

# **Odločitve na dlani: Sistem za podporo večparametrskemu odločanju na dlančnikih**

## **Decisions at Hand: The Multi-attribute Decision Support System on Handhelds**

Blaž Zupan<sup>1,2,3</sup>, Aleš Porenta<sup>1</sup>, Gaj Vidmar<sup>4</sup>

<sup>1</sup> Fakulteta za računalništvo in informatiko, Univerza v Ljubljani, Tržaška 25, Ljubljana

<sup>2</sup> Inštitut Jožef Stefan, Jamova 39, Ljubljana

<sup>3</sup> Baylor College of Medicine, 1 Baylor Plaza, 77030 Houston, Texas, ZDA

<sup>4</sup> Filozofska fakulteta, Univerza v Ljubljani, Aškerčeva 2, Ljubljana

### **Izvleček**

Podpora kliničnemu odločanju je ena od naprednejših, a premalo uporabljenih funkcij kliničnih informacijskih sistemov. Težava pri uvajanju tovrstnih pripomočkov je predvsem potreba po uporabi računalniške opreme, ki pa mnogokrat ni dosegljiva na mestu dejanskega odločanja, npr. na vizitah, ob pogovorih s pacientom, ipd. V članku podajamo možno rešitev tega problema v obliki lupine za pomoč pri odločanju, ki deluje na dlančnih računalnikih in uporablja modele logistične regresije. Predlagamo rešitev, kjer ustrezne modele odločanja razvijemo na osebnih računalnikih in delovnih postajah, od koder se modeli prenesejo v obliki XML datoteke na dlančnike, kjer se nato lahko prične njihova dejanska klinična uporaba.

### **Abstract**

One of the advanced features of clinical information system is decision support. Although the advantages of utilizing such aids have never been theoretically disputed, they have been rarely used in practice. The factor that probably limits the utility of clinical decision support systems the most is the need for computing power at the very site of decision making – at the place where the patient is interviewed, in discussion rooms etc. The paper reports on a possible solution to this problem. A decision-support shell is presented, which runs on a handheld computer and uses logistic regression models. A general schema of operation is also proposed, where the models are developed on personal computers/workstations, encoded within an XML file and then transferred to handhelds, where the models are actually used in the clinical practice.

### **1. Uvod**

Sodobni klinični informacijski sistemi morajo zdravnikom in zdravstvenemu osebju omogočiti enostaven vnos in obdelavo podatkov, ter jim na podlagi zbranih podatkov nuditi podporo pri vsakodnevem odločanju. Razvoj informatike v medicini in zdravstvu je tako v razvitih državah kot tudi v Sloveniji navadno ubiral poti, kjer so zdravstveni in predvsem zavarovalniški informacijski sistemi bili razviti prej in bolje od kliničnih. Če zdravstveni informacijski sistemi predvsem podpirajo administrativne poslovne funkcije, so klinični

informacijski sistemi neposredno namenjeni izboljšanju dela zdravnikov, saj naj bi na sistematičen in konsistenten način nudili zdravniku vse potrebne podatke o bolniku, ki so potrebni za kvalitetno in informirano odločanje o zdravstvenih posegih, izboru terapij in spremljanju poteka zdravljenja.

Ena od naprednejših funkcij kliničnih informacijskih sistemov je nudenje podpore pri odločanju. Tipična opravila vključujejo pomoč pri postavljanju diagnoz, pomoč pri napovedovanju izidov zdravljenja in pomoč pri izboru terapij. Sistemi za pomoč pri kliničnem odločanju navadno od lečečega zdravnika ali specialista zahtevajo vnos pacientovih podatkov, podatkov o poškodbi oz. bolezni ter podatkov o bolezenskih okoliščinah. Na osnovi vnešenih podatkov s pomočjo odločitvenega modela nato ovrednotimo variante (diagnoze, prognoze, ipd.). Ker naj bi odločitveni sistemi bili predvsem v pomoč zdravnikom in specialistom pri vsakodnevnem odločanju, morajo biti dostopni in enostavni za uporabo, poleg same ocene verjetnosti izida (diagnoze, prognoze) pa naj bi podali tudi razlago odločitve (npr., kateri dejavniki so prispevali k povečanju verjetnosti določenega izida in kateri dejavniki so vplivali negativno).

