

Matematické modely a zdravie verejnosti

Ciele kapitoly

Definície matematického modelu

Využitie matematických modelov vo verejnom zdravotníctve

Výhody a nevýhody využitia matematických modelov

Súhrn

Literatúra

Ciele kapitoly

V predchádzajúcich kapitolách sme hovorili o zdravotníckej štatistike a jej metódach, ktoré využívame pri štúdiu zdravia verejnosti. Vieme tiež, že zdravie a choroba nie sú dôsledkom pôsobenia iba jedného faktora, ale práve naopak, sú výsledkom spolupôsobenia komplexu faktorov. Aby sme svoje tvrdenia konkretizovali, môžeme sa krátko zamyslieť nad tým, čo ovplyvňuje vývoj úmrtnosti na kardiovaskulárne choroby. Iste nás ako prvý napadne nevhodný životný štýl. Štúdie poukazujú na to, že ak človek fajčí, nevenuje sa dostatočnej fyzickej aktivite, má zvýšenú hladinu cholesterolu v krvi v dôsledku nevhodnej stravy charakterizovanej okrem iného aj nedostatočnou konzumáciou zeleniny a ovocia, jeho riziko vzniku infarktu myokardu sa niekoľkonásobne zvyšuje. [1] Mohli by sme teda predpokladať, že práve tieto rizikové faktory by mohli vysvetľovať vývoj úmrtnosti na kardiovaskulárne choroby v čase (čím vyššia prevalencia rizikových faktorov, tým vyššia úmrtnosť). Avšak pri uvažovaní nesmieme zabudnúť na ďalšie faktory, ktoré tu môžu zohrať významnú úlohu. Základy teórie determinantov zdravia hovoria, že na zdravie a chorobu vplýva nielen životný štýl, ale aj životné prostredie, úroveň zdravotníckych služieb a biologické a genetické faktory. Je teda zrejmé, že do nášho uvažovania musíme zaradiť aj vplyv zdravotníckych služieb. Koľko ľudí podstupuje kardiochirurgické a kardiointervenčné zákroky? Koľko ľudí sa lieči liekmi, ktoré oddalujú úmrtie v dôsledku kardiovaskulárnych chorôb, ktoré by bez nich nastalo omnoho skôr? Taktiež sa musíme zamyslieť aj nad vplyvom sociálno-ekonomických determinantov zdravia. Naša úvaha nás dovedla k zisteniu, že nami skúmaný problém je skutočne dôsledkom komplexu determinantov. A môžeme uviesť aj iné príklady náročných otázok: Politikov zaujíma, aké výdavky bude potrebné pre nasledujúce obdobie vyčleniť na

zdravotníctvo. Riaditeľa nemocnice by mohlo zaujímať, približne koľko pacientov bude nutné hospitalizovať v období epidémie infekčného ochorenia. Ak chce verejný zdravotník presadiť implementáciu preventívneho opatrenia, mal by mať v rukách dôkaz o účinnosti tohto opatrenia. Inými slovami, mal by vedieť osobám oprávneným rozhodovať poskytnúť informácie o tom, čo by sa stalo, ak by intervencia bola, resp. nebola implementovaná, aké budú jej prínosy. Tradične využívanou metódou na skúmanie príčin vzniku ochorení a tiež účinnosti metód ich prevencie či liečby sú epidemiologické štúdie. Epidemiologické štúdie majú často neprekonateľné limity, vyplývajúce z etických, finančných alebo iných obmedzení ich realizácie. Niektoré z nich môžeme prekenuť využitím metodiky matematického modelovania.

Cieľom tejto kapitoly je poskytnúť čitateľovi základné informácie o matematických modeloch na teoretickej úrovni a ich využití vo verejnom zdravotníctve. Po preštudovaní tejto kapitoly bude čitateľ schopný pochopiť princípy modelovania biologických systémov, porozumieť štruktúre matematického modelu a bude taktiež vedieť popísať využitie viacerých známych matematických modelov

Definície matematického modelu

Pohľad do histórie

V roku 1766 uverejnil švajčiarsky matematik a fyzik Daniel Bernoulli (1700 – 1782) článok, v ktorom sa na žiadosť matematika Maupertuisa snažil zistiť, ako stúpne očakávaná dĺžka života vo Francúzsku po zavedení inokulácie (očkovania) proti pravým kiahňam. V Bernoulliho časoch totiž existovali rozpory medzi zástancami a odporcami očkovania proti pravým kiahňam. Diskutovalo sa o otázke, či má byť očkovanie zavedené, hoci má niekedy smrteľné následky. Išlo teda o to, akým spôsobom sa dajú porovnať potenciálne prínosy inokulácie v dlhodobom meradle s jej aktuálnymi rizikami. Bernoulli výpočtami zistil, že očkovanie proti pravým kiahňam je výhodné iba za predpokladu, že riziko smrti po tomto očkovaní je menšie ako 11 % a že očkovanie môže zvýšiť očakávanú dĺžku života o viac ako tri roky. Bernoulli je považovaný za tvorca prvého epidemiologického modelu pre infekčné choroby. [2, 3] Matematické modelovanie sa však naplno rozvinulo až v ére počítačov, keď bolo možné uskutočniť komplikované výpočty s vysokou presnosťou a rýchlosťou.

