Programski sustavi za podršku odlučivanju u medicini

Kolar, Matej

Master's thesis / Diplomski rad

2017

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:148538

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA

Sveučilišni studij Programskog Inženjerstva

PROGRAMSKI SUSTAVI ZA PODRŠKU ODLUČIVANJU U MEDICINI

Diplomski rad

Matej Kolar

Osijek, 2017.

Sadržaj

1. UVOD 1
1.1. Zadatak rada 1
2. SUSTAVI ZA PODRŠKU ODLUČIVANJU 2
2.1. Općenito o sustavima za podršku 2
2.2 Povijest 3
2.3 Taksonomije 5
2.4 Komponente 6
2.5 Razvojni okviri 8
2.6 Klasifikacija 8
2.7 Primjena 9
3. PROGRAMSKI SUSTAVI ZA PODRŠKU ODLUČIVANJU U MEDICINI 11
3.1. Definicija i funkcije sustava 11
3.2. Karakteristike sustava 12
3.3. Tipovi sustava 14
3.3.1. CDSS na temelju znanja (stručni sustavi) 15
3.3.2. CDSS koji se ne temelji na znanju 16
3.3.3. CDSS prilagodljiv dokazima 16
3.4. Arhitektura CDSS-a 19
3.4.1. Osnovni koncept DSS arhitekture 19
3.4.2. Četvero fazni model arhitekture kliničke podrške odlučivanju 21
3.5. Algoritam za kliničku podršku odlučivanju 22
3.5.1. Umjetna neuronska mreža 22
3.5.2. Bayesova mreža 23
3.6. Izazovi usvajanja CDSS-a 24
3.6.1. Klinički izazovi 24
3.6.2. Tehnički izazovi i prepreke za implementaciju 25
3.6.3. Održavanje 25
3.6.4. Procjena 26
3.7. Učinkovitost CDSS-a 26
4. PRIMJERI PROGRAMSKIH SUSTAVA ZA PODRŠKU ODLUČIVANJA U MEDICINI 28
4.1. Apgar sustav vrednovanja 28
4.2. DXplain 29
4.3. GRIP 32

4.4 Lexicomp 35
5. ZAKLJUČAK 37
6. LITERATURA 38
SAŽETAK 42
ABSTRACT 43
ŽIVOTOPIS 44

1. UVOD

Tema ovog diplomskog rada je objasniti što su to sustavi potpore odlučivanju, kada su nastali, gdje se primjenjuju, koja je njihova zadaća i koliki utjecaj i interakciju vrše svakodnevno kako bi pomogli donošenju odluka u svim područjima primjene.

U prvom dijelu se objašnjavaju osnovni pojmovi tih sustava, kratak pregled povijesnog razvoja, od čega se ti sustavi sastoje, kako se razvijaju i koje vrste sustava poznajemo. Što je zapravo glavna ideja i cilj tih sustava i kako se njima danas upravlja. Objašnjeno je i korištenje sustava u raznim područjima svakodnevnog života i njihov doprinos poboljšanju i napretku.

Drugi dio se bavi užom primjenom, a to je u medicini. Kako ih razlikujemo, karakteristike pojedinih vrsta i arhitektura i razvoj sustava u medicini od ranih početaka do modernih globalnih sustava. Objašnjene su prepreke i ograničenja sa kojima su se kroz povijest inžinjeri morali suočiti i opću prihvaćenost, kako od strane liječnika i medicinskog osoblja sve do pacijenata, i uvid kakav je danas odnos prema tim sustavima i koliko oni doprinose poboljšanju rada osoblja i stanju pacijenata.

Zadnji dio je vezan za pregled nekih od sustava koji se danas koriste. Zbog njihove kompleksnosti, tehničkih zahtjeva, ograničenosti pristupa i potrebnog medicinskog znanja kako bi se uspješno koristio sustav, nije bilo moguće testirati niti jedan pravi veliki sustav. Stoga, pažnja je usmjerena na njihovu izvedbu, namjenu i pojedine tehničke značajke. Obrađeno je i nekoliko manjih, mobilnih aplikacija koje su sve češće korištene i svrha im je pružanje informacija za djelovanje na manje tegobe i bolesti.

1.1. Zadatak rada

Objasniti pojam sustava za podršku odlučivanju. Navesti prednosti i nedostatke takvih sustava. Dati detaljan pregled programskih sustava za podršku odlučivanju u medicini kao i prijedlog mogućih alternativnih rješenja. Sumentor: Doc.dr.sc. Krešimir Šolić, dipl.inž.el., Medicinski fakultet Osijek.

2. SUSTAVI ZA PODRŠKU ODLUČIVANJU

U ovom poglavlju će biti objašnjena povijest, osnovna svrha i sastavni dijelovi sustava za podršku odlučivanju. Detaljniji uvid u što su zapravo ti sustavi i gdje se koriste, koja je njihova svrha u svakodnevnom životu i koliko uspješno se koriste.

2.1. Općenito o sustavima za podršku

Programski sustavi za podršku odlučivanju su računalni informacijski sustavi koji podržava organizacijske ili poslovne aktivnosti odlučivanja koje se temelji na rangiranju, sortiranju ili odabirom između alternativa. Ovi sustavi služe kao pomoć ljudima pri donošenju odluka o problemima čije se stanje može brzo mijenjati i koji se ne mogu lagano i precizno unaprijed definirati. Prema tome, programski sustavi za podršku odlučivanju mogu biti potpuno računalizirani, ljudski upravljani ili kombinacija jednog i drugog [1].

Postoji nekoliko različitih definicija i pogleda na programske sustave za podršku odlučivanju. Akademici ih smatraju alatom za podršku procesu donošenja odluka dok ih sami korisnici vide kao alat za olakšavanje organizacijskih procesa [2]. Neki su autori proširili definiciju programskih sustava za podršku odlučivanju na bilo koji sustav koji podržava donošenje odluka. Tu se posebice ističe Sprague[3] koji definira sustave za podršku odlučivanju kako slijedi:

1. Sustavi za podršku odlučivanju imaju tendeciju usmjeriti se na lošije strukturiran i nedostatan problem s kojim se obično suočavaju menadžeri na gornjoj razini
2. Sustavi za podršku odlučivanju pokušavaju kombinirati upotrebu modela ili analitičkih tehnika s tradicionalnim funkcijama pristupa i pronalaženja podataka
3. Sustavi za podršku odlučivanju se posebno usredotočuju na značajke koje olakšavaju upotrebu za osobe koje nisu sklone korištenju računala u interaktivnom načinu rada
4. Sustavi za podršku odlučivanju naglašavaju fleksibilnost i prilagodljivost promjenama u okolišu i pristupu donošenja odluka korisnika

Pravilno dizajniran sustav za podršku odlučivanju (engl. *Decision Support System*, skraćeno DSS) interaktivni je sustav temeljen na programskoj podršci koja je namijenjena za pomoć donositeljima odluka u prikupljanju korisnih informacija iz neobrađenih podataka, dokumenata i

osobnog znanja ili poslovnih modela u svrhu prepoznavanja i rješavanja problema te donošenja odluka.

Tipične informacije koje aplikacija za podršku odlučivanju može prikupiti i predstaviti uključuje:

- Popis informacijske imovine (uključujući naslijeđene i relacijske izvore podataka, kocke, skladišta podataka)
- Usporedne prodajne brojke između dva razdoblja
- Projicirane brojke prihoda na temelju pretpostavki o prodaji proizvoda

Iako postoje sustavi za podršku odlučivanju za različite faze strukturiranja i rješavanja problema odlučivanja, većina programskih podrški za donošenje odluka se ipak usredotočuje na odabir iz skupine alternativa karakteriziranih višestrukim kriterijima ili atributima.

Glavna zadaća programske podrške za donošenje odluka (engl. *Decision Making Software*, skraćeno DMS) bi trebala biti podržavanje analize uključene u procese donošenja odluke, a ne zamijeniti ga. „*Software za donošenje odluka treba koristiti kao potporu procesu, a ne kao pokretačku ili prevladavajuću silu, oslobađajući korisnike od pojedinosti tehničke implementacije omogućujući im da se usredotoče na prosudbe temeljne vrijednosti*.“ [4]

2.2 Povijest

Koncept potpore odlučivanju se uglavnom razvio od teorijskih proučavanja organizacijskog odlučivanja koje je provedeno na Tehnološkom institutu Carnegie tijekom kasnih 50-ih i tijekom 60-ih godina prošlog stoljeća, zatim je sredinom 70-ih postao posebno područje istraživanja prije nego je 80-ih dobio još veću pažnju uslijed koje su se razvili izvršni informacijski sustavi (engl. *Executive Information Systems*, skraćeno EIS), grupni sustavi podrške odlučivanju (engl. *Group Decision Support Systems*, skraćeno GDSS) i sustavi podrške organizacijskom odlučivanju (engl. *Organizational Decision Support Systems*, skraćeno ODSS) od jednog korisnika i modelno usmjerenog DSS-a.

Početni primjer DMS-a opisan je 1973. godine kada su prije pojave široko pojasne mreže (engl. *World Wide Web*) takvi sustavi bili bazirani na proračunskoj tablici. Sredinom 1990-ih se

pojavljuje prvi DMS na mreži, a danas je dostupno barem 20 DMS proizvoda koji su uglavnom temeljeni na njoj[1].

Prema Solu[5], definicija i opseg DSS-a migrira tijekom godina: početkom 1970-ih godina DSS je opisan kao „računalni sustav koji pomaže donošenju odluka“; krajem 1970-ih DSS pokret usredotočio se na sljedeću definiciju: „interaktivni računalni sustavi koji pomažu donositeljima odluka da koriste baze podataka i modele za rješavanje loše strukturiranih problema“; tijekom 1980-ih DSS je trebao osigurati sustave „koristeći odgovarajuće i dostupne tehnologije za poboljšanje učinkovitosti menadžerskih i profesionalnih aktivnosti“, a krajem 1980-ih DSS se suočio s novim izazovom za oblikovanje inteligentnih radnih stanica.

Značajna implementacija ovakvih sustava dogodila se 1987. godine kada je tvrtka Texas Instruments dovršila razvoj Sustava za dodjelu vrata (eng. *Gate Assignment Display System,* skraćeno GADS) za zrakoplovu kompaniju United Airlines. Zahvaljujući ovom sustavu značajno su smanjena putna kašnjenja tako što sustav pomaže u upravljanju kopnenim operacijama u različitim zračnim lukama, počevši od Međunarodne zračne luke O'Hare u Chicagu i zračne luke Stapleton u Denveru u Coloradu [6]. Početkom godine 1990. zahvaljujući skladištenju podataka i on-line analitičkoj obradi (engl. *On-Line Analytical Processing*, skraćeno OLAP) počelo je širenje područja DSS-a te su pri prijelazu tisućljeća uvedene nove web analitičke aplikacije.

Poboljšavanjem i pojavom novih tehnologija vidjelo se kako DSS postaje kritična stavka upravljanja dizajnom. Kao primjer se može uzeti u obzir intenzivna količina rasprave o DSS-u u obrazovnom okruženju.

DSS također ima kraću vezu s paradigmom korisničkog sučelja hiperteksta. Sustav PROMIS Sveučilišta u Vermontu (za medicinsko odlučivanje) i Carnegie Mellon ZOG/KMS sustav (za vojno i poslovno odlučivanje) bili su sustavi podrške odlučivanju, koji su također igrali veliku ulogu u istraživanju korisničkog sučelja. Nadalje, iako su hipertekstualni istraživači općenito bili zabrinuti zbog preopterećenja informacijama, neki istraživači, osobito Douglas Engelbart, bili su posebno usmjereni na donositelje odluka [1].

2.3 Taksonomije

Koristeći odnos s korisnikom kao kriterij, Haettenschwiller razlikuje pasivni, aktivni i kooperativni DSS. Pasivni DSS je sustav koji pomaže u procesu donošenja odluka, ali ne može donijeti jasan prijedlog ili rješenje odluke dok aktivni DSS to može. Kooperativni DSS omogućava iterativni proces između čovjeka i sustava u svrhu postizanja ujedinjenog rješenja: donositelj odluke (ili njegov savjetnik) može mijenjati, dovršiti ili preraditi prijedlog odluke koju je pružio sustav prije nego što ih pošalje natrag sustavu za validaciju, a isto tako se sustav ponovno poboljšava, dovršava i prerađuje prijedlog donositelja odluke i šalje ih natrag za provjeru valjanosti [1].

Još jednu taksonomiju za DSS prema načinu pomoći, stvorio je Daniel Power: on razlikuje DSS temeljen na komunikaciji, DSS temeljen na podacima, DSS temeljen na dokumentima, DSS temeljen na znanju i DSS temeljen na modelu [7].

- Komunikacijski DSS omogućava suradnju podržavajući više od jedne osobe za rad na zajedničkom zadatku (integrirani alati kao što su Google Docs ili Microsoft Groove)
- Podatkovni DSS (ili DSS temeljen na podacima) naglašava pristup i manipulaciju vremenskim nizom unutrašnjih podataka tvrtke, a ponekad i vanjskih podataka
- DSS upravljan dokumentom upravlja, prima i manipulira nestrukturiranim informacijama u različitim elektroničkim formatima
- DSS temeljen na znanju pruža specijalizirano stručno rješavanje problema koje se pohranjuje kao činjenica, pravilo, postupak ili slične strukture [7]
- DSS temeljen na modelu naglašava pristup i manipulaciju statističkim, financijskim, optimizacijskim ili simulacijskim modelom. Koristi podatke i parametre koje korisnici pružaju kako bi pomogli donositeljima odluka u analizi situacije. Nisu nužno podatkovno intenzivne, a primjer tome je Dicodess kao generator DSS-a temeljenog na modelu koji je otvorenog koda[8]

Korištenje opsega kao kriterija, Power razlikuje još i DSS na razini poduzeća i DSS za pojedinog korisnika. DSS na razini poduzeća je povezan s velikim skladištima podataka i njime se služe mnogi menadžeri u tvrtki dok je DSS za pojedinog korisnika manji sustav koji se pokreće na osobnom računalu pojedinog menadžera [1].