## **2. Podpora odločanju in dlančni računalniki**

Literatura s področja kliničnega odločanja navaja več tipov modelov, ki lahko strokovnjakom bistveno pomagajo pri odločanju. Ti vključujejo statistične modele, na primer linearno in logistično regresijo ali kompleksnejše multivariatne metode, modele uteženih vsot, kot tudi zadnje čase vse bolj uveljavljane modele, ki uporabljajo tehnologije odkrivanja znanja iz podatkov (*knowledge discovery, data mining*), razpoznavanja vzorcev (*pattern recognition*) in strojnega učenja (*machine learning*). Primeri slednjih so klasifikacijska drevesa, naivni Bayesovi modeli, Bayesovske mreže in nevronske mreže.

Skupno vsem zgoraj naštetim modelom pa je, da je potrebno za njihovo uporabo v namene podpore odločanja uporabiti računalnik oziroma program, ki vnešene pacientove podatke ustrezno pretvori in jih uporabi v modelu. Po določenem računskem postopku uporabljeni program nato vrne rezultat, ki je na področju kliničnega odločanja navadno podan v obliki verjetnosti diagnoze oz. prognoze. Tu naletimo na prvi in večji problem: zdravnikom in specialistom je računalnik ob pacientu na voljo le redkokdaj. Zdravnik bi si tako pacientove podatke moral zapisati, iti v prostor z računalnikom, pognati pravi program, vpisati podatke ter analizirati rezultate. Ta scenarij (ki vključuje tudi za pacienta zelo nadležno čakanje) je seveda nerealen in najbrž eden od osnovnih vzrokov, zakaj do širše uporabe odločitvenih modelov pri kliničnem odločanju do sedaj tudi v razvitejših državah še ni prišlo.

Možno rešitev opisanega problema nudijo dlančniki (*handheld computers, personal digital assistants*). To so majhni, žepni računalniki, ki pa vsebujejo dovolj računalniške moči, da lahko služijo osnovnemu zbiranju in obdelavi podatkov. V razvitih državah, predvsem pa v ZDA., je razmah tovrstnih naprav takšen, da v nekaterih zdravstvenih ustanovah skoraj

polovica zdravnikov že uporablja dlančnike za shranjevanje kontaktnih podatkov in informacij o sestankih oziroma napovedanih obiskih. Za dlančnike je bilo predvsem v zadnjih treh letih razvitih tudi precejšnje število programov z medicinskimi vsebinami.

Ravno zaradi zgoraj omenjenega trenda vse večje uporabe dlančnih računalnikov v zdravstvu, je Dr. Micheal Kattan iz Sloan-Kettering Hospital v New Yorku pred leti predpostavil, da bodo zdravniki, ki že uporabljajo dlančnike, voljni na njih uporabljati tudi sistem za podporo odločanja. Njegova skupina je izdelala program, ki na podlagi osnovnih podatkov o pacientih z rakom na prostati napove možnost ponovitve raka po operaciji in pomaga pri določitvi razširjenosti raka na podlagi predoperativnih podatkov [Kattan in sod., 1998; Kattan in Fearn, 2000]. Dve leti po izidu in preizkušanju programa, ki je po vsej verjetnosti tudi prvi tovrstni izdelek za dlančnike na področju klinične medicine, je danes ta v redni uporabi na Urološkem oddelku omenjene institucije.

Kattanov sistem za podporo kliničnemu odločanju na dlančnih računalnikih pa ima eno pomembno omejitev. Namenjen je izključno prognostiki raka na prostati, hkrati pa je omejen na model, ki je "zapečen" v dlančniku, torej pri njem uporabnik ne more spreminjati ne vrednosti parametrov ne strukture. Uporaba kakršnegakoli drugega modela bi vključevala spreminjanje same programske kode programa, ponovno prevajanje (in razhroščevanje aplikacije) ter nalaganje aplikacije v dlančnik. To opravilo pa je daleč od enostavnega – ne samo za zdravnike, marveč tudi za izkušenejšje računalniške programerje.

Pričujoči članek opisuje rešitev zgornjega problema in aplikacijo na dlančnikih, ki omogoča podporo odločanja na osnovi modelov, ki so od aplikacije neodvisni in jih uporabnik oziroma razvijalec modela določi z ustreznim zapisom v XML označevalnem jeziku. To stori na osebem računalniku, potem pa se ob sinhronizaciji podatkov model prenese na dlančnik, kjer ga je moč uporabiti. Razvita aplikacija torej predstavlja nekakšno lupino za uporabo odločitvenih modelov (*decision support shell*) in potencialno razširja uporabo tovrstne tehnologije na poljubne probleme, za katere obstajajo dobri odločitveni modeli.