Matematické modely

Critchleyová a Capewell definujú model ako „zjednodušenie reality, ktoré varíruje od jednoduchých, popisných nástrojov (napríklad nákras domu) k systému matematických postupov, ktoré dokážu vysvetliť minulé vývoj výskytu chorôb alebo predikovať budúce udalosti, ako napríklad epidémie“ [4]. Weinstein definuje mate-

matický model ako „logický, matematický systém, ktorý umožňuje vkladanie faktov a hodnôt a ktorý spája tieto vstupné dáta do výsledkov, ktoré sú objektom záujmu osôb oprávnených rozhodovať v zdravotnej starostlivosti“. [5]

Iná definícia modelu hovorí, že model je „zjednodušenie reality, ktorého cieľom je pomôcť zodpovedať špecifické otázky“. [6]

Syntézou týchto definícií možno dôjsť k záveru, že modelovanie je prístup, ktorý využíva matematický jazyk a môže pomáhať pri skúmaní komplexných otázok v zdravotníctve v prípade, ak je použitý adekvátne a za predpokladu, že tvorcovia aj osoby, ktoré výsledky modelu použijú, si sú vedomí jeho limitov. Hoci model nedokáže „dať jednu správnu odpoveď“, jeho najvýznamnejšou úlohou je nasmerovať osoby oprávnené rozhodovať správnym smerom – ponúknuť možné riešenie. [6]

Regresné modely

Aby sme u čitateľa nevzbudili dojem, že model musí byť extrémne komplikovaný, spomenieme aj modely, ktoré v štúdiu zdravia verejnosti používame relatívne často. Pre nás najznámejšími modelmi budú pravdepodobne modely regresnej analýzy, spomedzi nich špeciálne lineárna regresia a logistická regresia. Oba typy regresíí sú detailne popísané a diskutované v publikácii o bioštatistike [7] a ďalších publikáciách venovaných štatistike. Podrobný popis týchto metód je preto nad rámec cieľov tejto kapitoly. Zopakujme len, že lineárna regresia popisuje vzťah (závislosť) medzi dvoma, resp. viacerými premennými. Na rozdiel od korelácie lineárna regresia umožňuje posunúť sa o krok vpred a zistiť ako jedna premenná, ktorú označíme závislá (Y), závisí od druhej (alebo viacerých) nezávislých premenných (X). Pre ilustráciu môžeme uviesť príklad vzťahu medzi úmrtnosťou v dôsledku nádoru pľúc a počtom predaných cigariet. Očakávali by sme, že tento vzťah bude pozitívny (so vzrastajúcim počtom predaných cigariet bude rásť aj úmrtnosť na nádor pľúc). Takto popísaný vzťah by sme potom mohli posunúť ďalej a mohli by sme sa opýtať, aká bude úmrtnosť na nádor pľúc, ak bude predaných napríklad 10 miliónov kusov cigariet. Toto je princíp regresie – vytvoríme z našich údajov model a ten používame na predikovanie hodnoty závislej premennej (úmrtnosti) pri zmene nezávislej premennej (počte predaných cigariet). V prípade lineárnej regresie ide o lineárny model, čo znamená, že cez naše údaje rozložené na roztrúsenom grafe (scatterplot) preložíme priamku, ktorá bude uložená tak, aby bola vzdialenosť medzi ňou a každým bodom na grafe čo najkratšia. Ako to urobíme? Je evidentné, že na to nemôžeme použiť intuíciu, pretože tá je často subjektívna. Preto je potrebné použiť matematický postup, ktorý sa nazýva metóda najmenších štvorcov. Takýmto spôsobom prídeme k priamke, ktorá najlepšie kryje údaje. Štatistické programy, ako aj programové prostredie $\{R\}$ dokážu vypočítať charakteristiky tejto priamky, ktoré potrebujeme poznať, a to: intercept – priesečník (a), t. j. bod, v ktorom priamka pretne os y v okamihu, keď premenná X bude mať hodnotu 0, a sklon priamky (b), ktorý hovorí,

akú hodnotu nadobudne premenná Y pri jednotkovej zmene premennej X . Model lineárnej regresie je charakterizovaný vzorcom:

$$Y_i = a + bX_i + \epsilon_i,$$

kde Y_i je hodnota závislej premennej, a je intercept, b je regresný koeficient charakterizujúci sklon priamky, X je hodnota nezávislej premennej a ϵ_i je chyba, ktorá reprezentuje rozdiel medzi hodnotou predikovanou priamkou a v skutočnosti pozorovanou hodnotou (niekedy tento vzorec býva prezentovaný bez chyby, avšak treba si uvedomiť, že práve hodnota chyby poukazuje na to, že odvodený vzťah nie je dokonalý – že ide v skutočnosti o model).