2.4 Komponente

Osim samih korisnika, najvažnije komponente DSS arhitekture su [1]:

1. Upravljanje podacima
2. Sustav programske podrške
3. Korisničko sučelje

Upravljanje podacima se sastoji od baze podataka i sustava za upravljanje bazom podataka. Informacije unutar sustava dolaze od jednog ili više od iduća tri izvora [9]:

- Organizacijske informacije: sve informacije dostupne unutar organizacije, organizacijske baze podataka i skladišta podataka. Često se neke određene informacije kopiraju u DSS kako bi se skratilo vrijeme pretrage kroz bazu podataka.
- Vanjske informacije: neke odluke zahtjevaju unos iz vanjskih izvora informacija kao što su različiti državni zakoni, internet i slično.
- Osobne informacije: dodavanje informacija na temelju vlastitog znanja i iskustava. Moguće je dizajnirati DSS tako da se osobne informacije unose kada je potrebno ili da se takve informacije pohranjuju u osobnoj bazi podataka kojoj DSS može pristupiti.

Sustav programske podrške se sastoji od različitih matematičkih i analitičkih modela koji se koriste za analiziranje složenih podataka koji pružaju tražene informacije. Model predviđa rezultat na temelju unesenih podataka ili različitih uvjeta ili otkriva kombinaciju uvjeta i ulaznih informacija koji su potrebni za izradu željenog izlaza. Sustav podrške odlučivanju može ugroziti različite modele gdje svaki model obavlja specifičnu funkciju. Prema tome, izbor modela koji trebaju biti uvršteni u sustav podrške ovisi o potrebama korisnika i svrsi DSS-a. Treba imati na umu da DSS sadrži unaprijed definirane modele (ili rutine) pomoću kojih se mogu graditi novi modeli za podršku određenoj vrsti odluka [10].

Neki od uobičajeno korištenih matematičkih i statističkih modela:

- Statistički modeli: sadrže širok raspon statističkih funkcija, kao što su srednja vrijednost, način rada, odstupanja itd. Ovi se modeli koriste za utvrđivanje odnosa između pojava događaja i različitih čimbenika koji se odnose na taj događaj. Može se, na primjer, odnositi na prodaju proizvoda na razlike u području, dohotku, sezoni ili nekim drugim čimbenicima. Osim statističkih funckija, sadrži i programsku podršku koja može analizirati niz podataka kako bi se projicirali budući ishodi.

- Modeli analize osjetljivosti: koriste se za pružanje odgovora na „što ako“ situacije koje se često pojavljuju u organizaciji. Tijekom analize, vrijednost jedne varijable se brzo mijenja zbog čega se promatraju promjene na drugim varijablama. Na primjer, na prodaju proizvoda utječu različiti čimbenici kao što su cijena, troškovi oglašavanja, broj prodanih primjeraka, troškovi proizvodnje itd. Korištenjem modela osjetljivosti, cijena proizvoda može se izmijenjivati kako bi se utvrdila osjetljivost različitih faktora i njihov utjecaj na prodaju. Za ovakve analize se obično koriste Excel Spreadsheet i Lotus 1-2-3.
- Modeli analize optimizacije: koriste se za postizanje optimalne vrijednosti za ciljanu varijablu u danim okolnostima. Naširoko se koristi za donošenje odluka vezanih za optimalno korištenje resursa u organizaciji. Tijekom analize optimizacije, vrijednosti za jednu ili više varijabli se uzastopno mijenjaju uzimajući u obzir specifična ograničenja, dok se ne pronađu najbolje vrijednosti za ciljanu varijablu. Primjer korištenja je pri određivanju najviše razine proizvodnje koja se može postići mijenjanjem radnih zadatka radnika, imajući na umu da su neki radnici kvalificirani i da se njihov zadatak ne može mijenjati. Tehnike linearnog programiranja i Solver alati u Microsoft Excelu se najviše koriste pri ovakvim analizama.
- Modeli predviđanja: koriste različite alate i tehnike predviđanja, uključujući regresijske modele, analizu vremenskih nizova, metode istraživanja tržišta i slične metode kako bi dobili uvid o budućnosti ili predvidjeli nešto unaprijed. Pružaju informacije koje pomažu u analizi poslovnih uvjeta i stvaranju budućih planova pa su samim time pogodni za predviđanje prodaje.
- Modeli osjetljivosti za analizu unatrag: poznata i kao analiza traženja ciljeva,tehnika je koja u tim modelima upravo suprotna tehnici primijenjenoj u modelima analize osjetljivosti. Umjesto uzastopnog mijenjanja vrijednosti varijable u svrhu praćenja promjena nad drugim varijablama, ova tehnika postavlja ciljanu vrijednost za varijablu i onda uzastopno mijenja druge varijable dok se ne postigne ciljana vrijednost. Za primjer se može uzeti povećanje razine proizvodnje za 40% pomoću analize osjetljivosti unatrag tako što se postavi ciljana vrijednost za proizvodnu razinu a zatim se rade potrebne promjene u drugim čimbenicima kao što su količina sirovine, strojeva, alata, osoblja i slično kako bi se postigla ciljana razina proizvodnje.

Korisničko sučelje omogućava komunikaciju sa DSS-om i korištenje znanja i sposobnosti korisnika sa mogućnostima obrade računala. Grafičko korisničko sučelje je jedina komponenta s

kojom korisnik ima direktan kontakt i kroz njega se vrši unos traženih informacija i parametara i prikazuje rezultate analize u različitim formama (tekst, tablica, dijagram) [9] [10].

2.5 Razvojni okviri

Slično kao i drugi sustavi, DSS sustavi zahtjevaju strukturirani pristup. To uključuje ljude, tehnologiju i razvojni pristup. Rani razvojni okvir DSS-a se sastoji od četiri faze:

- Inteligencija koja predstavlja traženje uvjeta koji zahtijevaju odluku
- Dizajn za razvijanje i analiza mogućih alternativnih postupaka rješenja
- Izbor jednog od ponuđenih rješenja
- Implementacija kao usvajanje odabranog načina djelovanja u situaciji odlučivanja

Razine tehnologije DSS-a (sklopovlja i programske podrške) mogu uključivati:

1. Stvarnu aplikaciju koju će korisnik koristiti. Odnosi se na dio koji omogućava korisniku da donosi odluke u određenom području problema i da reagira na taj problem.
2. Generator koji sadrži sklopovsko ili programsko okruženje koje omogućava programerima da lako razvijaju određene DSS aplikacije. Ova razina koristi alate za slučajeve ili sustave kao što su Crystal, Analytica i iThink.
3. Alate koji uključuju sklopovlje i programsku podršku niže razine, obično su to DSS generatori uključujući posebne jezike, biblioteke funkcija i povezivanje modula.

Iterativni razvojni pristup omogućuje da se DSS mijenja i redizajnira u različitim intervalima. Nakon što je sustav dizajniran, mora se testirati i pregledati gdje je potrebno kako bi se dobio traženi rezultat [1].

2.6 Klasifikacija

Postoji nekoliko načina klasifikacije DSS aplikacija, ali ne uklapaju se sve aplikacije uredno u jednu od kategorija nego su to često kombinacije dvije ili više arhitektura. Holsapple i Whinston dijele DSS u sljedećih šest okvira: tekstualno orijentirani DSS, DSS orijentirani prema

proračunskoj tablici, DSS usmjereni prema rješavačima, DSS usmjereni prema pravilu i spoj DSS. Od svih navedenih, najpopularnija klasifikacija je spoj DSS koja je hibridni sustav koji uključuje dvije ili više od ukupnih pet temeljnih struktura[1].

Podrška koju daje DSS može se izdvojiti u tri različite, ali međusobno povezane kategorije: osobna podrška, grupna podrška i organizacijska podrška[11].

DSS komponente se mogu klasificirati kao:

1. Ulazi: čimbenici, brojevi i karakteristike za analizu
2. Korisničko znanje i stručnost: ulazi koji zahtijevaju ručnu analizu od strane korisnika
3. Izlazi: transformirani podaci iz kojih se generiraju DSS odluke
4. Odluke: rezultati koje generira DSS na temelju korisničkih kriterija

DSS-ovi koji obavljaju određene funkcije spoznajnih odlučivanja i koje su temeljene na umjetnoj inteligenciji ili inteligentnim izvršiteljima se nazivaju Inteligentni sustavi podrške odlučivanju (engl. *Intelligent Decision Support Systems*, skraćeno IDSS)[12].

Početno polje inženjerstva odlučivanja odluku razmatra kao projektirani objekt i primjenjuje inženjerska načela kao što su dizajn i osiguranje kvalitete na određeno predstavljanje elemenata koji čine odluku.

2.7 Primjena

Teoretski, DSS se može ugraditi u bilo koju domenu znanja. Jedan od primjera, koji je ujedno i tema ovoga rada, je primjena u polju medicine kao sustav kliničke podrške za medicinsku dijagnozu. Postoje četiri faze u razvoju sustava kliničke podrške (engl. *Clinical Decision Support System*, skraćeno CDSS): primitivna verzija koja je samostalna i ne podržava integraciju; druga generacija koja podržava integraciju s drugim mediciniskim sustavima; treći je standardno zasnovan, a četvrti je temeljen na uslugama [1].

DSS se opsežno koristi i u poslovanju i menadžmentu. Izvršna nadzorna ploča i druge programske podrške za performanse poslovanja omogućuju brže donošenje odluka, prepoznavanje negativnih trendova i bolju raspodjelu poslovnih resursa. Zbog DSS-a sve su informacije iz bilo koje organizacije prikazane u obliku grafikona,tablica i sličnim sažetim prikazima što pomaže menadžmentu pri donošenju strateških odluka. Kao primjer se može uzeti

bankarevo odobravanje zajma podnositelju zahtjeva ili inženjerskoj tvrtki koja ima ponude na nekoliko projekata i želi znati mogu li biti konkurentni svojim troškovima.

Rastuće područje korištenja DSS aplikacija, koncepata, načela i tehnika se odvija u poljoprivrednoj proizvodnji, to jest, u marketingu za održivi razvoj. Na primjer, paket DSSAT4 [13] se razvio financijskom podrškom USAID-a tijekom 80-ih i 90-ih omogućujući brzu procjenu nekoliko poljoprivrednih proizvodnih sustava širom svijeta kako bi se olakšalo donošenje odluka na farmama i razinama politike. Postoje, međutim, mnoga ograničenja za uspješno usvajanje DSS-a u poljoprivredi [14].

DSS također prevladava u upravljanju šumama gdje dugo planiranje smjera i prostornih dimenzija planiranja problema zahtijevaju specifične zahtjeve. Svi aspekti upravljanja šumama, od transporta cjepanica, rasporeda sječe i zaštite ekosustava su obrađeni u modernom DSS-u. Tu se često javljaju problem kao što su razmatranje pojedinačnih ili višestrukih ciljeva upravljanja vezano uz pružanje dobara i usluga kojima se trguje ili ne trguje i koje su često podložne ograničenjima resursa i problemima odlučivanja. Zbog toga, zajednica prakse sustava za podršku odlučivanju o šumama pruža veliku količinu znanja o izgradnji i korištenju DSS-a za šume [1][15].

Posebni primjer se odnosi na kanadski nacionalni sustav željeznica, koji redovito provjerava opremu koristeći sustav podrške odlučivanju. Problem s kojim se suočava željeznička pruga su istrošene ili neispravne tračnice što može rezultirati stotinama ispadanja vlaka iz tračnica godišnje. Prema DSS-u, kanadski nacionalni željeznički sustav uspio je smanjiti učestalost isklizavanja dok su istovremeno druge kompanije doživjele povećanje takvih nezgoda [1].

3. PROGRAMSKI SUSTAVI ZA PODRŠKU ODLUČIVANJU U MEDICINI

Tema ovog dijela rada je detaljnije objasniti sustave podrške odlučivanju koji se primjenjuju u medicini, s kojim su se preprekama susreli tijekom implementacije i koje su bitne karakteristike tih sustava zbog kojih ih dijelimo na više vrsta. Objašnjene su strukture, principi rada i poteškoće prihvaćanja sustava kroz godine unaprijeđivanja i njihova trenutna učinkovitost u gotovo svakoj grani medicine.

3.1. Definicija i funkcije sustava

Klinički sustavi podrške odlučivanju (engl. *Clinical Decision Support Systems*, skraćeno CDSS) je sustav zdravstvene informacijske tehnologije koji je osmišljen kako bi liječnicma i drugim zdravstvenim djelatnicima pružio podršku kliničkim odlukama [16]. CDSS je izvedba sustava za podršku odlučivanju koji se obično koristi za podršku poslovnom upravljanju [17].

Liječnici, medicinske sestre i drugi zdravstveni djelatnici koriste CDSS kako bi pripremili i pregledali dijagnozu kao sredstvo za poboljšanje konačnog rezultata. Također se može provesti "rudarenje" podataka u svrhu pregleda medicinske povijesti pacijenta u kombinaciji s relevantnim kliničkim istraživanjima kako bi se dosegnula dijagnoza na temelju pacijentovih podataka. Takva analiza može pomoći pri predviđanju potencijalnih događaja, koji se mogu razlikovati od interakcije pojedinih lijekova do simptoma bolesti[17].