Zaradi enostavnosti, robustnosti, trdne statistične podlage in razširjenosti v medicini smo se odločili, da lupina, ki smo jo razvili, podpre odločanje na osnovi modelov logistične regresije. V nadaljevanju članka najprej na kratko podamo teoretične temelje tovrstnih modelov (celovito predstavitev podajajo številni učbeniki, npr. [Kleinbaum, 1994]), nato pa predstavimo arhitekturo sistema in dva primera s področja medicinske prognostike, za katera obstaja v literaturi dokumentiran odločitveni logistično-regresijski model, ki smo ju implementirali na dlančniku. Izdelani sistem smo poimenovali LogReg, deluje pa pod operacijskim sistemom PalmOS na dlančnikih tipa PalmPilot in kompatibilnih.

### 3. Logistični regresijski model in njegova uporaba

#### 3.1 Osnove modela

Logistična regresija je ena od najbolj uveljavljenih multivariatnih statističnih metod na področju biomedicinskih ved [Stare, 1998]. Uporablja se za napovedovanje dihotomne odvisne spremenljivke, torej izida 0 (npr. odgovor NE, odsotnost bolezni) ali 1 (npr. odgovor DA, prisotnost bolezni). Temelji na logistični funkciji, ki je sigmoidne oblike in se z naraščanjem oziroma padanjem  $z$  proti  $\infty$  oziroma  $-\infty$  asimptotično približuje 1 oziroma -1:

$$f(z) = 1 / (1 + e^{-z})$$

Neodvisne spremenljivke (vektor prediktorjev  $\mathbf{x}$  sestavljajo  $X_{i=1...k}$ ) so preko linearne kombinacije

$$z = \alpha + \beta_1 X_1 + \dots + \beta_k X_k$$

vključene v logistični model

$$P(Y=1 | X_1, \dots, X_k) = P(\mathbf{x}) = f(z)$$

Povečanje  $\sum \beta_i X_i$  torej pomeni povečanje pogojne verjetnosti izida 1. Model je v osnovi linearen, saj je linearna zveza med prediktorji in napovedano verjetnostjo, podvrženo logit transformaciji, t.j. naravnim logaritmom obojnih: regresijska enačba je

$$z = \text{logit}(P) = \ln [P / (1 - P)]$$

Kot vselej v okviru splošnega linearnega modela, lahko tudi pri logistični regresiji v model vključimo dihotomne, nominalne in/ali intervalne prediktorje, člene višjega reda ter morebitne interakcije, pri čemer nominalno (opisno, kvalitativno, kategorialno) spremenljivko z  $n$  kategorijami pretvorimo v  $n-1$  dihotomnih ("slepih") spremenljivk. Obravnavana aplikacija je zaradi svoje prototipske narave ter enostavnosti prikaza in interpretacije napovedi omejena na modele brez interakcij in členov višjega reda.

Običajni linearni regresijski model je za napovedovanje binarnega izida<sup>1</sup> manj primeren od logističnega (od katerega se za območje  $P$  od 0,2 do 0,8 sicer bistveno ne razlikuje) z vidika razvidne veljavnosti, saj lahko pri prvem vrednost odvisne spremenljivke preseže 1 ali pade pod 0, predvsem pa z vidika robustnosti (predpostavke slednjega so v splošnem blažje, predpostavka prvega o normalnosti porazdelitve rezidualov ne more biti izpolnjena).

Postopki za logistično regresijo so vključeni v vso množico sodobnih statističnih programskih paketov. Za ocenjevanje parametrov se skorajda izključno uporablja metoda največje

---

<sup>1</sup> V tem primeru je linearna diskriminantna analiza kot druga "klasična" alternativa ekvivalentna linearni regresiji.

zanesljivosti (*maximum likelihood*), ki sicer zahteva nekoliko večje vzorce, a je pri ustrezno velikem razmerju števila primerov in števila spremenljivk mnogo zanesljivejša od metode najmanjših kvadratov.

Problematično je ocenjevanje bazičnega tveganja, t.j. parametra  $\alpha = \text{logit } P(0, \dots, 0)$ , za katerega je načeloma potrebno podatke zbrati s spremljevalno (*follow-up*) študijo. Vpliv oziroma pomen posameznih prediktorjev se navadno izraža z razmerjem obetov (OR, *odds ratio*), ki ga je moč oceniti tudi pri študijah primerov in kontrol (*case-control studies*) in transferzalnih (*cross-sectional*) študijah. Splošni obrazec zanj je

$$\text{OR} = \exp [-\beta_i (X_{i1} - X_{i2})]$$

ki se za dihotomne prediktorje poenostavi v  $e^\beta$ . Za numerične prediktorje isti izraz pomeni spremembo obetov, če se ob nespremenjenih vrednostih ostalih prediktorjev  $X_i$  poveča za eno enoto.