Ak teda máme údaje a vypočítali sme hodnoty regresných koeficientov (a) a (b), môžeme v regresnej rovnici dosadiť za nezávislú premennú akékoľvek číslo a predikovať tak hodnotu závislej premennej. Vytvorili sme model jednoduchej lineárnej regresie. Ako sme však už spomínali, v reálnom svete je veľmi málo javov dôsledkom iba jedného ovplyvňujúceho faktora. Preto aj model jednoduchej lineárnej regresie je značným zjednodušením reality. Je preto vhodnejšie rozšíriť tento model o ďalšie vysvetľujúce premenné (X_1, X_2, \dots, X_n) a vytvoriť tak model viacnásobnej lineárnej regresie.

V lineárnej regresii je podmienkou, že závislá premenná musí byť kvantitatívna spojité premenná. Čo však v prípade, že nás zaujíma závislá premenná, ktorá je kategorická (napríklad typu áno – nie)? Uvedme si príklad takéhoto problému. V súčasnosti, keď v rozvinutých krajinách sú jednými z najvýznamnejších ochorení kardiovaskulárne choroby, je dôležité, aby lekár presne vedel, kedy je vhodné začať pacienta liečiť. Musí zvážiť, aké je u pacienta riziko vzniku kardiovaskulárnej choroby (povedzme ischemickej choroby srdca ICHS) a tiež aj náklady, ktoré za liečbu vzniknú. Kľúčová je otázka, aká veľká je pravdepodobnosť pacienta ochorieť (ochorie alebo neochorie?). Ako lekár zistí túto pravdepodobnosť? V súčasnosti na to existujú nástroje, ktoré vznikajú na základe veľkých epidemiologických štúdií. Ak by sme mali (reprezentatívny) súbor ľudí s ICHS a bez, v ktorom by sme sledovali krvný tlak, výšku koncentrácie cholesterolu, fajčiarsky status, pohlavie a iné charakteristiky, vedeli by sme určiť faktory, ktoré u vybraných jedincov viedli k vzniku ICHS. Použitím logistickej regresie môžeme zistiť, že všetky vyššie uvedené faktory môžu viesť k vzniku ICHS (väčšinou vplyv týchto faktorov vyjadrujeme v logistickej regresii pomocou odds ratios). Avšak tento postup zároveň umožní predpovedať, akú pravdepodobnosť má jedinec mimo nášho súboru ochorieť na ICHS. Ak teda zmeriame jeho tlak, aktuálnu hladinu cholesterolu, opýtame sa ho, či fajčí, vieme jeho pohlavie a všetky tieto informácie vložíme do modelu logistickej regresie, vieme vypočítať pravdepodobnosť, s akou sa u daného jedinca vyskytne ICHS. Vidíme teda, že aj logistická regresia slúži ako matematický model.

Rozdelenie modelov

Prvým delením modelov je delenie na kvantitatívne a kvalitatívne. Kvalitatívne modely nie sú konštruované tak, aby priniesli informáciu vo forme čísel. Namiesto toho prinášajú náhľad na to, ako systém funguje a prečo vlastne existuje. Príkladom kvalitatívneho modelu môže byť napr. health belief model, ktorý sa využíva na popis správania človeka najmä pri plánovaní intervencií. Kvantitatívne modely možno nazvať aj matematické, pretože používajú jazyk a nástroje matematiky na popis správania systému. Ich výstupom sú numerické informácie.

Z časového hľadiska ich môžeme deliť na statické a dynamické. Statické modely poskytujú prierez situáciou vo vybranom časovom bode (prípadne dvoch bodoch). Ako také nezohľadňujú vplyv času na sledované premenné. Napriek tomu ich výsledky často postačujú a ich konštrukcia je jednoduchá. Dynamické modely, na rozdiel od statických, umožňujú zmenu premenných v čase. Vďaka komponentu času dynamické modely umožňujú simuláciu evolúcie sledovaného javu. Ich konštrukcia je však komplikovanejšia. [6]

Iné rozdelenie modelov delí modely na diskkrétne a kontinuálne. Diskkrétne modely umožňujú zmenu stavu (napr. fajčiar – bývalý fajčiar) iba v určitých časových úsekoch (napr. ročne). Kontinuálne modely naopak umožňujú tieto zmeny v ktoromkoľvek bode času.