U prvim inačicama CDSS-a, CDSS je bio zamišljen za doslovno donošenje odluka umjesto medicinskog osoblja. Kliničar ili netko iz medicinskog osoblja bi unio informacije i čekao da CDSS izda "pravi" izbor kojeg će osoblje prihvatiti i djelovati na taj rezultat. Takav način rada je odbačen zbog pogrešaka koje se mogu dogoditi i ugroziti pacijenta, kao što su greške u računalnom programu zbog koje se može donijeti kriva ili nepotpuna odluka, zanemarivanje znanja i iskustva medicinskog djelatnika i mnoge druge.

U sadašnje vrijeme, medicinsko osoblje može unijeti podatke u sustav i pričekati da CDSS odluči svoj izbor kako bi osoblju savjetovao ispravnu odluku. Prolazeći kroz računalnu analizu, medicinsko osoblje ne samo da donosi odluke kroz vlastito znanje i iskustvo koje se možda neće u potpunosti suglasiti sa danim rezultatom, ali dobiva i savjete od računala kako bi se poboljšala kvaliteta odlučivanja. Drugim riječima, CDSS služi osoblju kao periferni mozak.

Ovakvim se načinom rada postiže suradnja računalne analize i precizne obrade podataka i stručnog mišljenja medicinskog osoblja koje zapravo donosi odluku [18].

Postoje četiri osnovne funkcije sadržane unutar svakog CDSS-a [18]:

1. Administrativne: sustav mora biti administrabilan što znači da mora biti u mogućnosti podržavati kliničko kodiranje i dokumentaciju te postupke i preporuke medicinskog centra. Kako bi se to postiglo, CDSS se uvijek stvara kroz više platformi i vrlo dobro razumije svaki medicinski standardni postupak.
2. Mora biti u stanju upravljati kliničkom složenosti i detaljima. To znači da sustav drži pacijente na istraživačkim i kemoterapijskim protokolima, kao što je to medicinsko osoblje uvijek činilo. Prati naloge pacijenata, preporučuje status praćenja pacijenta i preventivnu njegu nakon propisanog recepta.
3. Kontroliranje troška koje se odnosi na trošak koji se može kontrolirati izbjegavanjem dupliciranja procesa, dokumenta ili bilo kojeg nepotrebnog laboratorijskog testa i praćenje naloga za lijekove kako bi se potvrdilo koja su pogrešna mjesta narudžbe koja bi mogla predstavljati izravnu štetu financijama određenog medicinskog centra.
4. Podrška odlučivanju što predstavlja podržavanje kliničke dijagnoze i procesa planova liječenja te poticanje primjene najboljih praksi, smjernice za specifična stanja pacijenta i upravljanje stanovništvom.

3.2. Karakteristike sustava

Sustavi kliničke podrške definirani su kao “aktivni sustavi znanja koji koriste dvije ili više stavki iz pacijentove baze podataka kako bi generirali savjete specifične za pojedine slučajeve” [19]. To podrazumijeva da je CDSS jednostavno sustav podrške odlučivanju koji je usmjeren na upravljanje znanjem na takav način kako bi se postigli klinički savjeti za skrb o pacijentima na temelju više stavki podataka pacijenata [16].

Postoje obično četiri osnovne komponente koje su potrebne za CDSS [18]:

1. Sustav zaključivanja koji je ujedno i glavni dio CDSS-a. Koristi znanje iz baze podataka koja je integrirana u sustav, kao i znanje o pacijentu kako bi generirao izlaz ili zaključak na temelju određenog stanja. Kontrolira djelovanje sustava i vodi sustav koristeći najbolje postupke. Na primjer, počinje otkrivati stanje za

pokretanje upozorenja ili zaključka koji će se pokazati pri dijagnostičkom napretku.

2. Baza znanja koja stječe znanje koje je sustav zaključivanja predstavljao korisnicima. U njoj su sadržani svi čimbenici rizika koji se mogu pojaviti u novim ozlijedama i rizičnim situacijama. Izgrađuje se uz sudjelovanje i pomoć stručnjaka u domeni klinike uz svaku aktivnost stvaranja, uređivanja i održavanja. No neke baze znanja nastaju i putem automatiziranog procesa. Automatizirano procesno znanje stječe se iz vanjskih izvora kao što su knjige, časopisi, razni članci i baza podataka računalne aplikacije. Proces stvaranje baze znanja je vrlo složen, a da bi se olakšao, postoje posebno napravljeni alati koji olakšavaju stjecanje i dobivanje baze znanja.
3. Radna memorija koja je zbirka podataka pacijenta ili oblika poruke koja je pohranjena unutar baze podataka. Ti podaci mogu uključivati starost pacijenta, ime, podatke o rođenju, spol, detalje o alergijama, povijest medicinskih informacija ili problema i druge informacije.
4. Modul za objašnjenje čija je zadaća sastavljanje opravdanja za zaključke koje donosi sustav zaključivanja primjenom baze znanja i podataka o pacijentu. Ova komponenta nije nužno prisutna u svim CDSS-ovima.

CDSS također može raditi u sinkroniziranom i asinkronom načinu rada. U sinkroniziranom načinu rada, korisnici mogu izravno komunicirati s aplikacijom i čekati rezultat iz sustava prije nego što mogu dalje nastaviti s radom. Na primjer, CDSS provjerava interakciju lijekova ili bilo koji mogući lijek na koji je pacijent alergičan da bi zatim kliničar mogao nastaviti dijagnosticirati pacijenta temeljem rezultata generiranog CDSS-om. Kada je u asinkronom načinu rada, CDSS se izvodi samostalno i ne zahtijeva od korisnika da pričeka. Na primjer, moguće je generirati podsjetnik za pregled pacijenta.

CDSS možemo raspodjeliti i kao sustave otvorene petlje ili zatvorene petlje. CDSS otvorene petlje će generirati zaključak, ali neće svojevoljno poduzet nikakvu radnju. Obično korisnici poduzimaju radnje na konačnoj odluci. Na primjer, CDSS generira upozorenje ili podsjetnik korisnicima da poduzmu traženu radnju. Suprotno od toga, CDSS zatvorene petlje poduzima vlastite radnje bez intervencije korisnika. Na primjer, sustav automatski sprema sve pojedinosti o postupku dijagnoze.

Još jedna primjena CDSS-a može biti i kao monitor događaja, sustav savjetovanja ili klinička smjernica. Monitor događaja je aplikacija programske podrške koja pretvara sve dostupne podatke u elektronički format i koristi svoju ugrađenu bazu znanja kako bi se prikladno poslao podsjetnik kliničarima. Sustav savjetovanja omogućuje korisniku unos podataka o slučaju, a zatim sustav korisniku pruža popis problema koji mogu objasniti odabrani slučaj i prijedlog najbolje radnje koju treba poduzeti. Inačicu kliničke smjernice je razvila grupa kliničkih stručnjaka, koju je distribuirala vlada ili profesionalna organizacija,a primjenjuje se u većini CDSS-ova. Radi na način da za tražene uvjete kao rezultat daje najbolji smjer akcije i prakse koje treba poduzeti za određeno zdravstveno stanje. Osim pružanja preporuka iz različitih praksi, može se uzeti kao primjer u medicinskom obrazovanju [18].

3.3. Tipovi sustava

Primjer kako liječnik ili medicinsko osoblje mogu upotrijebiti CDSS ovisi o vrsti CDSS-a, kao na primjer, sustav za potporu dijagnosticiranju odluka (engl. *Diagnosis Decision Support System*, skraćeno DDSS). DDSS zahtijeva neke podatke pacijenta i kao odgovor, predlaže skup odgovarajućih dijagnoza. Liječnik zatim uzima te rezultate i određuje koje bi dijagnoze mogle biti relevantne, a koje ne [20], i po potrebi naručuje daljnje testove za dobivanje preciznije dijagnoze.

Još jedan primjer CDSS-a bi bio sustav događajem-baziranog rasuđivanja (engl. *Case-Based Reasoning*, skraćeno CBR) [21]. Primjer CBR sustava je korištenje podataka prethodnog slučaja kako bi pomogao odrediti odgovarajuću količinu zraka i optimalne kutove snopova zraka u radioterapiji za pacijente s rakom mozga; medicinski fizičari i onkolozi bi tada pregledali preporučeni plan liječenja kako bi utvrdili njegovu održivost [22].

Druga važna klasifikacija CDSS-a temelji se na vremenu njegove uporabe. Doktori koriste ove sustave na mjestu skrbi kako bi im pomogli pri bavljenju pacijentima, s tim da je vrijeme korištenja bilo pred-dijagnoza, tijekom dijagnoze ili nakon dijagnoze. CDSS za pred-dijagnozu se koriste kako bi pomogli liječniku pripremiti dijagnozu. Sustavi koji se koriste tijekom dijagnoze pomažu pregledati i filtrirati početne dijagnostičke izbore liječnika kako bi poboljšali svoje konačne rezultate. Sustavi za nakon dijagnoze se koriste u rudarenju podataka kako bi se dobila veza između pacijenta i njihove prošle medicinske povijesti i kliničkih istraživanja za predviđanje budućih događaja [20].

Drugačiji pristup, koji koristi Nacionalna zdravstvena služba u Engleskoj, je korištenje DDSS-a (kojeg je u prošlosti koristio pacijent ili danas, operater telefona koji nije medicinski osposobljen) za utvrđivanje stupnja opasnosti medicinskog stanja nakon radnog vremena liječnika ili regularne ambulante, predlažući odgovarajući slijedeći korak pacijentu (na primjer, nazovite hitnu pomoć ili posjetite liječnika opće prakse slijedećeg radnog dana). Prijedlog koji bi pacijent ili telefonski operater mogao zanemariti ako zdrav razum ili opreznost sugeriraju drugačije, temelji se na poznatim podacima i implicitnom zaključku o tome koja je najvjerojatnija dijagnoza najgorih slučajeva (koja se ne otkriva uvijek pacijentu, jer bi mogla biti netočna i ne temelji se na mišljenju medicinski osposobljenih osoba – koristi se samo za početno procijenjivanje) [16].

CDSS može imati puno različitih namjena, ali sve sustave možemo raspodijeliti na dvije glavne vrste:

3.3.1. CDSS na temelju znanja (stručni sustavi)

Nastaju tako da stručnjaci koriste biomedicinsku literaturu kako bi identificirali odnose između nezavisnih varijabli (poput znakova i simptoma) i ovisnih varijabli (kao što su vjerojatne temeljne bolesti). Sadrži povezane uređene informacije lokalne bolnice, podatke o pacijentima i druge prikupljene podatke te ih primjenjuju s unaprijed definiranim pravilima IF-ELSE-THEN kako bi se vodili kroz cijeli napredak donošenja odluka. Međutim, pravila se mogu dobiti iz različitih stabala odluke. Ovi CDSS-ovi temeljeni na pravilima se najčešće nalaze među svim kliničkim primjenama. Upozoriti će korisnika sustava kada postoji moguća doza lijeka ili je prisutna alergija koja može naštetiti ili ugroziti život pacijenta temeljem detalja pacijenta, kao što su dob, spol, težina, visina i slično.

Na primjer, ako se sustavna pravila koriste za određivanje interakcije lijekova, formula će početi raditi i otkriti svaku moguću rizičnu interakciju lijekova. Pravila bi se mogla odvijati ako je lijek A uzet i lijek B je uzet onda upozori korisnika. Prolazeći tim unaprijed definiranim pravilima, informacije moraju uvijek biti ažurirane kako bi se spriječilo pogrešno računanje izlazne informacije iz sustava koje bi moglo dovesti do pogrešne dijagnoze.

Da bi se izgradio sustav koji se temelji na pravilima za pružanje medicinske odluke, uvijek se mora unajmiti stručnjak s poznavanjem domena kako bi stvorio i obradio bazu znanja i osposobio sustav. Osposobljavanje stručnog sustava vrlo je dugotrajno i rezultat koji se

proizvodi iskoristiv je samo u uskom okviru projekta. Zbog toga, CDSS-ovi koji se temelje na pravilima obično se ne koriste za isporuku kritične poruke kliničaru [18].

3.3.2. CDSS koji se ne temelji na znanju

Ovi sustavi ne primjenjuju nikakve podatke iz baze znanja, ali koriste drugu vrstu umjetnog znanja naziva strojno učenje (engl. *Machine Learning*). Pojam strojno učenje znači da će stroj naučiti iz prošlih iskustava i prethodne lekcije koju daju stručnjaci. Ova ideja je temelj u ovoj vrsti CDSS-a. Računalo će sve naučiti u prethodnom medicinskom napretku i pronaći uzorak u kliničkim podacima. CDSS koji nije baziran na znanju je osposobljen za odnos između simptoma i znakova (nezavisnih varijabli) i bolesti (zavisne varijable). Strojno učenje upotrebljava se na temelju slučajeva kako bi nastavila svaku lekciju jer sustav trenira iz prethodnih slučajeva.