### 3.2 Ocenjevanje intervala zaupanja za napovedano verjetnost

Napovedano vrednost  $P$  za primer, ki ga ni bilo v učni množici, dobimo seveda tako, da vstavimo vrednosti  $X$  v logistično enačbo z ocenjenimi regresijskimi koeficienti. Ker problematika določanja optimalne meje (*cut-off point*) za razvrstitev primera, oziroma celotno zapleteno področje mer klasifikacijske točnosti logistično-regresijskega modela presega okvir obravnavane aplikacije, pomeni  $P > 0,5$  vedno razvrstitev primera v razred 1,  $P < 0,5$  pa razvrstitev v razred 0.

Pri sistemih za podporo medicinskemu odločanju pa je vedno potrebno, da dobi uporabnik vsaj okviren podatek o zanesljivosti (gotovosti) odločitve. Zato smo implementirali izračun intervala zaupanja za napovedano vrednost. Aproksimacija binomske porazdelitve deleža  $p$  z normalno porazdelitvijo, torej izračun intervala zaupanja na podlagi izračuna standardne napake po obrazcu

$$\text{SE}(p) = [p(1-p) / N]^{1/2}$$

bi bila pri vzorcih velikosti vsaj 100 enot, s kakršnimi imamo praviloma opravka pri razvoju logistično-regresijskih modelov, sicer sprejemljiv postopek za območje  $P$  od 0,2 do 0,8, a tovrstna rešitev poleg neustreznosti pri ekstremnih deležih (zgornja meja 95%-intervala zaupanja tam tudi preseže 1 oziroma spodnja pade pod 0) povsem zanemari informacijo, vsebovano v vrednostih neodvisnih spremenljivk za klasificirani primer. Zato smo se odločili za sodobni postopek [Piergorsch in Casella, 1988], ki izhaja iz linearne narave regresijskega modela: s standardnim inferenčnim aparatom linearne regresije obravnavamo  $g(\mathbf{x}) = \text{logit}(P)$ , nato pa dobljeni meji intervala zaupanja za  $g(\mathbf{x})$  pretvorimo v verjetnosti z inverzno transformacijo

$$P = 1 / \{1 + \exp [-g(\mathbf{x})]\}$$

Pri tem smo morali razrešiti dva problema, ki izhajata iz standardnega izraza za 95% (oziroma – z ustrežno spremembo faktorja, s katerim množimo standardno napako napovedi – katerikoli ožji ali širši) interval zaupanja za napovedano vrednost pri linearni regresiji (npr. [Myers in Well, 1991]):

$$CI = E(Y) \pm [MSE(1 + h_{ii})]^{1/2}$$

Prvi problem je vsebinske (statistične) narave in zadeva srednji kvadrat napake (MSE): pravega ekvivalenta tej količini pri logistični regresiji v splošnem ni, zato je v obrazcu

$$MSE = \{\Sigma [Y - E(Y)]\} / (N - \text{število prediktorjev} - 1)$$

namesto razlike med dejansko in napovedano vrednostjo najprimerneje uporabiti kar razliko med dejanskim razredom (0 ali 1) in napovedjo  $P$ , ne glede na to, da izračun standardne napake napovedi sicer poteka "v svetu" ("na strani") logit vrednosti.

Pri ročicah ( $h_{ii}$ ), t.j. diagonalnih vrednostih matrike  $\mathbf{H} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$ , pa gre za tehnični problem. Prenos matrike podatkov  $\mathbf{X}$  (v kateri so v prvem stolpcu, ki ustreza konstantnemu členu regresijske enačbe, same vrednosti 1), na kateri je bil razvit logistično-regresijski model, v dlančni računalnik, nato pa transponiranje, obračanje in množenje matrik v dlančnem računalniku zaradi spominskih in hitrostnih omejitev seveda ne pride v poštev. Učinkovita rešitev je prenos predhodno izračunane matrike  $(\mathbf{X}^T \mathbf{X})^{-1}$  v dlančni računalnik ter izračun ročice za novi primer po obrazcu

$$h_{ii} = \mathbf{x}_i^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{x}_i$$