Modely možno ďalej rozdeliť na mikro a makro simulácie. Makro simulácie rozlišujú skupiny (napríklad sociálno-ekonomické skupiny, skupiny rozdelené podľa pohlavia či príjmu). Na rozdiel od makro simulácií, ktoré pracujú s proporciami v skupine, mikro modely narábajú s individuálnymi charakteristikami. [8]

Podľa toho, ako zmena stavu nastáva, rozlišujeme modely deterministické a stochastické. Stochastické modely pracujú s náhodnými udalosťami a správaním. Deterministické modely sú také, kde sa udalosti a správanie dejú fixným a predvídateľným spôsobom. [6] Inými slovami, deterministický model po zadaní tých istých hodnôt vráti vždy tie isté výstupy, kým stochastický model v dôsledku vstupov, ktoré sú náhodné, vráti vždy iný výstup.

Postup tvorby modelu

Vo všeobecnosti postup tvorby matematického modelu zahŕňa niekoľko krokov. V prvom rade je potrebné definovať problém, o ktorý sa zaujímate. Následne si vyberieme vhodný typ modelu, určíme jeho základnú štruktúru a stanovíme vzťahy medzi vstupnými údajmi a výstupmi modelu (rečou matematiky). V tomto momente sa stávajú kľúčovými vstupné údaje, pretože ďalším krokom je práve ich zber, spracovanie a analýza. V tomto prípade si spomeňme na už spomínaný slogan „Garbage in, garbage out“, ktorý v tomto prípade znamená, že model bude iba taký kvalitný, ako kvalitné sú vstupné údaje. Tie sú kritickým bodom tvorby každého modelu, mnohokrát sú nedostupné a je potrebné vykonávať dodatočné štúdie, ktorými

sa tieto dáta získavajú, alebo sa spoľahnúť na odborné explicitné odhady. Ďalším krokom je validácia modelu – overenie, či model skutočne pracuje tak, ako chceme, aby pracoval. Model pracuje správne, ak jeho výstupy sú v súlade s historickými a empirickými zisteniami (ak napríklad chceme, aby model vysvetlil oddialené úmrtia a pridáme na to, že má byť vysvetlených povedzme 1 000 oddialených úmrtí, model bude validný vtedy, ak ich vysvetlí čo najviac). Pretože do modelov často vkládame údaje z rôznych zdrojov, ktoré majú často sekundárny charakter (tzn. neboli zbierané priamo pre potreby modelu), zanášame do neho chyby. Preto je potrebné vykonať analýzu senzitivity, ktorou si overujeme, ako sa výsledky modelu líšia, ak do neho vložíme rôzne hodnoty toho istého parametra. Príklad analýzy senzitivity vidíme na obrázku 1. Ide o analýzu senzitivity z modelu IMPACT, kde vidíme vplyv využitých liečebných metód a rizikových faktorov na pokles úmrtnosti na ICHS v Českej republike medzi rokmi 1985 – 2007. Vidíme, že najsilnejší vplyv na pokles úmrtnosti mal cholesterol v krvi. Zvislá čiara nereprezentuje konfidénčné intervaly ale výsledky analýzy senzitivity. Pri vkladaní rozličných hodnôt (dolný a horný extrém) priemernej hodnoty celkového cholesterolu v populácii vidíme, že model stále ukazuje, že najsilnejším faktorom je cholesterol. V analýze citlivosti si svoje poradie vplyvu neudržali napr. tlak krvi a fajčenie. [9] Ak model generuje približne rovnaké výsledky v rôznych podmienkach, označujeme ho za robustný. Poslednou fázou je vylepšovanie modelu, pretože tvorba modelu nie je len procesom hľadania odpovedí na nastolené otázky, ale aj proces učenia. [6, 8]



Obrázok 1 Analýza senzitivity v modeli IMPACT. Prevzaté z [9]

Využitie matematických modelov vo verejnom zdravotníctve

Matematické modelovanie má v oblasti zdravotníctva ako aj štúdia zdravia verejnosti široké využitie. Patrí sem:

-
- Odhadovanie potreby zdravotníckej starostlivosti v budúcnosti, optimalizácia poskytovania zdravotníckej starostlivosti,
 - znižovanie čakacích dôb a nedostupnosti zdravotnej starostlivosti,
 - skúmanie demografických vplyvov na zdravotný stav populácie,
 - pochopenie a kontrola šírenia infekčných chorôb (napríklad chrípky),
 - predpoveď výskytu chorôb v populácii v budúcnosti (napríklad diabetes mellitus, obezita),
 - vysvetlenie poklesu alebo nárastu incidencie či úmrtnosti na rôzne choroby,
 - vyjadrenie získaných rokov života, ušetrených finančných prostriedkov v dôsledku použitej intervencie alebo naopak, vyjadrenie negatívnych vplyvov zamýšľaného činu (napr. politiky).
-