Unutar ovakvih sustava možemo napraviti još jednu podijelu na dvije vrste: umjetne neuronske mreže i genetički algoritmi. Sadrže neke matematičke modele koji mogu promatrati i oponašati svojstva stavke i neku vrstu prilagodljivog učenja simuliranja osobine stavke. Umjetne neuronske mreže mogu analizirati atribute ili uzorke iz podataka pacijenta kako bi se dobile poveznice između simptoma i dijagnoze. Može obavljati nadzirano ili ne nadzirano strojno učenje, ovisno o načinu pružanja dostupnih informacija. Genetički algoritam temelji se na nekoliko procesa pretraživanja i pojednostavljivanja i koristi usmjereni odabir kako bi postigao optimalan rezultat. Algoritam prvo određuje svojstva skupa rješenja za neki problem. Svako rješenje koje se generiralo će se ponovno spajati, mijenjati i ponoviti postupak. Rotacija pronalaženja rješenja se zaustavlja tek kada se pronađe odgovarajuće rješenje. Znanje koje se koristi za pronalaženje rješenja izvedeno je iz podataka o pacijentu. Obično se usredotočuje na one bolesti koje su uzrokovane uskim popisom simptoma [18].

3.3.3. CDSS prilagodljiv dokazima

Engleskog naziva *evidence-adaptive CDSS,* ovo je podklasa CDSS-ova čija se baza znanja CDSS-a izvodi i neprekidno nadopunjava s najnovijim dokazima iz istraživanja i izvora temeljenih na praksi. Na primjer, CDSS za liječenje raka prilagodljiv je dokazima ako se njegova baza znanja temelji na trenutačnim dokazima i ako se njegove preporuke rutinski ažuriraju kako

bi uključile nove rezultate istraživanja. S druge strane, CDSS koji upozorava kliničare na poznatu interakciju lijekova temelji se na dokazima (engl. *evidence-based*), ali nije prilagodljiva dokazima (engl. *evidence-adaptive*) ako je njihova baza znanja izvedena iz znanstvenih dokaza, ali ne postoje mehanizmi za uključivanje novih dokaza.

CDSS je učinkovit onoliko koliko su kvalitetna istraživanja, dokazi i znanje na kojima se temelji. Ako postoje nedostatci u kvaliteti ili relevantnosti istraživačkih dokaza to će se negativno odraziti na korisnost i učinkovitost samog sustava. Upravo je zbog toga jedan od ključnih koraka u razvoju učinkovitijih CDSS-ova nije samo stvaranje više kliničkih istraživanja i dokaza, nego i više kvalitetnih, korisnih i djelotvornijih dokaza koji se neprestano ažuriraju, lako su dostupni i mogu se računalno interpretirati [23].

Ovu podklasu CDSS-ova možemo podijeliti na tri skupine, ovisno koji su izvori dokaza na kojima se ta podskupina temelji.

3.3.3.1. Dokazi temeljeni na literaturi

Postoje problemi s korištenjem literature iz različitih istraživanja za medicinu temeljenu na dokazima. Istraživanja djelotvornosti kliničke prakse koje čine osnovu za medicinu temeljenu na dokazima čini samo mali dio ukupne istraživačke literature (na primjer, samo otprilike pola intervencija unutar i izvan bolnice pri njezi pacijenata su sadržane u literature s dokazima o djelotvornosti dok druga polovica nije ni proučavana ili nema pouzdane dokaze). Problemi sa literaturom kliničkih istraživanja postoje već desetljećima zbog problema sa slanjem i obradom izvještaja i još su uvijek prisutni pa ne čudi što većina kliničara takvu literaturu smatra nepotpunom i ograničenom za primjenjivost pri vlastitoj kliničkoj praksi [23].

CDSS-ovi za olakšavanje rada medicine temeljene na dokazima će u potpunosti zaživjeti tek kada budu mogli držati korak sa literaturom – to jest, kada CDSS-ovi prilagodljivi dokazima budu mogli pratiti literaturu za nova relevantna istraživanja, prepoznati one visoke kvalitete, a zatim ugraditi najbolje dokaze u procjenu određenih pacijenata ili preporuku praksi. Automatizacija tih zadataka je još uvijek otvoreno polje istraživanja, a u međuvremenu postoje alternativni izvori informacija koji pružaju najnovije i najkvalitetnije informacije koji čine čvrsti temelj za praksu temeljenu na dokazima, ali im je mana što su u tekstualnom obliku pa samim time nisu pogodni za korištenje u sadašnjim CDSS-ovima koji ih ne mogu interpretirati.

Kada bi istraživačka literatura bila dostupna kao zajednička baza znanja koju računalo može interpretirati, onda bi CDSS-ovi imali izravan pristup najnovijim istraživanjima i automatski bi se ažurirala baza znanja. Kao prvi korak pri ostvarivanju tog cilja, project “The Trial Bank” [24], koji je rezultat suradnje “Annals of Internal Medicine” i JAMA-e koji uzimaju dizajn i rezultat nasumičnih ispitivanja i bilježe u strukturirane baze znanja kao resurs koji računalo lako može čitati i interpretirati.

3.3.3.2. Dokazi temeljeni na praksi

Iako istraživačka literatura služi kao temelj za praksu temeljenu na dokazima, nije neuobičajeno da su lokalni dokazi temeljeni na praksi potrebni za optimizaciju zdravstvenih ishoda. Na primjer, ispitivanja su pokazala da bolesnici sa simptomskom stenozom karotidne arterije imaju manje udara ako dobiju operaciju nazvanu karotidna endarterektomija [25]. Ako su šanse za komplikaciju nakon operacije veće od otprilike 6%, tada se pozitivni rezultati operacije poništavaju. Za kliničke probleme s lokalno promijenjivim parametrima, razvojni inženjeri CDSS-a trebali bi staviti visoki prioritet za dobivanje lokalnih dokaza temeljenih na praksi koji bi nadopunjavali dokaze temeljene na literaturi [23].

Još jedan od primjena dokaza temeljenih na praksi je njihova uloga u izradi smjernica za praktične radove. Iako dokazna potpora za pojedinačne korake u smjernicama primarno dolazi iz dokaza temeljenih na literaturi, proces tijeka smjernice obično se konstruira na temelju stručnog mišljenja liječnika. S više informacija temeljenih na praksi vezanih za kliničke procese i događaje, razvojni inženjeri mogli bi poboljšati način izrade procesnih tokova.

Koliko god korisni dokazi temeljeni na praksi mogu biti, često nije lako doći do njih. Kako bi se poboljšalo prikupljanje podataka i svih događaja tijekom praktičnog rada, informatička zajednica može potaknuti novo potrebno istraživanje razvijanjem informacijskih tehnologija za istraživačke mreže temeljene na praksi kako bi automatski snimala kliničke procese i događaje [23].

3.3.3.3. Dokazi usmjereni na pacijenta

Primarno internet, ali i drugi izvori informacija i istraživanja omogućili su pacijentima puno veći izbor pri dobivanju informacija, ali su i povećali šanse da pacijent pogrešno protumači tražene rezultate. Kao rezultat, pacijenti su manje ovisni o kliničarima, ali još uvijek traže pomoć pri odabiru, ocjenjivanju i primjeni zdravstvenih informacija i odluka do kojih su došli koristeći se vlastitim navođenjem i istraživanjem literature. CDSS može podržati ovu sve veću angažiranost pacijenata u kliničkom odlučivanju putem interaktivnih alata koji omogućuju pacijentu da istraži relevantne i bitne informacije koje mogu poticati zajedničko donošenje odluka. Sustavi koji pružaju pacijentima i kliničarima valjane, primjenjive i korisne informacije mogu rezultirati odlukama o skrbi koje su usklađenije s trenutnim preporukama, bolje se prilagođavaju pojedinačnim pacijentima i naposljetku su povezane s poboljšanim kliničkim ishodima [23].

3.4. Arhitektura CDSS-a

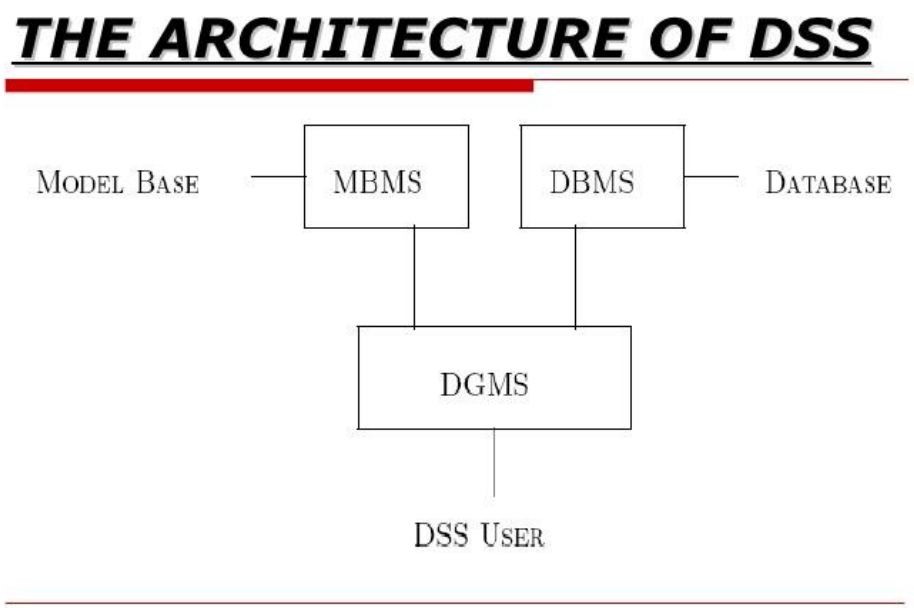
Arhitektura sustava ovisi o njegovoj namjeni, ali svakoj vrsti je zajedničko da se sastoje od dva dijela: računalni model sustava i ljudski faktor. U medicini se ne prakticiraju sustavi bez ljudskog nadzora i upravljanja pa se razlike u arhitekturi svode na razlike u karakteristikama računalnog modela i njegovog načina rada.

3.4.1. Osnovni koncept DSS arhitekture

Budući da je CDSS svojevrsni sustav podrške odlučivanju koji je dizajniran da pomaže kliničaru i medicinskom osoblju u donošenju odluka, dizajn arhitekture sustava podrške odlučivanju uvijek se sastoji od dva glavna podsustava: ljudski donositelj odluka i računalni sustav. Izgraditi sustav podrške odlučivanju samo računalnim sklopovljem i programskom podrškom nije ispravan koncept jer postoji neka nestrukturirana ili polustrukturirana odluka (one se ne mogu odlučiti kroz zbirku matematičkog modela ili formule) i nije moguće da ju sustav programira jer se radi o prirodi razmišljanja čovjeka koja je nedostižna i složena. Ne postoji takva neovisna komponenta niti u jednom sustavu podrške odlučivanju. Oduvijek je potreban ljudski donositelj odluka kao komponenta sustava podrške odlučivanju za integraciju s računalnim sustavima. Funkcija ljudskog donošenja odluke nije izgradnja baze podataka za

sustav, umjesto toga, funkcionira kao donositelj odluka koji donosi prosudbu, podijeli svoja iskustva i vježba intuiciju tijekom čitavog procesa odlučivanja [18].

Prvi korak donošenja odluka započinje stvaranjem modela podrške odlučivanju (formula ili način na koji korisnik pomaže filtrirati ili odlučiti o određenom rezultatu) pomoću nekog integriranog DSS programa (npr. Microsoft Excel). Sustav komunicira s bazom podataka putem sustava za upravljanje bazama podataka (engl. *Database Management Systems*, skraćeno DBMS) i obrađuje podatke iz te baze s modelom podrške odlučivanju putem sustava upravljanja temeljem modela (engl. *Model-Based Management System*, skraćeno MBMS). DBMS je aplikacija koja se koristi za stvaranje, upravljanje i kontrolu pristupa bazi podataka, dok je MBMS aplikacija koja je ugrađena unutar DSS programa koja omogućuje stvaranje, uređivanje i brisanje modela podrške odlučivanju. Korištenjem DBMS i MBMS, model se može povezati s podacima iz baze podataka kako bi donio odluku [18].



Sl. 3.1. – *Dijagram DSS sustava sa integriranim DBMS i MBMS (izvor: https://image.slidesharecdn.com/decisionsupportsystem-090902132533-phpapp01/95/decision-support-system-8-728.jpg?cb=1251898104)*

3.4.2. Četvero fazni model arhitekture kliničke podrške odlučivanju

Četvero fazni model arhitekture odnosi se na četiri tipa arhitekture koja je korištena u razvoju CDSS-a: samostalan sustav podrške odlučivanju, ugrađeni sustav, sustav temeljen na standardima i modeli usluga. Te arhitekture također predstavljaju evolucijski sustav kliničke podrške odlučivanju. Faze se događaju sekvencijalno, svaka se faza nauči i ima utjecaj iz prethodnih faza [18].

Prva faza je samostalni sustav podrške odlučivanju koji je nastao 1959. godine. Ovi sustavi djeluju odvojeno od kliničkog sustava. Kliničar je morao s namjerom tražiti sustav i unijeti podatke o njegovim medicinskim slučajevima, a zatim pričekati da sustav protumači rezultat. Ovakvu vrstu sustava je lako razviti ako korisnik ima medicinsko i računalno znanje. Zbog jednostavnog razvoja je lagano i dijeljenje sustava pa se zbog toga može smatrati i kao jednostavan sustav kojeg korisnik može kopirati, a zatim poslati drugom korisniku koji ga također želi koristiti. Zbog jednostavnosti postoje i ograničenja kao što je potreba da korisnik unese sve potrebne informacije u sustav kako bi ga zaključio. Potrebno je i znanje kako sustav funkcionira i obavljanje rada na njemu tako da korisnici koji nemaju dovoljno medicinskog znanja mogu imati poteškoća pri upotrebi sustava što može uzrokovati mnoge medicinske pogreške. Također, sustavi ne mogu biti proaktivni i vremenski su dugotrajni, može potrajati od pola do jednog sata za ulazak u slučaj jer je značajka modela vrlo uska i zahtijevali su puno informacija kako bi se generirao rezultat [18].