### 3.3 Razlaga odločitev z razmerjem obetov tveganj

Poleg predstavitve negotovosti napovedi h kakovosti podpore uporabnikovi odločitvi bistveno pripomore tudi razlaga odločitve. Problematika medsebojne povezanosti ter prikaza različnih parametrov oziroma značilnosti logistično-regresijske analize zahteva obsežen in celovit pregled, kot ga podaja Harrell [1998, 1999], na tem mestu pa naj omenimo le prikaz razmerij obetov tveganj (ROR, *risk odds ratio*), ki ga aplikacija omogoča za vsakega od prediktorjev.

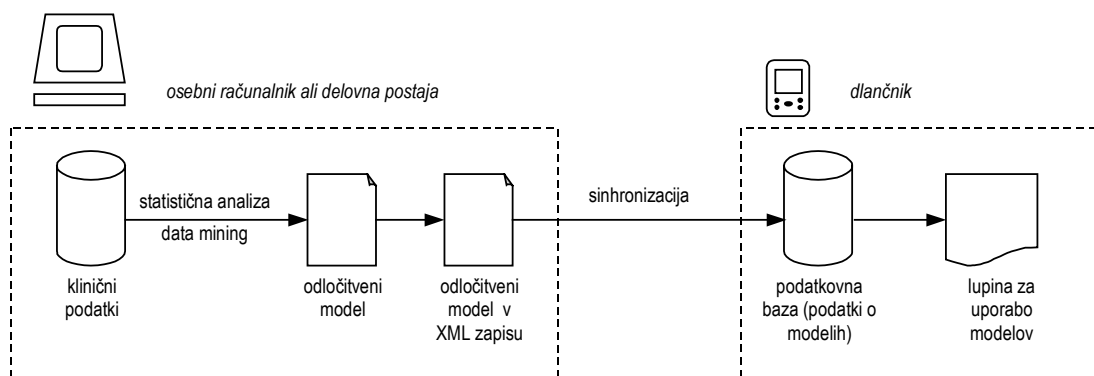
Razmerje obetov tveganj v splošnem podaja primerjavo med dvema konfiguracijama vrednosti prediktorjev glede napovedane vrednosti  $P$ , praviloma pa se izračuna za primera, ki se razlikujeta le v vrednosti enega od prediktorjev. Če je izbrani prediktor binaren, je dobljeni izraz seveda bodisi računsko ekvivalenten razmerju obetov (v obravnavani aplikaciji je tako za primere, ki imajo vrednost izbranega dihotomnega prediktorja 1), bodisi enak 1 (če je

vrednost izbranega prediktorja 0). Pri numeričnih prediktorjih je potrebno posamezni primer primerjati z reprezentativno vrednostjo za populacijo, iz katere je vzet analizirani vzorec, kar je navadno aritmetična sredina prediktorja v vzorcu (taka je tudi naša implementacija). Če pa gre za kategorialen prediktor, izračun (ki, kot je bilo poudarjeno že uvodoma in se nanaša na vse vidike aplikacije, velja le za model brez interakcijskih členov) najbolje pojasnjuje spodnji primer za štiri kategorije, torej skupino treh dihotomnih spremenljivk, pri čemer je bila bazična (prva) kategorija pri ocenitvi parametrov modela kodirana z  $X_{1a}=1$ ,  $X_{2a}=0$  in  $X_{3a}=0$ , posameznik, za katerega smo z logističnim modelom napovedali  $P$ , pa pripada kategoriji, ki je kodirana kot tretja ( $X_{1b}=X_{2b}=0$ ,  $X_{3b}=1$ ):

$$RR_{3:1} = \exp [(X_{1a} - X_{1b}) \beta_1 + (X_{2a} - X_{2b}) \beta_2 + (X_{3a} - X_{3b}) \beta_3] = \exp (-\beta_1 + \beta_3)$$

#### 4. Arhitektura sistema

Sistem LogReg – lupina za podporo odločanja na dlančnikih – temelji na izdelavi modela logistične regresije na osebem računalniku ter njegovem zapisu v XML označevalnem jeziku. Tovrstnih modelov je na istem osebem računalniku lahko več. Uporabnik bo modele lahko pridobil z lastno analizo podatkov (modeli bodo nastali kot rezultat statistične analize), lahko jih bo našel v literaturi in zapisal v XML datoteki, lahko pa bo razvijalec druga oseba, ki bo dala XML datoteko v uporabo zdravnikom oziroma specialistom. S pomočjo posebnega programa, ki je del razvitega sistema, uporabnik nato določi, katere modele želi uporabljati na dlančniku. Program Vodilo (Conduit), ki je del paketa, poskrbi, da se vsi modeli, ki jih je uporabnik izbral, pretočijo v dlančnik ob naslednji sinhronizaciji dlančnika z osebim računalnikom. Arhitekturo sistema shematsko prikazuje slika 1.