Tabuľka 1 Využitie matematických modelov v zdravotníctve

Je vidieť, že matematické modely sú veľmi užitočný nástroj pri rozhodovaní. Náklady na zdravotnícku starostlivosť neustále rastú. V súvislosti s týmto faktom a tlakom na to, aby zdravotná starostlivosť poskytovala kvalitné služby, je stále viac potrebné, aby tvorcovia politík a osoby oprávnené rozhodovať vykonávali rozhodnutia založené na báze znalostí a nie iba náhodné rozhodnutia. Otázky, ktoré v zdravotnej starostlivosti vznikajú, sú natoľko komplexné, že nie je viac akceptovateľné spoliehať sa na intuíciu alebo náhodné odpovede. Matematické modelovanie sa preto stáva dôležitým v hľadaní solídnych, obhájiteľných a na dôkazoch založených odpovedí na tieto komplexné otázky. [6]

Na tomto mieste popíšeme niekoľko modelov, ktoré sa v praxi používajú, aby sme demonštrovali niektoré z tvrdení v tabuľke 1.

Metóda Monte Carlo

Metódou Monte Carlo³⁸ rozumieme súbor matematických postupov, ktoré využívajú náhodné čísla a pravdepodobnosť na riešenie problémov. Táto metóda má veľmi široké využitie od ekonómie cez fyziku až po štúdium zdravia verejnosti. Ide o stochastickú metódu, ktorá sa využíva najmä vtedy, keď deterministické prístupy nepostačujú na popis javov, ktoré sú silne ovplyvnené náhodnými vstupmi. Princíp metódy je jednoduchý: hľadáme strednú hodnotu (priemer, medián) veličiny,

³⁸ Názov je odvodený od mesta Monte Carlo, známeho svojimi kasínami a ruletou.

ktorá je výsledkom náhodného javu. Zo štatistiky vieme, že strednú hodnotu musíme počítať z viacerých vstupných údajov. Metóda Monte Carlo preto predpokladá, že vytvoríme model a opakujeme ho stovky či dokonca tisícky ráz, pričom vstupy budú generované náhodne v stanovenom reálnom rozsahu. Každé opakovanie prinesie požadovaný výstup, ktorý je dôsledkom vložených (náhodných) vstupov. Keď máme dostatočný počet opakovaní, vieme vypočítať strednú hodnotu, ako aj smerodajnú odchýlku a sme blízko k reálnemu výstupu, ktorý zohľadňuje neistoty, ktoré ho v reálnom svete ovplyvňujú. V oblasti zdravia verejnosti má metóda široké využitie. Monte Carlo bolo využité napríklad pri popise prenosu meticilín rezistentného *Stafylokoka aurea* (MRSA) medzi pacientmi na nemocničnom oddelení v závislosti od návykov zdravotníckeho pracovníka v oblasti hygieny rúk [10] alebo v zisťovaní vplyvu znečistenia ovzdušia na úmrtnosť a chorobnosť. [11]