Zbog značajnih problema sa samostalnim CDSS-om, programeri su počeli uključivati poznatu arhitekturu u integrirani sustav, čiji je rezultat riješio mnoge probleme. Prvi od njih je bilo uklanjanje višestrukog unosa korisnika, podaci su se pohranjivali elektronički nakon prvog unosa korisnika. Uz to, sustav je mogao biti proaktivan. Mogao je automatski upozoriti korisnika kada otkrije opasnost između interakcije lijekova ili pogreške doziranja. Najveći nedostatak ovakvog sustava su bile poteškoće s dijeljenjem jer su sustavi bili vrlo složeni jer su izravno građeni s velikim kliničkim sustavom. Zbog toga nije bilo moguće direktno dijeljenje s drugima koji ne koriste isti klinički sustav za razliku od samostalnog sustava koji je izgrađen samo na osnovu vlastitog znanja i računalnih vještina. Drugi veliki problem je bio problem upravljanja znanjem. Kada je trebalo ažurirati za znanje ili smjernicu, nekada je trebalo pronaći izvorni kod da bi se znalo gdje se koristi smjernica [18].

Kako bi se sadržaj mogao dijeliti, bilo je potrebno poduzeti nekoliko istraživanja radi standardizacije sadržaja podrške za kliničku odluku. Zahvaljujući standardizaciji, otklonjeni su mnogi nedostatci integriranog sustava. Sadržaj podrške za kliničku odluku se dijeli odvajanjem koda koji opisuje sadržaj od izvornog koda. Međutim, još uvijek postoje ograničenja. Postoji previše standardnih formata za odabir (na primjer, preko stotinu standarda koji predstavljaju jednostavnu obavijest). Standardizirano kodiranje može ograničiti korisnički standard. "Standard" koji je korisnik namjeravao pisati jer ima poteškoća u kompatibilnosti s "standardiziranim standardom" [18].

Modeli usluga su najnovija CDSS arhitektura. Ponovno su spojeni klinički informacijski sustavi i komponente CDSS-a koristeći standardno sučelje programskog programiranja (engl. *Application Programming Interface*, skraćeno API). Ovaj model je standardizirao i sustav kliničke podrške odlučivanja i klinički sustav u jedno sučelje. Oba sustava gledaju na samo jedan klinički sustav i jedan CDSS u isto vrijeme, iako su znanje o pacijentu i medicine na mnogim mjestima [18].

3.5. Algoritam za kliničku podršku odlučivanju

Razlikujemo više algoritama koji se koriste u CDSS-ovima, biraju se ovisno o funkciji koju sustav treba obavljati i definiraju pravac kojim će sustav "razmišljati" na putu do rješenja. Svaki od algoritama ima i svoje podvrste i komponente koji pomažu preciznijoj izgradnji puta do traženog odgovora. Dvije velike podjele su:

3.5.1. Umjetna neuronska mreža

Umjetna neuronska mreža je metoda koju koristi CDSS koji nije temeljen na znanju. Zahtijeva treniranje od strane stručnjaka u obliku umjetne inteligencije, temelji se na prošlim iskustvima ili prepoznatim primjerima kako bi stvorili skup riješenja za medicinski problem. Posjeduju ponašanje "slično ljudskom mozgu" umjesto "računalnog". Zbog sposobnosti poznavanja "ponašanja" problema kroz svoje iskustvo, obično se koriste u problemima prepoznavanja. Ova metoda je pokazala jako dobre rezultate u određivanju uskog i dobro definiranog kliničkog problema [18].

Tri su općenita tipa algoritma koje strojno učenje koristi: bez nadzora, nadzirano i pojačano.

Učenje bez nadzora znači da računalo prepoznaje neku prirodnu grupu unutar baze podataka na temelju načina na koji su "slične" stavke i što čini "dobru" grupu bez danih primjera značajnih vrijednosti stavki. Stoga se strojno učenje naziva i "grupiranje". Nažalost, učenje bez nadzora se ne koristi u mnogim istraživanjima različitih vrsta dijagnoze [18].

U nadziranom učenju, računalu se daju uzorci vrijednosti značajki predmeta. Razlog provođenja nadziranog učenja je razviti "klasifikator" koji može predvidjeti sve mogućnosti iz unaprijed zadanih klasa ili uzoraka na temelju skupa atributa i značajki za opisivanje stavki [18].

U pojačanom učenju nije pružen niti jedan uzorak značajki vrijednosti stavki. Umjesto davanja uzoraka, dobiva se određena glavna točka ili povratne informacije koje mogu odrediti je li sustav na ispravnom putu [18].

3.5.2. Bayesova mreža

Bayesova mreža prikazuje skup varijabli i zavisnosti uvjetnosti između varijabli putem direktnog acikličkog grafikona (engl. *Directed Acyclic Graph*, skraćeno DAG). Svaki čvor na grafikonu predstavlja varijablu, a određeni čvor povezat će se sa susjedom kako bi se prikazale ovisnosti među odgovarajućim varijablama. Ovaj algoritam omogućuje jednostavno razumijevanje i definiciju između bilo koja dva čvora. Pomaže predvidjeti i izračunati svaki mogući događaj koji se može dogoditi u određenom stanju. Sa medicinskog stajališta, može izračunati svaku moguću bolest na temelju navedenih simptoma. Na primjer, groznica, kašalj i upala grla mogu dovesti do simptoma denga groznice[18].

Postoje dvije važne komponente sadržane u ovom algoritmu, a to su struktura i skup parametara. Struktura Bayesove mreže izgrađena je od DAG-a. Svakom čvoru u DAG-u roditeljski čvor može dati neku vrijednost. Parametri opisuju odnos i vjerojatnost čvora za svog roditelja. Ove komponente mogu podržati računanje Bayesove mreže koristeći pravilo lanca. Stoga se učenje parametara i strukture mora provoditi kako bi se u potpunosti prikazala raspodjela vjerojatnosti. Učenje parametara je u svrhu određivanja svakog čvora u DAG-u da bi bio približno raspoređen na temelju uvjetnog odstupanja, a učenje strukture je u svrhu identifikacije načina distribucije kroz cijelu mrežu na temelju lokalnih podataka [18].

Prilikom učenja Bayesove mreže, količina podataka za vježbanje je vrlo važna i izravno utječe na točnost mreže. Stoga, mora biti pruženo dovoljno podataka za vježbanje kroz zapošljavanje stručnjaka za pružanje različitih oblika znanja kako bi se poboljšala točnost modela. Stručnjaci mogu pružiti neko znanje koje određuje stanje među varijablama u Bayesovoj mreži [18].

3.6. Izazovi usvajanja CDSS-a

3.6.1. Klinički izazovi

Mnoge su zdravstvene ustanove i softwareske tvrtke uložile znatne napore u proizvodnju održivih CDSS-ova za podršku svim aspektima kliničkih zadataka. Međutim, s obzirom na visoku složenost kliničkih tijekova rada i zahtjeve za vrijeme osoblja, institucija koja provodi sustav podrške mora paziti da sustav bude fluidan i sastavni dio kliničkog tijeka rada. Neki su se CDSS-ovi susreli s različitim stupnjem uspjeha, dok su drugi pretrpjeli poznate probleme koji sprječavaju ili smanjuju uspješno usvajanje i prihvaćanje.

Dva sektora zdravstvene domene u kojima su CDSS-ovi imali veliki utjecaj su ljekarne i sektori naplate. Postoje obično korišteni sustavi za ljekarne i naručivanje recepta koji sada provode provjeru narudžbe za negativne interakcije lijekova i prijavljuju upozorenja naručiteljima. Drugi sektor uspjeha za CDSS je u naplati i podnošenju zahtjeva. Budući da se mnoge bolnice oslanjaju na naknade da ostanu u funkciji, stvoreni su sustavi kako bi se pomoglo istražiti i predloženi plan liječenja i trenutna pravila Medicarea kako bi predložili plan koji pokušava riješiti i brigu pacijenta i financijske potrebe institucije.

Drugi CDSS-ovi koji su usmjereni na dijagnostičke zadatke pronašli su uspjeh, ali su često vrlo ograničeni u implementaciji i opsegu. “The Leeds Abdominal Pain System” je pokrenut 1971. godine u bolnici Sveučilišta u Leedsu, te je podnesen izvještaj da je u 91.8% slučajeva izrađena točna dijagnoza, u usporedbi s osobljem klinike čiji je uspjeh iznosio 79.6%.

Unatoč širokom rasponu napora institucija za proizvodnju i korištenju tih sustava, prihvaćenost CDSS-a i dalje nije na zadovoljavajućoj razini. Tijekom povijesti razvoja, velika prepreka pri prihvaćanju je bila integracija rada. Postojalo je nastojanje da se usredotoči na samo funkcionalnu jezgru donošenja odluka CDSS-a, što uzrokuje nedostatak u planiranju kako će

kliničar zapravo koristiti sustav. Često su CDSS-ovi bili samostalne aplikacije, zahtijevajući da kliničar prestane raditi na svom trenutnom sustavu, prebaci se na CDSS, unese potrebne podatke (čak i ako su već uneseni u drugi sustav) i ispiše dobivene rezultate. Svi ti dodatni koraci prekidaju tijek rada kliničara i oduzimaju vrijeme. Rezultati istraživanja [intechopen BM] također navode kako stupanj prihvaćanja liječnika ovisi i o njihovim stavovima o njihovoj profesionalnoj ulozi i njihovom stavu prema ulozi raačunala u upravljanju bolestima i donošenju odluka [16].

3.6.2. Tehnički izazovi i prepreke za implementaciju

CDSS se susreće sa mnogim zahtjevnim tehničkim izazovima u svim poljima primjene. Biološki su sustavi vrlo složeni, a klinička odluka može koristiti ogroman raspon potencijalno relevantnih podataka. Na primjer, elektronički sustav medicine na temelju dokaza može potencijalno uzeti u obzir pacijentove simptome, povijest bolesti, obiteljsku povijest i genetiku, kao i povijesne i zemljopisne pojave bolesti, te objavljene kliničke podatke o ljekovitoj učinkovitosti pri preporuci pacijentovog tijeka liječenja. Puno stavki često dolazi u obzir i potrebno ih je sve u što kraćem roku prikupiti, obraditi i dostaviti rezultat zadovoljavajuće kvalitete što je često tehnički vrlo zahtijevan posao.

Također se u mnogim sustavima pojavljuje problem što proizvode ogroman broj upozorenja. Kada sustavi proizvode veliku količinu upozorenja (osobito onih koji ne zahtijevaju eskalaciju), osim smetnje za kliničara, može dovesti do problema da kliničari manje pažnje posvećuju upozorenjima, uzrokujući propuštanje potencijalno kritičnih upozorenja [16].

3.6.3. Održavanje

Jedan od ključnih izazova s kojima se suočava CDSS je poteškoća u uključivanju opsežne količine kliničkih istraživanja koja se neprekidno objavljuju, godišnje se objavi i po desetak tisuća kliničkih ispitivanja [26]. Trenutačno, svako od tih istraživanja mora se ručno čitati, procijeniti za znanstveni legitimitet i precizno uključiti u CDSS. U 2004. godini, navodi se kako je proces prikupljanja kliničkih podataka i medicinskog znanja i stavljanje u oblik kojima računalo može manipulirati kako bi pomogao u kliničkom odlučivanju “još uvijek u djetinjstvu”.[27]

Ipak, više je izvedivo za posao učiniti to centralno, čak i ako je nepotpuno, nego da svaki pojedini liječnik pokušava držati korak sa svim objavljenim istraživanjima. Osim što je naporno, integraciju novih podataka ponekad može biti teško izmjeriti i uključiti u postojeći plan podrške odluke, osobito u slučajevima kada se različiti klinički papiri mogu pojaviti u sukobu razlike podataka. Pravilno rješavanje takvih razlika često je predmet samih kliničkih radova, čiji dovršetak često traje mjesecima[16].

3.6.4. Procjena

Da bi CDSS imao svoju vrijednost, mora se pokazati da poboljšava klinički tijek rada ili ishod. Procjena CDSS-a je proces mjerenja njegove vrijednosti za poboljšanje kvalitete sustava i mjerenje njezine učinkovitosti. Budući da postoje različiti CDSS-ovi sa različitim namjenama, ne postoji opći mjerni podatak koji se odnosi na sve takve sustave; međutim, atributi kao što su dosljednost (sa samim sobom i stručnjacima) često se primjenjuju u širokom spektru sustava [16].

Referentna vrijednost evaluacije za CDSS ovisi o cilju sustava: primjerice, sustav podrške za dijagnostičku odluku može se ocijeniti na temelju dosljednosti i točnosti njegove klasifikacije bolesti (u usporedbi s liječnicima ili drugim sustavima podrške odlučivanju). Sustav medicine temeljen na dokazima može biti ocijenjen na temelju visoke učestalosti poboljšanja zdravlja pacijenata ili veće financijske naknade za pružatelje usluga skrbi.