**Slika 1** Osnovna arhitektura sistema za uporabo odločitvenih modelov na dlančnih računalnikih

Na tem mestu želimo poudariti, da je kljub odločitvi, da sistem podpre modele logistične regresije, opisani koncept splošen in uporaben za poljubno tehniko modeliranja. Tako so na primer logistični regresiji po enostavnosti in uporabnosti v medicini precej blizu modeli, osnovani na naivni Bayesovi enačbi. Za implementacijo lupine za tovrstne modele bi bilo potrebno spremeniti le način opisa v XML datoteki, del programa za prenos podatkov in del

programa na dlančniku za izračun verjetnosti izidov. Celotna shema sistema, kot tudi (obsežnejši) del programa na dlančniku, ki podpira vnos podatkov, bi ostal nespremenjen.

## 5. Primeri uporabe sistema na dlančniku

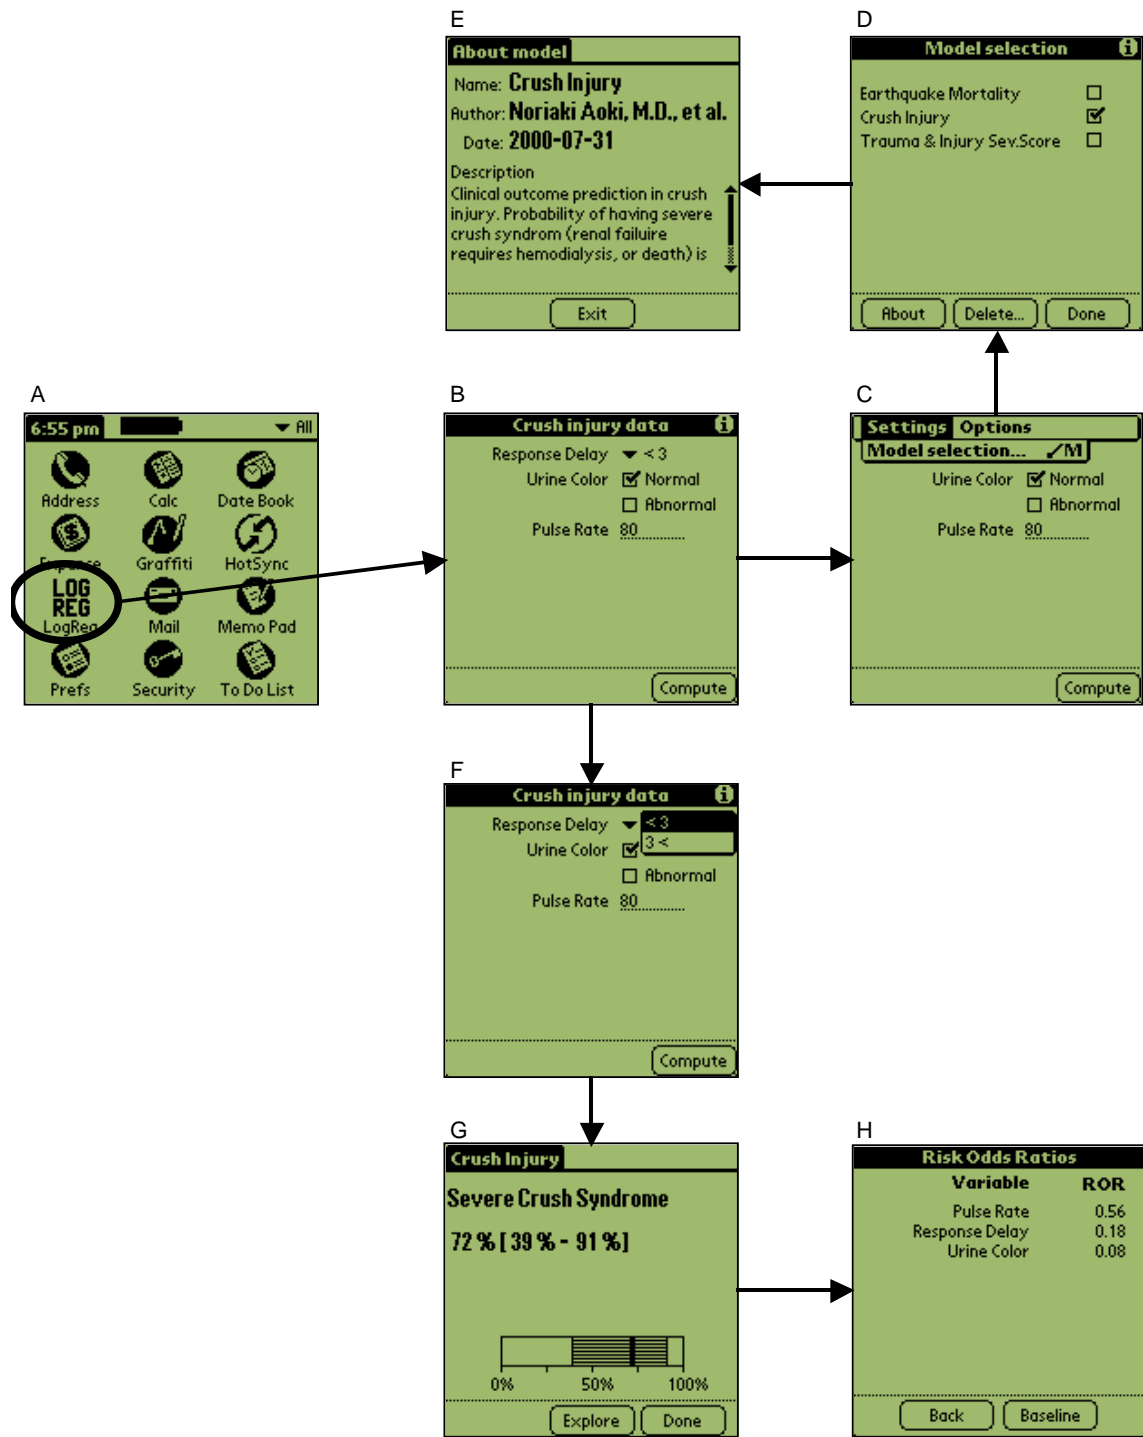
Podajamo dva primera uporabe dlančnika za podporo odločanju. Prvi primer uporablja model, ki so ga za potrebe podpore odločanja o pacientih z zmečkaninami pri naravnih nesrečah (potresih) razvili Aoki in sodelavci [2000]. Model je namenjen določitvi teže poškodbe, v pomoč pa naj bi bil osebu prve pomoči na področju naravne nesreče, ki ga ne sestavljajo zdravniki niti specialisti. Prav v takih situacijah, kjer gre za odločanje na terenu, bi podpora, ki