacije, projekti bazenskih tehnik.

Iskratel Kranj, 1999. Raziskovanje / razvoj (R/D) Raziskave in razvoj IN – Inteligent-

nih omrežij, GPRS, UMTS, OCANEQ tehnologije, centrale SI 2000 in EWD Siemens, končan Specialni program izobraževanja za področje komutacije.

Splošna bolnišnica Ptuj, 2000. Sistemski inženir Implementacija delovnih postaj in serverjev v bolnišnični informacijski sistem MEDIS, priklopi mrežne opreme in komunikacijskih vozlišč, uvajanje zaposlenih za delo z bolnišničnim informacijskim sistemom (MEDIS), reševanje težav povezanih z delovanjem MEDIS-a, uvajanje za delo s čitalci kartic zdravstvenega zavarovanja, vzdrževanje čitalcev kartic zdravstvenega zavarovanja, upravljanje podatkovne baze medicinskega informacijskega sistema, ažuriranje podatkovne baze, pošiljanje podatkov na Inštitut za varovanje zdravja IVZ in pošiljanje ustreznih formatov podatkov na Zavod za zdravstveno zavarovanje ZZZS, 24-urna pripravljenost–vse dni v tednu, povezana z delovanjem računalniškega sistema, uvajanje in pomoč pri kompleksni medicinski opremi. Dodatna izobraževanja iz Paliativne oskrba bolnika, Telekomunikacij v zdravstvu, Informatike v zdravstvu, Informacijske družbe v javnem sektorju. Sodelovanje v razvoju implementacije Olympus ENDOBASE kliničnega informacijskega sistema.

Ljudska univerza Ormož, 2003. Predavatelj predmetov: Računalništvo in informatika, Elektrotehnika, Laboratorijske vaje, Prenosna in informacijska elektronika, Elektronska vezja, Digitalni sistemi, Merjenja in regulacije ter Vezja in naprave. Član in predsednik maturitetnih komisij in izvajanje računalniških tečajev za občane občine Ormož.

Univerza v Mariboru, FERI, 2003. Asistent z magisterijem Asistent na področju elektronike. Izvajanje laboratorijskih vaj iz področja elektronike.

Univerza v Mariboru, Fakulteta za zdravstvene vede Maribor, 2004. Strokovni sodelavec, asistent. Izdelava idejnega projekta simulacijskega centra, prostorska ureditev simulacijskega centra, vzdrževanje strojne in programske opreme delovnih postaj, posnetki stanj medicinskih simulacijskih centrov, projektiranje postavljanja NIST sistemov, standardi EN 737 – sistemi napeljav za medicinske pline, elektrostatika, projektiranje elektrostatičnih zaščit simulacijskega centra, priprava strojne opreme BLS, ALS, ACLS, ATLS simulatorjev, priprava programske opreme simulatorjev. Priprava biomedicinske tehnologije za izobraževalne namene. Sodelovanje v učnih procesih Uvoda v raziskovalno delo, Statistike, Informatike v zdravstveni negi, Nujne medicinske pomoči, Perioperativne zdravstvene nege, Simulacij v zdravstvu in Biomedicinske tehnologije v kliničnih procesih.