3.7. Učinkovitost CDSS-a

Mnoga su istraživanja pokazala učinkovitost CDSS-a u poboljšanju kvalitete i kliničkih ishoda, osobito u skladu sa smjernicama preventivne skrbi. Također, poboljšavanje liječnikovog rada i pacijentovog zdravlja pomoću potpore kliničkom odlučivanju (engl. *Clinical Decision Support*, skraćeno CDS) rezultiralo je većom suglasnosti i preporukama CDS-a. Međutim, praksa skrbi za pacijente, smjernice i preporuke temeljene na dokazima i smisleno korištenje CDS-a, kako je propisano zakonom, i dalje ostaje izazovna [28]. Prema dosadašnjim istraživanjima, rezultati i učinkovitost ovise o području medicine na koji se određeni CDSS primjenjuje. U nekim područjima je zabilježen znatan napredak u poboljšanju rada doktora i

zdravlja pacijenata dok istovremeno, u drugim područjima, napredak nije zadovoljavajuć i ekonomičnost sustava je upitna. Postoji puno mjesta za napredak u svakom području, a zbog konstantnog napretka tehnologije i novih istraživanja, teško je stvoriti dobar uzorak istraživanja i jasniju sliku o učinkovitosti CDSS-a.

4. PRIMJERI PROGRAMSKIH SUSTAVA ZA PODRŠKU ODLUČIVANJA U MEDICINI

U ovom poglavlju ćemo pogledati i opisati neke od sustava koji se koriste. Problem pri opisivanju takvih sustava je što je njihova dostupnost vrlo ograničena. Zbog strogih zahtijeva, tehnološke složenosti, uske i precizne primjene, ovi sustavi su vrlo skupi i nisu dostupni za osobnu upotrebu izvan dogovorenih granica upotrebe kao što su bolnice, medicinske ambulante i slično. Postoje i inačice nekih sustava koje su otvorenog koda, međutim, implementacija i korištenje takvih sustava zahtijeva stručno medicinsko znanje kako bi se mogla napraviti kvalitetna evaluacija vrijednosti takvog sustava, a i samo korištenje je, osim znanjem, ograničeno ostalom potrebnom opremom kako bi se iskoristio potencijal sustava (na primjer, za neke sustave su ulazne informacije različiti detalji o krvnom statusu pacijenta do kojih nije moguće doći bez opreme potrebne da se takva analiza provede).

Postoje i jednostavnije aplikacije, većinom za mobilne uređaje, koji pružaju znatno smanjenu i pojednostavljenu količinu informacija. Neke su razvijene od strane istih tvrtki koje razvijaju i velike sustave i takve aplikacije često nisu besplatne, a osim stručnog i proširenog znanja, nude i podršku boljim i preciznijim analizama koristeći svoje velike sustave kao potporu mobilnoj aplikaciji. Drugi tip mobilnih aplikacija su potpuno pojednostavljene aplikacije izrađene od nezavisnih tvrtki koje nemaju utjecaj ni značaj u primjeni u stvarnoj medicine već su više orijentirane na pružanje općeg znanja o pojedinim simptomima manjih bolesti i medicinskih problema. Oba tipa aplikacija se koriste kao informativna smjernica za poduzimanje manjih akcija iz prve ruke dok posjet liječniku ne bude omogućen, nikako se ne bi trebale shvatiti kao definitivno i točno riješenje zbog moguće krive procjene same osobe (pacijenta) koji koristi aplikaciju i koja nije medicinski sposobna donositi takve odluke te same upitnosti točnosti rješenja kojeg je proizvela aplikacija bez suglasnosti stručnog mišljenja medicinskog osoblja.

4.1. Apgar sustav vrednovanja

Virginia Apgar, specijalistica anesteziologije i porođaja, 1949. godine je razvila ovaj sustav koji se prvo zvao “Newborn Scoring System” (u prijevodu, sustav vrednovanja novorođenčeta). Apgar sustav vrednovanja ocjenjuje fizičko stanje novorođenčeta minutu nakon rođenja i pet minuta nakon rođenja. Novorođenče dobiva ukupan rezultat koji se kreće od 0 do

10, ovisno o ocjenjivanju boje, brzini otkucaja srca, naporu dišnih puteva, tonusu mišića i razdražljivosti refleksa [29]. Rezultat minutu nakon rođenja određuje koliko dobro je beba podnijela proces porođaja, a rezultat pet minuta nakon rođenja govori koliko dobro beba podnosi stanje izvan majčine utrobe. Samo u rijetkim slučajevima će se test odraditi i deset minuta nakon rođenja [30].

Apgarova ljestvica se određuje procjenom novorođenčeta na temelju pet jednostavnih kriterija na ljestvici od nula do dva, a zatim zbrajajući tih pet dobivenih vrijednosti. Pet kriterija dobiveni su korištenjem riječi izabranih kao stvaranje akronima APGAR: izgled (engl. *Appearance*), puls (engl. *Pulse*), grimasa (engl. *Grimace*), aktivnost (engl. *Activity*) i disanje (engl. *Respiration*). [31]

Rezultati u vrijednosti sedam ili više su normalni, četiri do šest su prilično niski, a tri i manje se smatraju kritično niskima [31]. Rezultati od deset bodova su izrazito rijetki jer se neka stanja smatraju normalnim pri rođenju i nisu uzrok za zabrinutost. Ocjenu od sedam do deset se smatra normalnom i stabilnim stanjem novorođenčeta i ne očekuju se zdravstveni problemi. Niski rezultat u testu nakon jedne minute može značiti da novorođenče zahtijeva medicinsku pomoć, ali ne mora nužno ukazivati na dugoročni problem, osobito ako se rezultat poboljša nakon testa nakon pet minuta. Tu ubrajamo rezultate od četiri do šest gdje je potrebna hitna intervencija, obično u obliku pomoći dotoka kisika i disanja, obično znakovima kako novorođenče ima poteškoća u prilagođavanju na vanjski život, koji u nekim slučajevima nastaju zbog majčinog uzimanja lijekova tijekom poroda, prijevremenog ili brzog poroda. Rezultat koji ostaje ispod tri u kasnijim testiranjima (kao što je test nakon deset minuta i slično) zahtjeva hitnu pomoć oživljavanja, pomoći pri disanju, provjeru postoji li unutarnje krvarenje i slično. Može ukazivati na dugoročno neurološko oštećenje, uključujući mali, ali značajan porast rizika od cerebralne paralize i visoku osjetljivost na bolesti. Međutim, svrha Apgar testa je brzo odrediti treba li novorođenče hitnu medicinsku pomoć i samo testiranje nema nikakvih rizika za zdravlje novorođenčeta. Nije namijenjeno predviđanju dugoročnih zdravstvenih problema [29].

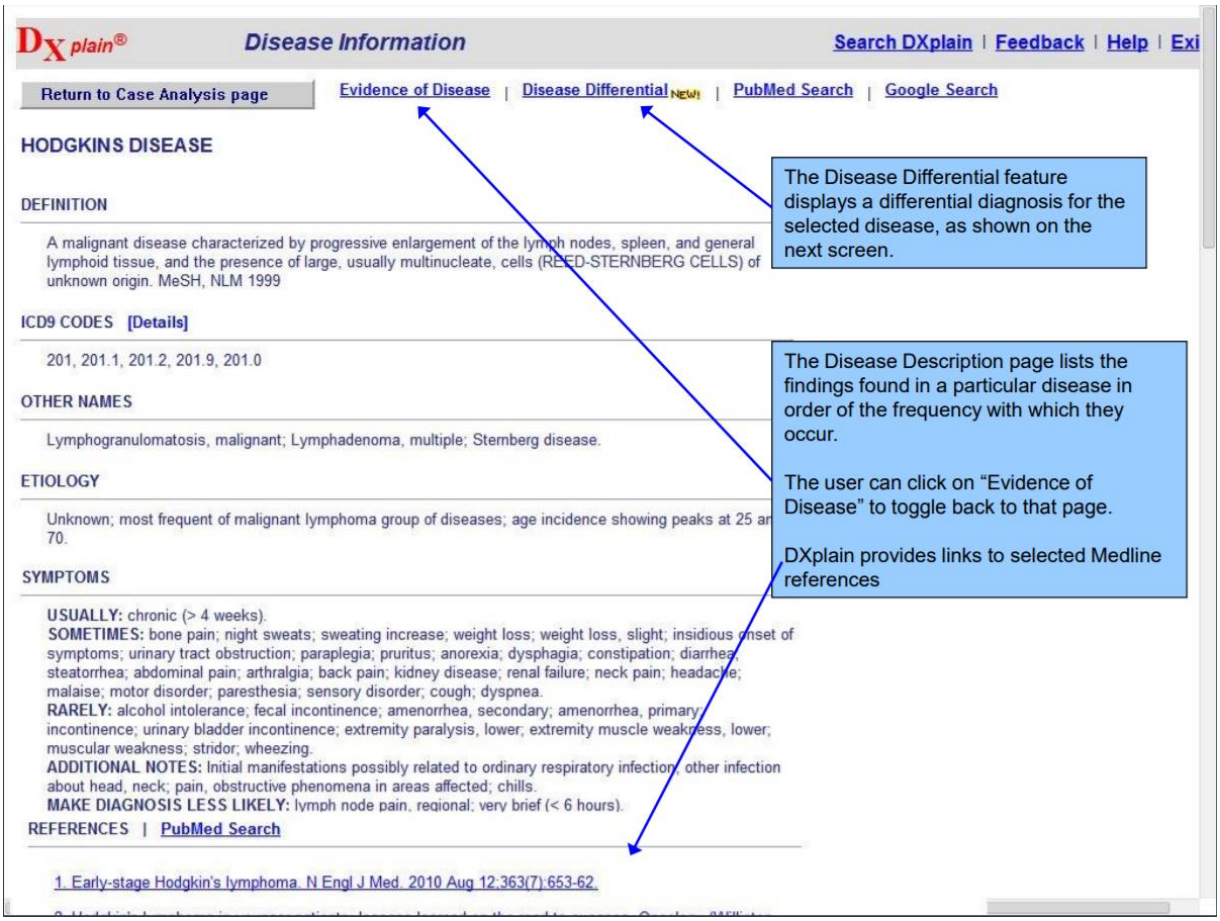
4.2. DXplain

DXplain je dijagnostički sustav za podršku odlučivanju. Razvili su ga Barnett i kolege iz opće bolnice Massachussetts i Harvardškog laboratorija medicinske škole i računalne znanosti 1986. godine, koji su ga u članku iz 1987. godine opisali kao “dijagnostički sustav podrške

odlučivanju u razvoju" [32]. DXplain se može licencirati za edukativnu upotrebu i dostupan je na internetu. Njegova baza znanja uključuje oko 5,000 kliničkih manifestacija povezanih sa više od 2,000 bolesti od kojih opis svake bolesti ima barem deset do sto aktualnih referenci. Tako se DXplain oglašava i kao elektronički udžbenik i medicinski referentni sustav. Svaka bolest ili pronađeni par imaju po dva atributa koji opisuju njihov odnos: prvi koji predstavlja učestalost s kojom se traženi pojam pojavljuje u bolesti, a drugi je stupanj do kojeg prisutnost traženog pojma sugerira razmatranje bolesti. Također, svaka bolest ima dva pridružena atributa: gruba približnost njene rasprostranjenosti (vrlo česta, česta, rijetka ili vrlo rijetka), a drugi je njezin značaj, s namjerom da odražava utjecaj ne uzimajući u obzir bolest ako je prisutna [33].

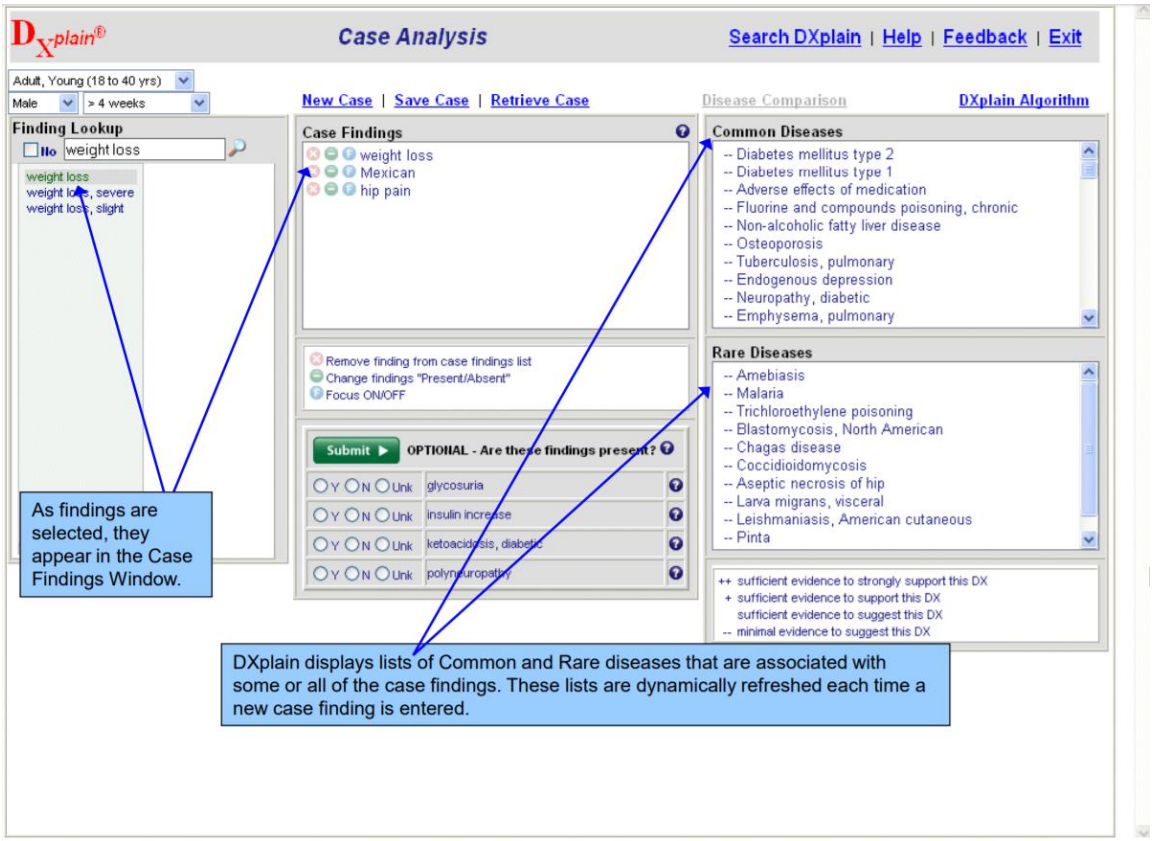
Za prikupljanje kliničkih informacija koristi promijenjen oblik Bayesove logike za dobivanje kliničkih interpretacija [34]. Sučelje sustava nudi dijaloške okvire s tri opcije: diferencijalna dijagnoza nalaza, opis bolesti, i dokaz za dijagnozu u kontekstu slučaja koji je podnešen za analizu. Na primjer, ako se unese "dislipidemija" i sustav ju ne pronađe u svojoj bazi, onda dijaloški okvir pomaže korisnicima da pronađu "hiperlipidemiju" kao najbliži pojam. Kada se unese "hiperlipidemija" u pretraživač, dobiva se opsežna diferencijalna dijagnoza stanja povezanih s tim pojmom. Međutim, ako se unese hiperlipidemija kao bolest, kao rezultat se generira ograničen popis nekoliko vrsta hiperlipoproteinemije [33].