jo lahko nudi dlančnik, bila zelo dobrodošla. Poleg modela Aokija in sodelavcev smo uporabo dlančnika preverili tudi z implementacijo znanega TRISS modela (Trauma and Injury Severity Score; [Champion in sod., 1981]) za določanje teže poškodb oseb, ki so prispele v travmatološko obravnavo s površinskimi oz. neubodnimi ranami. Aokijev model uporablja tri spremenljivke (srčni utrip, prisotnost nenormalne barve urina, zamuda pri reševanju), TRISS pa jih uporablja sedem (krvni tlak, hitrost dihanja, starost pacienta in dve oceni zdravnikov ob prihodu na urgentni blok: Glasgow Coma Scale in Injury Severity Score). V pričujočem članku podrobneje podajamo le vmesnik do modela Aokija in sodelavcev.

Nekateri od zaslonov in prehodov med njimi, s katerimi se sreča uporabnik sistema za podporo odločanja na dlančniku, so prikazani na sliki 2. Ob pritisku na ikono programa LogReg (slika 2.A) ta odpre okno zadnjič uporabljanega odločitvenega modela (slika 2.B, v našem primeru je to Aokijev model). V tem oknu lahko preko ustreznega menija (slika 2.C) pridemo do okna, v katerem nam LogReg izpiše vse modele, ki so trenutno na dlančniku (slika 2.D). Uporabnik lahko izpiše dodatne informacije o modelu (slika 2.E) ali pa izbere, kateri model želi uporabiti.