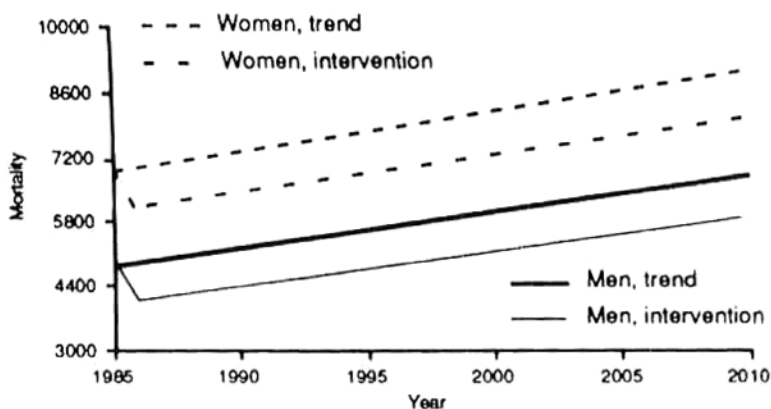
PREVENT

V 80. rokoch 20. storočia bol vyvinutý model **PREVENT**. [12, 13] Táto makrosimulácia odhaduje potenciálne prínosy (vo forme počtu odvrátených úmrtí a počtu získaných rokov života) vyplývajúce z primárnej prevencie – znižovania prevalencie rizikových faktorov chronických chorôb v populácii. Použitím tohto modelu možno porovnať, ako by sa vyvíjal napríklad trend úmrtnosti na zvolenú skupinu ochorení, ak sa preventívnymi opatreniami dosiahla redukcia v prevalencii rizikových faktorov s prípadom, že preventívne opatrenia by sa nevykonali vôbec. Výhody modelu možno zosumarizovať takto: zohľadňuje demografické zmeny a umožňuje simulácie v dlhých časových obdobiach, zahŕňa klasické rizikové faktory a rôzne skupiny chronických chorôb, je user-friendly (vyznačuje sa jednoduchým používaním), nové verzie zahŕňajú aj vyčíslovanie nákladov a odhady chorobnosti na sledované choroby. Negatíva vyplývajú z architektúry modelu, pridanie nového rizikového faktoru je veľmi náročné [4]. Model PREVENT sa stále široko používa. Nedávno bol použitý napríklad v projekte EUROCADET,³⁹ v ktorom sa odhadovala budúca incidencia nádorových ochorení v prípade implementácie intervencií. Ďalej bol PREVENT využitý v projekte EPIDERM,⁴⁰ kde bol model použitý na odhadnutie potenciálneho vplyvu intervencií zameraných na redukciu UV žiarenia na incidencia nádoru kože v piatich európskych krajinách. [14] Aktuálne bol model použitý na odhad toho, ako efektívny bude projekt v Severnom Írsku⁴¹ zameraný na skultivovanie prostredia, vybudovanie parku a cyklistických trás v meste v zvyšovaní fyzickej aktivity obyvateľov mesta. [15]

³⁹ <http://www.eurocadet.org/objective-3.html#note>

⁴⁰ <http://www.epiderm-network.eu/home.html>

⁴¹ <http://www.communitygreenway.co.uk/project/about-connswater-community-greenway>



Obrázok 2 Počet úmrtí v dôsledku cievnych mozgových príhod, ktoré by sa vyskytli za predpokladu že by bola alebo nebola vykonaná intervencia smerovaná na boj proti hypertenzii podľa modelu PREVENT. Prevzaté z [13].

Model IMPACT

Deterministický **model IMPACT**, ktorý vysvetľuje príčiny poklesu, resp. vzostupu v úmrtnosti na ischemické choroby srdca je založený na funkciách programu Excel. Model berie do úvahy výskyt rizikových faktorov ICHS v populácii a tiež užívanie na dôkazoch založených liečebných metód ICHS a kvantifikuje účinok, ktorým sa podieľajú na znižovaní (alebo zvyšovaní) úmrtnosti za stanovené obdobie. Na základe počtu úmrtí v dôsledku ICHS a veľkosti populácie v začiatčnom a konečnom roku sledovania sa stanoví počet úmrtí, ktoré by sa mali vyskytnúť v konečnom roku sledovania, ak by pretrvala úmrtnosť zo začiatčného roku sledovania. Tento počet sa však nevyskytol, pretože úmrtnosť poklesla a počet úmrtí v skutočnosti pozorovaných je odrátaný od očakávaných počtov úmrtí. Výsledkom tohto rozdielu sú „deaths prevented or postponed (zachránené životy a oddialené úmrtia) (DPPs)“. Práve získaný počet DPPs má potom model za úlohu vysvetliť. Ako sme spomenuli vyššie, model pracuje s dvoma skupinami vysvetľujúcich faktorov: prevalenciou rizikových faktorov a používaním liečebných metód. Z rizikových faktorov ICHS pracuje model s prevalenciou fajčenia, so strednými hodnotami koncentrácie celkového cholesterolu, body mass indexu (BMI), systolického tlaku krvi, prevalenciou fyzickej inaktivity a diabetu. Model ďalej pracuje s deviatimi kategóriami pacientov (napr. pacienti hospitalizovaní s akútnym infarktomyokardu, pacienti žijúci s chronickým srdcovým zlyhávaním a podobne). [12] Model IMPACT bol vyvinutý v roku 1996 [16] a odvtedy bol základný model vybudovaný v 19 štátoch. Výsledky modelu poukazujú na fakt, že pokles úmrtnosti na ICHS je z väčšej čas-

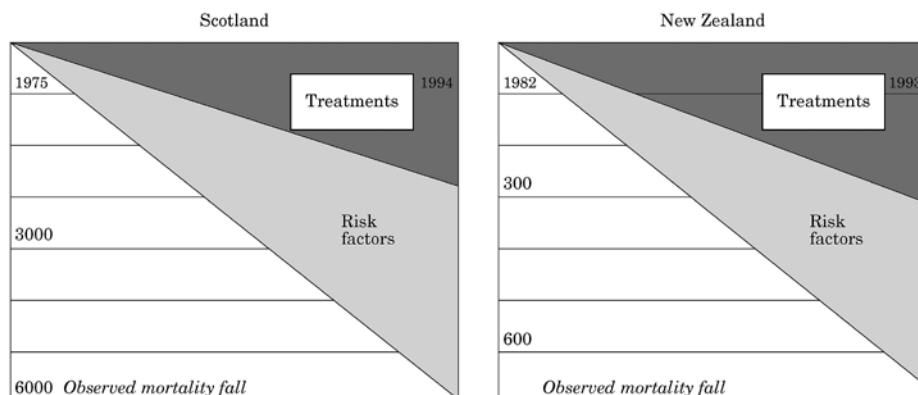


Figure 3 Declines in coronary heart disease mortality in Scotland 1975–94 and in New Zealand 1982–93: Estimated contribution of medical treatments and risk factor reductions^{338,391}.