Opisi bolesti organizirani su prema sljedećim stavkama: definicija, druga imena, etiologija, povezani pojmovi i uvjeti, simptomi, fizički nalazi, laboratorijski nalazi, informacije za pomoć dijagnostici, tijek, patologija, i reference (slika 4.1.).



Sl. 4.1. – *"Profil" tražene bolesti (izvor: http://dxplain.org/demo2/dxpdemo.pdf)*

Ako korisnik unese ključne rezultate tipične za obiteljsku hiperkolesterolemiju (na primjer, mladi bolesnik s povećanim kolesterolom i nedavni miokardialni infarkt), sustav ispiše tu dijagnozu i druge uobičajene bolesti. Također navodi i neke neodgovarajuće dijagnoze kao što je višestruki mijelom, kao i rijetke bolesti koje mogu uzrokovati trenutni skup nalaza (Sl. 4.2.) [33]. Naravno, postoji puno simptoma ili skupova nalaza i raznih kombinacija koje sustav ne može prepoznati, ali to se može objasniti činjenicom kako bolesti mogu djelovati jedna na drugu na različite načine koje jednostavno nije moguće uklopiti u model sustava.



Sl. 4.2. – *Sučelje nakon upisivanja problema pacijenta (izvor: http://dxplain.org/demo2/dxpdemo.pdf)*

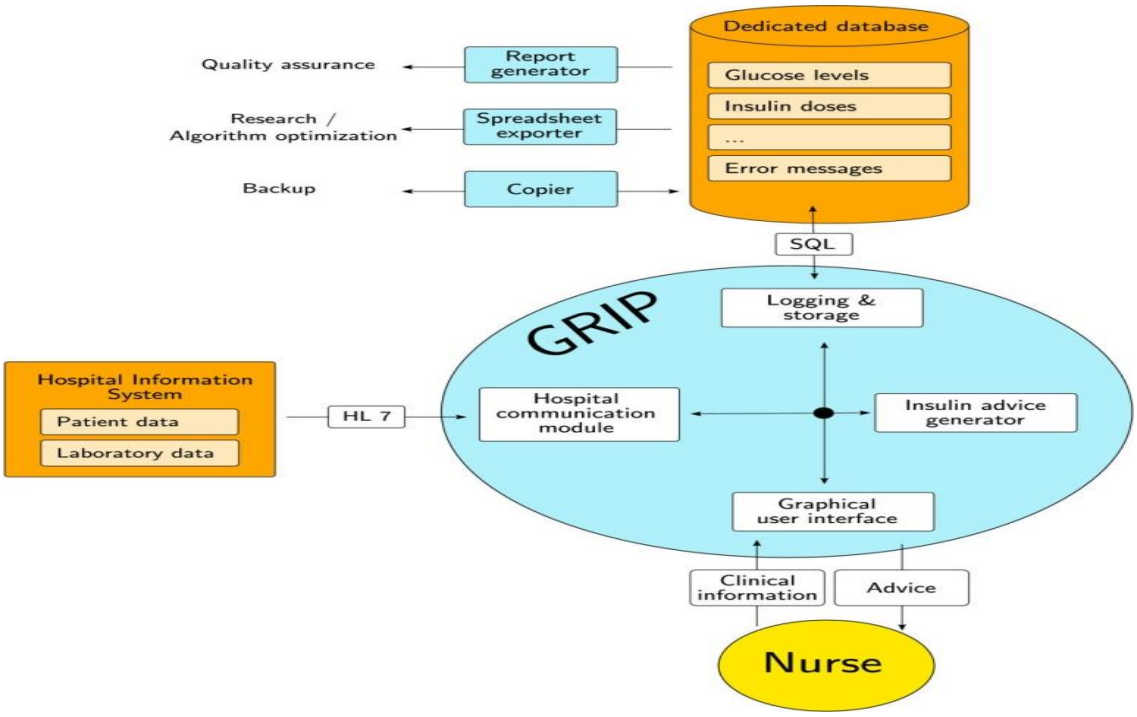
Korisničko sučelje je vrlo jednostavno i uglavnom sasvim dovoljno uz poneke poteškoće u unosu podataka i pojmova iz medicinskog žargona koje računalni sustav ne razumije. Prema navodima, postoje i problem sa nasumičnim odjavljivanjem korisnika iz sustava kao i "*time-out*" koji rezultira gubljenjem svih upisanih podataka ako nisu sačuvani [33].

4.3. GRIP

GRIP (skraćeno od Glucose Regulation for Intensive care Patients) je CDSS za kontrolu glukoze intenzivnom inzulinskom terapijom koji je pokazao učinkovitu kontrolu glukoze bez izazivanja teške hipoglikemije u testiranju koje je trajalo četiri mjeseca. Medicinske sestre su ga izvrsno prihvatile zbog njegove učinkovitosti i minimalnu potrebnu obuku za rad [35]. Njegov je razvoj započeo 2003. godine i objavljen je kao besplatna programska podrška otvorenog koda [36].

Jedno od ključnih načela dizajna je da se rezultat kojeg sustav predlaže smatra preporukom, a ne naredbom. Preporuke koje GRIP daje mogu se nadglasati u bilo kojem trenutku, i ako se nadglasaju, GRIP nastavlja davati smislene savjete sljedeći put (sve dok zna da njegova preporuka nije prihvaćena i koja je radnja umjesto toga poduzeta). Na taj način, GRIP ostaje upotrebljiv u različitim nepredvidljivim situacijama [35].

Kako bi se poboljšala sigurnost i olakšalo prihvaćenje korisnika, zatražene su sve informacije iz baze podataka centralne bolnice. Da bi se osigurale ispravne vrijednosti glukoze, svaka vrijednost glukoze koja je preuzeta iz laboratorijskog sustava zahtijevala je potvrdu od odgovorne medicinske sestre. Na taj su način spriječene pogreške u mjerenju, zamjene pacijenata, i druge pogreške koje bi ometale donošenje odluka sustava. Komunikacija s bolničkom bazom podataka dizajnirana je standardnim komunikacijskim protokolima, a podaci prikupljeni i izračunati pomoću GRIP-a, kao i poruke o greškama, pohranjeni su u relacijskoj bazi podataka pomoću standardnih SQL upita. Budući da se nalaze u bazi podataka, podaci su lako dostupni za aplikacije posebne namjene, poput generatora izvješća za povremenu reviziju kvalitete kontrole glukoze ili drugih stavki GRIP-a ili za program za izvoz podataka u istraživačke svrhe. Većina podataka u bazi je pohranjena u XML obliku, što olakšava nastavak pohrane podataka u budućnosti [35].



Sl. 4.3. – *Detaljan pregled GRIP-ovog dizajna (izvor: http://media.springernature.com/lw785/springer-static/image/art%3A10.1186%2F1472-6947-5-38/MediaObjects/12911_2005_Article_89_Fig2_HTML.jpg)*

Grafičko korisničko sučelje (Sl. 4.4.) je osmišljeno kako bi sustav prikupio kliničke podatke od medicinske sestre i kako bi mogao prenijeti savjete medicinskoj sestri. Kako bi unos podataka bio što je moguće jednostavniji, sve popunjene informacije se automatski popunjavaju s prethodnim vrijednostima, tako da samo izmjene vrijednosti zahtijevaju korisničko djelovanje. Radnje koje medicinska sestra treba poduzeti za unos podataka o pojedinom pacijentu su podijeljene u tri koraka:

1. Uzimanje krvnog uzorka i analiziranje
2. Pregled trenutnih podataka pacijenta i ažuriranje ako je došlo do promjene. Ovaj korak također uključuje provjeru svakog novog mjerenja glukoze.
3. Pregled savjeta za pumpanje inzulina koje je dao GRIP i povratna informacija GRIP-u ako je njegova odluka prihvaćena ili, ako nije, koja je nova mjera inzulinske pumpe.



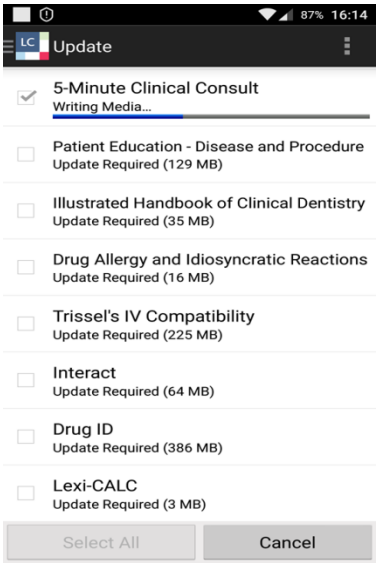
Sl. 4.4. – *Glavni izbornik GRIP-a,pregled svih pacijenata (izvor: http://grip-glucose.sourceforge.net/shots.htm)*

Program je razvijen u Java-i i dizajniran je da se može pokrenuti na klasičnom osobnom računalu, po mogućnosti blizu računala za analizu glukoze kako bi se dosegla optimalna integracija sustava. U potpunosti je besplatan i moguće ga je preuzeti sa stranice http://grip-glucose.sourceforge.net/ [35].

4.4 Lexicomp

Lexicomp je aplikacija za mobilne uređaje dostupna na iOS i Android sustavima. Smanjenih je proporcija i mogućnosti od web aplikacije, ali bez obzira na to, pruža informacije o lijekovima, bolestima i zdravom načinu života. Bogata baza podataka se ažurira na dnevnoj bazi i uvijek su dostupna najnovija istraživanja. Sadrži opće informacije o referencama lijekova, te nudi provjeru interakcije lijekova i izračun doze lijekova. Jedinstvena značajka ove aplikacije je mogućnost pristupa informacijama specifičnim za ustanovu s kojom je korisnik povezan [37].

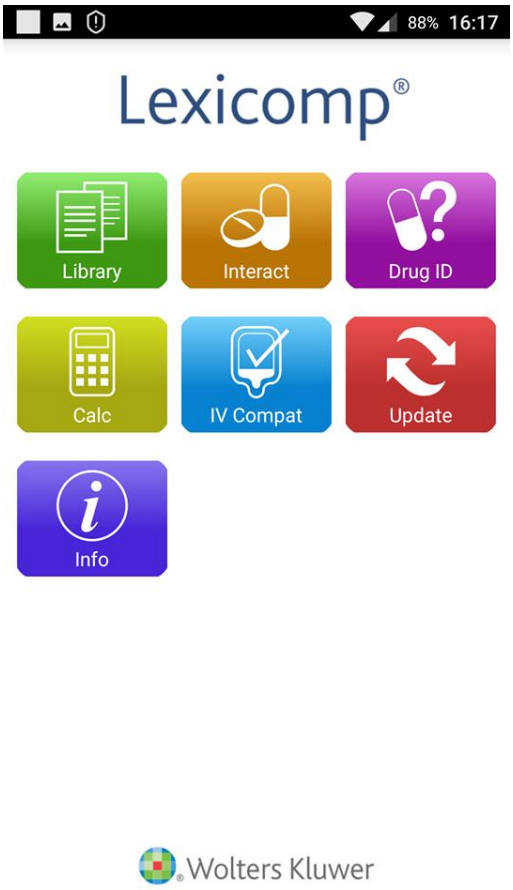
U svrhu isprobavanja mogućnosti, nudi se 30-dnevna besplatna testna verzija, nakon čijeg isteka je potrebno kupiti licencu nekog od ponuđenih paketa usluga. Aplikacija se može preuzeti sa Google Play trgovine (za Android sustave) a nakon instalacije je potrebno registrirati se. Pri prvom pokretanju se nudi lista stavki, tema i opcija koje se mogu odabrati a zatim slijedi preuzimanje podataka na mobilni uređaj (Sl. 4.5.). Ovisno o količini podataka i funkcija koje dolaze sa odabranom stavkom, tako se i veličina te stavke mijenja pa se preporučuje povezivanje na bežičnu mrežu pri preuzimanju stavki.



