


a pochopit základní rozhodovací proces. Dalšími důležitými aspekty jsou zkreslení a zobecnění. Modely strojového učení do značné míry závisí na kvalitě a reprezentativnosti trénovacích dat. Pokud jsou data použita pro trénink zkreslená nebo nereprezentují celé spektrum populací pacientů, může výsledný skórovací systém vykazovat zkreslené předpovědi. Pro řešení těchto problémů je zásadní zajistit rozmanitost a inkluzivitu trénovacích dat.

Přesnost modelů

Hodnocení přesnosti mortalitních modelů a jejich srovnávání není jednoduchou záležitostí. Mortaltní modely vznikaly ve specifických geografických oblastech a pro jejich použití na např. na jiném kontinentu je nutná kalibrace [13]. Rovněž byl z databází pro tvorbu skórovacích systémů velmi často vyřazeny specifické skupiny pacientů (nemocní s popáleninami, mladší 18 let, starší 90 let, nemocní s velmi krátkým pobytem na JIP apod.), pro něž nemusí být aplikace skórovacích modelů nyní dostatečně přesná [14]. Důležitou problematikou je také otázka sběru dat. Data byla shromažďována na vybraných JIP, jejichž zavedené terapeutické postupy nemusí plně odpovídat běžné praxi. Rozdílná spolehlivost dat byla zaznamenána i v případě manuálního zadávání proměnných ve srovnání s automatizovaným sběrem parametrů [16, 17]. Hodnocení statistické metodiky použité k posouzení kalibrace prediktivního modelu, která také může být zdrojem nepřesnosti je nad rámec tohoto sdělení. Jednoduché srovnání výkonnosti v odhadu nemocniční mortality nejčastějších modelů dle plochy pod křivkou (AUROC) v době svého publikování přináší tabulka 1. Obecně platí, že za dobrou diskriminační schopnost je vnímána hodnota AUROC vyšší než 0,8, hodnoty nad 0,9 jsou považovány za vynikající. Schopnost predikce mortality pomocí skóre qSOFA či SIRS dosahující v tabulce nejnižších hodnot je ospravedlnitelná tím, že žádný z těchto modelů nebyl k tomuto účelu navržen. Nápadným trendem je zastoupení a rozvoj modelů

Tab. 1. Porovnání jednotlivých prediktivních modelů v odhadu nemocniční mortality v době svého publikování dle AUC (area under curve)



založených na strojovém učení (v tabulce v odstínech zelené). Přesto je však logistická regrese nadále vnímána jako dostatečně konkurenceschopná statistická metoda pro tvorbu nových moderních skórovacích systémů [18].

Kvalifikovaný odhad

Prognostifikace a provádění komplikovaných medicínských rozhodnutí je rutinní součástí práce každého intenzivisty. Tyto kvalifikované odhady také rovněž očekává a do značné míry na ně spoléhá jak samotný ne-

Tab. 2. Porovnání parametrů nejpoužívanějších prognostických modelů

	APACHE	SAPS	APACHE II	MPM	APACHE III	SAPS 2	MPM II	SAPS 3	APACHE IV	MPM III
Charakteristika										
Rok	1981	1984	1985	1985	1991	1993	1993	2005	2006	2007
Počet zemí	1	1	1	1	1	12	12	35	1	1
Počet JIP	2	8	13	1	40	137	140	303	104	135
Pacienti	705	679	5 815	2 783	17 440	12 997	19 124	16 784	110 558	124 855
Způsob vytvoření	Panel expertů	Panel expertů	Panel expertů	Mnohočetná logistická regrese	Mnohočetná logistická regrese	Mnohočetná logistická regrese	Mnohočetná logistická regrese	Mnohočetná logistická regrese	Mnohočetná logistická regrese	Mnohočetná logistická regrese
Proměnné										
Věk	Ne	Ano	Ano	Ano	Ano	Ano	Ano	Ano	Ano	Ano
Etiologie	Ne	Ne	Ne	Ne	Ano	Ne	Ne	Ano	Ano	Ne
Komorbidity	Ano	Ne	Ano	Ano	Ano	Ano	Ano	Ano	Ano	Ano
Fyziologické proměnné	Ano	Ano	Ano	Ano	Ano	Ano	Ano	Ano	Ano	Ano
Akutnost diagnózy	Ne	Ne	Ano	Ne	Ano	Ne	Ano	Ano	Ano	Ano
Počet proměnných	34	14	17	11	26	17	15	20	142	16
Predikce mortality	Ne	Ne	Ano	Ano	Ano	Ano	Ano	Ano	Ano	Ano

Adaptováno z [14]