| | | | |
|-------------------------------|------------------------|-------------------------------|------------------------|
| Scotland | | New Zealand | |
| Total treatments 40% | Total risk factors 60% | Total treatments 46% | Total risk factors 54% |
| AMI treatments 10% | Smoking 36% | AMI treatments 12% | Smoking 30% |
| Angina (revascularization) 2% | Cholesterol 6% | Angina (revascularization) 4% | Cholesterol 12% |
| Angina (aspirin) 2% | Population BP (15%)* | Angina (aspirin) 3% | Population BP (11%)* |
| Heart failure 8% | Deprivation 3% | Heart failure 7% | Deprivation — N/A |
| Hypertension treatment 9% | Other factors 9% | Hypertension treatment 7% | Other factors 4% |
| Secondary prevention 8% | | Secondary prevention 12% | |

*Population blood pressure includes the effect of treatment of individuals for hypertension

Obrázok 3 Výsledky modelu IMPACT v Škótsku a na Novom Zélande. Prevzaté z [4]

ti spôsobený zmenami v prevalencii modifikovateľných rizikových faktoroch a využívaníu na dôkazoch založených liečebných metód. Týmto skutočnostiam možno pripísať 23 – 47 % pozorovaného poklesu mortality. Tieto výsledky sú mimoriadne dôležité pre plánovanie stratégií boja proti kardiovaskulárnym chorobám. Príklad výsledkov modelu IMPACT je uvedený na obrázku 3. Vidíme, že v sledovanom období došlo v oboch krajinách k poklesu úmrtnosti na ICHS, čo sa prejavilo v príslušnom počte DPPs. V Škótsku možno 60 % tohto poklesu pripísať poklesu prevalence v rizikových faktoroch a približne 40 % možno pripísať liečebným metódam. Na Novom Zélande možno 54 % DPPs vysvetliť zmenami v prevalencii rizikových faktorov a 46 % poklesu možno pripísať liečebným metódam. [4]

Výhody a nevýhody využitia matematických modelov

Niekedy sú pred verejným zdravotníkom také komplikované otázky, že využitie klasických epidemiologických štúdií by bolo veľmi náročné, ak nie nemožné (spomeňme si na Bernoulliho problém). Modelovanie umožňuje preklenúť limity epidemiologických štúdií, medzi ktoré možno zaradiť nasledujúce skutočnosti [4]:

- Demografické limity – len málo epidemiologických štúdií zahŕňa medzi participantmi adekvátnu proporciu žien, etnických menšín alebo starších ľudí. Takéto skupiny však môžu byť zahrnuté do modelu vykonaním explicitného odhadu o riziku v týchto skupinách.
- Metodologické limity – epidemiologické štúdie, ak majú byť dostatočne silné, sú náročné na čas, náklady a vždy hrozí potenciálne riziko biasu. Napríklad aj výsledky randomizovaných kontrolovaných trialov sa dajú ťažko zovšeobecniť na celú populáciu. Táto skutočnosť je dôsledkom prísnych zaraďovacích kritérií pre participantov v trialoch. Modely môžu pomôcť zhodnotiť význam takýchto biasov, a to napríklad prenesením výsledkov z trialov do skutočnej, všeobecnej populácie.
- Limity vyplývajúce z dát – modely môžu pomôcť pri skúmaní potenciálneho významu faktorov, kde dôkazy nie sú dostatočné alebo chýbajú úplne.
- Limity vyplývajúce z komplexnosti vplyvov – modely môžu pomôcť porovnať potenciálne benefity viacerých prístupov a umožniť tak tvorcom politik a osobám oprávneným rozhodovať identifikovať prioritné oblasti výskumu.

Okrem toho za silnú stránku modelov sa považuje aj fakt, že modely sú schopné kombinovať dáta z rôznych zdrojov a disciplín, a tak prispieť k vytvoreniu „celkového obrazu“ sledovaného javu. Modely je výhodné použiť aj vtedy, keď nie je reálne možné vykonať mnoho experimentov na zistenie hodnoty veličiny, ktorá je objektom nášho záujmu (spomeňme si na metódu Monte Carlo). Nevýhodou modelovania je fakt, že jeho výsledky sú silne závislé od kvality vstupných dát. Ďalšou slabou stránkou modelov sú predpoklady, ktoré treba urobiť pri ich tvorbe v prípade, že vstupné údaje nie sú dostupné. Inou potenciálnou nevýhodou je skutočnosť, že tí, ktorým sú výsledky modelu určené – osoby oprávnené rozhodovať, manažéri a tvorcovia politik – môžu mať ťažkosti s pochopením fungovania matematických modelov, a preto môžu byť náchylní nedôverovať ich výsledkom.