Sl. 4.5. – *Preuzimanje odabranih baza podataka*

Nakon što su sve željene baze preuzete, otvara se glavni izbornik iz kojeg se nudi navigacija na sve mogućnosti aplikacije (Sl. 4.6.). Korisničko sučelje je jednostavno i pregledno, nudi tražilicu kako bi se olakšala navigacija po stotinama članaka i njihovo spremanje u favorite. Prebacivanje između modula i baza podataka je brzo i nema zastoja, aplikacija vrlo uredno radi i ne čini se kao da ima značajnijih tehničkih poteškoća. Kao veće negativne stavke se može uzeti u obzir detaljnost podataka potrebnih za korištenje nekih značajki aplikacije, ne čini se da postoji

balans cijene licence za naprednog korisnika koji bi sve značajke znao dobro koristiti na dnevnoj bazi i povremenog korisnika koji se aplikacijom ne bi koristio toliko često. a treba platiti licencu koja se čini visoka za povremeno korištenje. Od manjih problema se može navesti nepreglednost, to jest, lošija formatiranost teksta pojedinih članaka.



Sl. 4.6. – *Glavni izbornik aplikacije*

5. ZAKLJUČAK

Sustavi potpore odlučivanju se koriste svakodnevno u svim područjima ljudskih poslova gdje je potrebno u obzir uzeti više čimbenika kako bi se dobio što bolji mogući rezultat. Okruženi smo njima svakodnevno, a toga nismo ni svjesni dok njihov razvoj i doprinos poboljšavaju kvalitetu usluga i poslova na kojima se primjenjuju.

Što se programskih sustava za potporu odlučivanja u medicine tiče, sustavi su od svojih početaka do sada postigli odličan napredak. Postali su veći, kvalitetniji, brži i precizniji s većim bazama podataka i znanja i boljim sustavima prikupljanja istih, što je pomoglo da ih doktori, ali i pacijenti bolje prihvate. Bez obzira što je postignut veliki napredak od početka do sada, i dalje se smatra da su sustavi još u "povojima" i da trebaju još puno napredovati kako bi postigli svoj puni potencijal.

6. LITERATURA

[1] https://en.wikipedia.org/wiki/Decision_support_system, datum zadnjeg posjeta stranici: 27.8.2017.

[2] P. Keen, Decision support systems : a research perspective, 1980., dostupno na: https://archive.org/stream/decisionsupports1980keen#page/n0/mode/2up, datum zadnjeg posjeta stranici: 4.9.2017.

[3] R. Sprague, A Framework for the Development of Decision Support Systems, 1980., dostupno na: https://www.jstor.org/stable/248957?seq=21#page_scan_tab_contents, datum zadnjeg posjeta stranici: 4.9.2017.

[4] V. Belton, T.J. Stewart, Multiple Criteria Decision Analysis: An Integrated Approach, 2002., dostupno na: https://books.google.hr/books?id=mxNsRnNkL1AC&printsec=frontcover&hl=hr&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false, datum zadnjeg posjeta stranici: 4.9.2017.

[5] H.G. Sol, Expert systems and artificial intelligence in decision support systems, 1987., dostupno na: https://books.google.hr/books?id=7CGv4CJwh1IC&printsec=frontcover&hl=hr&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false, datum zadnjeg posjeta stranici: 4.9.2017.

[6] E. Turban, J.E. Aronson, T.P. Liang, Decision Support System And Intelligent System 7th Edition, 2005., dostupno na: https://www.google.hr/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&cad=rja&uact=8&ved=0ahUKEwi30_2Rg53WAhXCNpoKHYXSAm4QFggwMAA&url=http%3A%2F%2Fbagus.staff.gunadarma.ac.id%2FDownloads%2Ffiles%2F45810%2FDecision%2BSupport%2BSystem%2BAnd%2BIntelligent%2BSystem%2B7th%2BEdition-%2BTurban_Aronson_Liang_2005.pdf&usg=AFQjCNGOpqJtJsatsegCjTWsGFw7edKlrg, datum zadnjeg posjeta stranici: 4.9.2017.

[7] D.J. Power, Decision support systems: concepts and resources for managers, 2002., dostupno na: https://books.google.hr/books?id=9NA6QMcte3cC&printsec=frontcover&hl=hr&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false, datum zadnjeg posjeta stranici: 4.9.2017.

[8] A. Gachet, Building Model-Driven Decision Support Systems with Dicodess, 2004., dostupno na: https://books.google.hr/books?id=WAJp6cjMD7MC&pg=PA21&lpg=PA21&dq=Building+Model-Driven+Decision+Support+Systems+with+Dicodess+pdf&source=bl&ots=O_n7Mob8eG&sig=jDDtLhufFTYPt8c-9LuzTecfV8M&hl=hr&sa=X&ved=0ahUKEwiQ0ODXhZ3WAhWDFJoKHYsYDS4Q6AEIXTAI#v=onepage&q=Building%20Model-Driven%20Decision%20Support%20Systems%20with%20Dicodess%20pdf&f=false, datum zadnjeg posjeta stranici: 4.9.2017.

[9] http://dsssystem.blogspot.hr/2010/01/components-of-decision-support-systems.html, datum zadnjeg posjeta stranici: 27.8.2017.

[10] http://www.managementstudyhq.com/components-of-decision-support-systems.html, datum zadnjeg posjeta stranici: 27.8.2017.

[11] R.D. Hackathorn, P.G.W. Keen, Organizational Strategies for Personal Computing in Decision Support Systems, 1981., dostupno na: http://www.jstor.org/stable/249288?seq=1#page_scan_tab_contents, datum zadnjeg posjeta stranici: 4.9.2017.

[12] F. Burstein, C.W. Holsapple, Handbook on Decision Support Systems 1, 2008., dostupno na: https://books.google.hr/books?id=q_3sRkRKZQwC&printsec=frontcover&hl=hr&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false, datum zadnjeg posjeta stranici: 4.9.2017.

[13] http://dssat.net/, datum zadnjeg posjeta stranici: 4.9.2017.

[14] W. Stephens, T. Middleton, Why has the uptake of Decision Support Systems been so poor?, u sklopu knjige: Crop-soil simulation models in developing countries, 2002., dostupno na: https://books.google.hr/books?id=ZgzBOcH9bDgC&pg=PA129&lpg=PA129&dq=Why+has+the+uptake+of+Decision+Support+Systems+been+so+poor?+In:+Crop-soil+simulation+models+in+developing+countries+stephens+middleton&source=bl&ots=66pcmOikI9&sig=xz99c9lz49EogtNSZNeVEHc0bZM&hl=hr&sa=X&ved=0ahUKEwj1hKu9mp3WAhWIAJoKHaxUAf0Q6AEINDAC#v=onepage&q=Why%20has%20the%20uptake%20of%20Decision%20Support%20Systems%20been%20so%20poor%3F%20In%3A%20Crop-soil%20simulation%20models%20in%20developing%20countries%20stephens%20middleton&f=false, datum zadnjeg posjeta stranici: 4.9.2017.

[15] http://www.forestdss.org/CoP/, datum zadnjeg posjeta stranici: 4.9.2017.

[16] https://en.wikipedia.org/wiki/Clinical_decision_support_system, datum zadnjeg posjeta stranici: 4.9.2017.

[17] http://searchhealthit.techtarget.com/definition/clinical-decision-support-system-CDSS, datum zadnjeg posjeta stranici: 4.9.2017.

[18] https://www.ukessays.com/essays/computer-science/types-of-clinical-decision-support-system-computer-science-essay.php, datum zadnjeg posjeta stranici: 4.9.2017.

[19] http://www.openclinical.org/dss.html, datum zadnjeg posjeta stranici: 4.9.2017.

[20] E.S. Berner, Clinical Decision Support Systems, 2007., dostupno na: https://books.google.hr/books?id=t4laP7U4a-AC&printsec=frontcover&hl=hr&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false, datum zadnjeg posjeta stranici: 4.9.2017.

[21] S. Begum, M.U. Ahmed, P. Funk, N. Xiong, M. Folke, Case-based reasoning systems in the health sciences: a survey of recent trends and developments, 2011., dostupno na: http://www.skateboardingalice.com/papers/2010_Begum.pdf, datum zadnjeg posjeta stranici: 4.9.2017.

[22] G. Khussainova, S. Petrovic, R. Jagannathan, Retrieval with clustering in a case-based reasoning system for radiotherapy treatment planning, Journal of Physics: Conference Series, 2015., dostupno na: http://iopscience.iop.org/article/10.1088/1742-6596/616/1/012013/pdf, datum zadnjeg posjeta stranici: 4.9.2017.

[23] https://www.ncbi.nlm.nih.gov/pmc/articles/PMC130063/, datum zadnjeg posjeta stranici: 4.9.2017.

[24] http://rctbank.ucsf.edu/home/trialreporting/introduction, datum zadnjeg posjeta stranici: 4.9.2017.

[25] http://www.sciencedirect.com/science/article/pii/S074152149970100X, datum zadnjeg posjeta stranici: 4.9.2017.

[26] C. Gluud, D. Nikolova, Likely country of origin in publications on randomised controlled trials and controlled clinical trials during the last 60 years, 2007., dostupno na: https://trialsjournal.biomedcentral.com/articles/10.1186/1745-6215-8-7, datum zadnjeg posjeta stranici: 4.9.2017.

[27] R.M. Gardner, Computerized Clinical Decision-Support in Respiratory Care, u sklopu knjige: Respiratory Care, dostupno na: http://rc.rcjournal.com/content/respcare/49/4/378.full.pdf, datum zadnjeg posjeta stranici: 4.9.2017.

[28] http://www.clinfowiki.org/wiki/index.php/Clinical_Decision_Support:_Effectiveness_in_Improving_Quality_Processes_and_Clinical_Outcomes_and_Factors_That_May_Influence_Success, datum zadnjeg posjeta stranici: 4.9.2017.

[29] http://www.encyclopedia.com/medicine/psychology/psychology-and-psychiatry/apgar-score, datum zadnjeg posjeta stranici: 4.9.2017.

[30] https://medlineplus.gov/ency/article/003402.htm, datum zadnjeg posjeta stranici: 4.9. 2017.

[31] https://en.wikipedia.org/wiki/Apgar_score, datum zadnjeg posjeta stranici: 4.9.2017.

[32] G.O. Barnett, J.J. Cimino, J.A. Hupp, E.P. Hoffer, DXplain: an evolving diagnostic decision-support system, 1987., dostupno na: http://people.dbmi.columbia.edu/cimino/Publications/1987%20-%20JAMA%20-%20DXplain-An%20Evolving%20Diagnostic%20Decision-Support%20System.pdf, datum zadnjeg posjeta stranici: 4.9.2017.

[33] https://www.ncbi.nlm.nih.gov/pmc/articles/PMC100779/, datum zadnjeg posjeta stranici: 4.9.2017.

[34] http://www.mghlcs.org/projects/dxplain/, datum zadnjeg posjeta stranici: 4.9.2017.

[35] https://bmcmedinformdecismak.biomedcentral.com/articles/10.1186/1472-6947-5-38, datum zadnjeg posjeta stranici: 4.9.2017.

[36] http://grip-glucose.sourceforge.net/index.htm, datum zadnjeg posjeta stranici: 4.9.2017.

[37] https://www.imedicalapps.com/2013/01/lexicomp-android-drug-reference-formulary-app/, datum zadnjeg posjeta stranici: 4.9.2017.

SAŽETAK

Ovaj rad predstavlja i objašnjava ulogu sustava za potporu odlučivanju s posebnim fokusom na programske sustave koji se koriste u današnje vrijeme. Cilj je detaljno opisati strukturu, karakteristike i primjenu programskih sustava za potporu odlučivanja u medicini i navesti neke od sustava koji se koriste. Kao uvod, objašnjen je općeniti koncept sustava za podršku odlučivanju, njihova povijest i najznačajnije primjene. Zatim je razrađena tema tih sustava konkretno u području medicine, njihova raspodjela, karakteristike i poteškoće s kojima se susreću. Na kraju su opisana su tri prava, veća sustava koji se koriste i jedan manji sustav, to jest, mobilna aplikacija. Kao rezultat, dobiven je uvid u rad sustava koji nas svakodnevno okružuju, njihov utjecaj za poboljšanje života u svim aspektima i napredak od začetka i prvih inačica do današnjih velikih i kompleksnih sustava.

Ključne riječi: programski sustav, podrška odlučivanju, medicina, sustav podrške odlučivanju, pomoćni sustavi

ABSTRACT

PROGRAM-BASED DECISION SUPPORT SYSTEMS IN MEDICINE

This paper presents and explains the role of decision support systems with a special focus on software systems used today. The goal is to describe the structure, characteristics and application of software-based decision support systems in medicine in detail and to list some of the systems that are used. As the introduction, the general concept of the decision support systems is described, their history is explained and the most important applications are listed. Then the subject of these systems, specifically in the field of medicine, was elaborated, their assignment, characteristics and difficulties they encounter are also listed and explained. In the end three real, large systems that are used and one smaller system, that is, a mobile application, are described. As a result, the insight into the workings of systems that are part of our daily environment is given, their impact on improving life in all aspects and progress they made from the beginning and the first versions to today's large and complex systems.

Keywords: software systems, decision support, medicine, decision support system, auxiliary systems

ŽIVOTOPIS

Matej Kolar rođen je 9.7.1993. godine u Koprivnici, Republika Hrvatska. Osnovnu školu Ivana Kozarca pohađao je u Županji od 2000. do 2008. godine. Srednju tehničku školu, smjer Računarstvo u Županji je upisao 2008. godine i završio 2012. godine. Godine 2012. upisuje se na Elektrotehnički fakultet u Osijeku, smjer Računarstvo te je zvanje prvostupnika stekao 2015. godine.