Vnos podatkov je enostaven in omogočen preko menijev (slika 2.F), gumbov ali pa z vpisom numerične vrednosti – odvisno od tipa spremenljivke in od tega, kako jo model uporablja. Snovatelj modela v XML datoteki, s katero ga popiše, določi, na kakšen način naj se vnos spremenljivke izvrši, LogReg pa sam na podlagi teh informacij določi, kako bo vmesnik za vpis podatkov dejansko izgledal.

Ko je uporabnik vpisal podatke, s pritiskom na gumb “Compute” sprožimo izračun verjetnosti izbranega izida na podlagi modela (v prikazanem primeru gre za verjetnost zelo hude poškodbe). Verjetnost se izpiše skupaj z mejama 95% intervala zaupanja, rezultate pa se tudi grafično ponazori (slika 2.G). Uporabnik se na tem mestu lahko še odloči, da razišče, kateri kriteriji so najbolj vplivali na podani izid (gumb “Explore”). S tem preide na naslednje okno, ki uredi kriterije glede na njihovo razmerje obetov tveganj (slika 2.H).





Slika 2 Uporabniški vmesnik programa LogReg na dlančnem računalniku PalmPilot

## 6. Zaključek

Predstavili smo postopek in program, ki omogočata uporabo lineranih logističnih modelov na dlančnih računalnikih. Osnovni predpostavki za uporabnost tovrstnega sistema sta naraščajoče število uporabnikov dlančnih računalnikov med zdravniki in specialisti ter obstoj množice modelov, objavljenih v medicinski literaturi, ki uporabljajo logistično regresijo. Naš sistem bi tovrstnim modelom omogočal, da bi presegli suhoparno objavo v revijah ter dejansko zaživel v klinični uporabi.

V času pisanja pričujočega prispevka se v sodelovanju z avtorji modela uporaba sistema preverja na področju napovedovanja teže poškodb, nastalih ob naravnih nesrečah [Aoki in sod., 2000]. V sodelovanju z Baylor College of Medicine v Houstonu in Sloan-Kettering Hospital v New Yorku pripravljamo modele, ki bodo delovali na dlančnikih in bodo namenjeni prognostiki raka na prostati pred in po operaciji oziroma radiološkem zdravljenju. Doma pa v povezavi z Oddelkom za Traumatologijo Kliničnega centra v Ljubljani in v sodelovanju z dr. Dragico Smrke, dr. med., oblikujemo modele, ki bodo na dlančniku služili za prognostiko in izbor terapij v kolčni protetiki.

## Literatura

- Aoki N, Pretto EA, Oda J, et al.: Clinical Outcome Predictors in Crush Injury: Mathematical Analysis of Data from the Hanshin-Awaji Earthquake. *Med Dec Mak*, 2000, submitted.
- Champion HR, Sacco WJ, Carnayyo AJ, et al.: Trauma score. *Crit Care Med* 9: 672, 1981.
- Harrell FE: *Regression modeling and validation strategies* [gradivo za udeležence predavanja]. Ljubljana 1998: Inštitut za biomedicinsko informatiko.
- Harrell FE: *How to present results of regression models to clinicians* [gradivo za udeležence predavanja]. Ljubljana 1999: Inštitut za biomedicinsko informatiko.
- Kattan MW, Eastham JA, Stapleton AMF, Wheeler TM, Scardino PT: A preoperative nomogram for disease recurrence following radical prostatectomy for prostate cancer. *J Natl Ca Inst* 1998; 90(10): 766-771.
- Kattan MW, Fearn P: Nomograms Web Page. <http://www.fearn.com/nomograms>, 2000.
- Kleinbaum DG: *Logistic regression: a self-learning text*. New York 1994: Springer.
- Myers JL, Well AD: *Research design and statistical analysis*. New York 1991: Harper Collins.

Piergorsch WW, Casella G: Confidence bands for logistic regression with restricted predictor variables. *Biometrics* 1988, 44 (3), 739-750.

Stare J: Regresijski modeli in linearnost. *Infor Med Slov* 1998; 5(1-2): 117-120.

### **Zahvala**

Projekt izdelave lupine za podporo odločanja na dlančnikih sta podprla Ministrstvo za znanost republike Slovenije (podpora programski skupini za Umetno inteligenco na FRI) in American Cancer Society (projekt "Prediction Methods for Prostate Cancer Progression"). Aplikacije in prispevka ne bi bilo brez nasvetov, ki so jih prijazno in potrpežljivo posredovali Aoki Noriaki, Michael M. Kattan, Begoña Campos Bonilla, Clint Cummins in Janez Stare.