Súhrn

V kapitole sme diskutovali o matematických modeloch a ich využití v skúmaní zdravia verejnosti. Definovali sme model a zaoberali sme sa rôznymi aspektmi delenia modelov. Povedali sme si, že matematické modely môžu variovať od jednoduchších, známych modelov, ako napr. regresné analýzy, až po komplikované modely, ktorých tvorba si vyžaduje hlboké znalosti z oblasti riešeného problému, ako aj znalosť pokročilého matematického aparátu. Zistili sme, že modely sú účinným nástrojom pri manažmente zdravotníckej starostlivosti a ich použitie umožňuje vykonávať rozhodnutia založené na dôkazoch, nie iba náhodné rozhodnutia. Predstavili sme si niektoré známe modely a metódu Monte Carlo. Pri porovnávaní výhod a limi-

tov modelov sme došli k záveru, že modely môžu vyplniť medzery o vedomostiach a kombinovať dáta z rôznych zdrojov do jedného celku. V porovnaní s epidemiologickými štúdiami (najmä drahými kohortovými štúdiami) je modelovanie lacnejšou a rýchlejšou alternatívou. Avšak pri ich použití si musíme byť vedomí ich limitov.

Literatúra

1. Yusuf, S. et al. *Effect of potentially modifiable risk factors associated with myocardial infarction in 52 countries (the INTERHEART study): case-control study*. Lancet, 2004. **364**(9438): p. 937 – 952.
2. Dietz, K. and Heesterbeek, J. A. P. *Daniel Bernoulli's epidemiological model revisited*. Mathematical Biosciences, 2002. **180**: p. 1 – 21.
3. Bacaër, N. *Daniel Bernoulli, d'Alembert and the inoculation of smallpox (1760)*, in *A Short History of Mathematical Population Dynamics*. 2011, Springer London. p. 21 – 30.
4. Critchley, J. A. and Capewell, S. *Why model coronary heart disease?* European Heart Journal, 2002. **23**(2): p. 110 – 116.
5. Weinstein, M. C. et al. *Principles of good practice for decision analytic modeling in health-care evaluation: Report of the ISPOR task force on good research practices-modeling studies*. Value in Health, 2003. **6**(1): p. 9 – 17.
6. The Complex Systems Modelling Group, *Modelling in Healthcare*. 2010, Providence, Rhode Island: American Mathematical Society.
7. Rusnák, M., Rusnáková, V., and Majdan, M., *Bioštatistika pre študentov verejného zdravotníctva*. 2010, Trnava: Typi Universitatis Tyrnaviensis – Vydavateľstvo Trnavskej univerzity.
8. Levy, D. T. et al. *Simulation models of obesity: a review of the literature and implications for research and policy*. Obesity Reviews, 2011. **12**(5): p. 378 – 394.
9. Bruthans, J. et al. *Explaining the decline in coronary heart disease mortality in the Czech Republic between 1985 and 2007*. European Journal Of Preventive Cardiology, 2012.
10. Beggs, C., Shepherd, S. and Kerr, K. *How does healthcare worker hand hygiene behaviour impact upon the transmission of MRSA between patients?: an analysis using a Monte Carlo model*. BMC Infectious Diseases, 2009. **9**(1): p. 64.
11. MacDonald Gibson, J. et al. *Deaths and Medical Visits Attributable to Environmental Pollution in the United Arab Emirates*. Plos One, 2013. **8**(3): p. e57536.
12. Unal, B., Capewell, S. and Critchley, J. *Coronary Heart Disease Policy Models: a systematic review* BMC Public Health, 2006. **6**(1): p. 213.
13. Gunning-Schepers, L. J., Barendregt, J. J. M. and van der Maas, P. J. *PREVENT, a Model to Estimate the Health Benefits of Prevention*, in *Models of Noncommunicable Diseases. Health status and Health Service Requirements*, W. Morgenstern, et al., Editors. 1992, Springer – Verlag: Berlin. p. 55 – 69.
14. de Vries, E. et al. *Potential impact of interventions resulting in reduced exposure to ultraviolet (UV) radiation (UVA and UVB) on skin cancer incidence in four European countries, 2010 – 2050*. British Journal of Dermatology, 2012. **167**: p. 53 – 62.
15. Dallat, M. A. T. et al. *Urban greenways have the potential to increase physical activity levels cost-effectively*. The European Journal of Public Health, 2013.
16. Capewell, S., Morrison, C. E. and McMurray, J. J. *Contribution of modern cardiovascular treatment and risk factor changes to the decline in coronary heart disease mortality in Scotland between 1975 and 1994*. Heart, 1999. **81**(4): p. 380 – 386.