

Rozhodování strojů a za pomoci strojů (UI)

Martin Gaier¹, Martin Janoch²

Střední průmyslová škola elektrotechnická, Havířov¹

Gymnázium Omská, Praha²

m.gaier@seznam.cz¹, janochmartin@seznam.cz²

Abstrakt

Tento velice zajímavý projekt se zabývá vytvořením Bayesovské sítě, která na základě výstupních dat předpovídá konfiguraci vstupních parametrů. Měřili jsme čas a vzdálenost pohybu míčku spuštěného z nakloněné roviny s různými typy míčků, povrchů, nastavení rampy a v různých povětrnostních podmínkách. Data byla vložena do námi vytvořené sítě, čímž jsme naučili její parametry. Takto naučená síť byla otestována. Z naměřené vzdálenosti a času získaných z testovacích dat jsme určili pravděpodobnosti počátečních konfigurací. Shrnutí nabízí detailní přehled výsledků.

1 Úvod

V běžném životě jsou všechna naše rozhodnutí ovlivněna mnoha faktory, které obvykle nabývají různých náhodných stavů. Motivace převést tyto reálné situace do počítačových systémů je velká. Cílem tohoto projektu bylo využití Bayesovské sítě pro odvození parametrů modelu reálného experimentu z námi naměřených hodnot. Konkrétně šlo o pokusy s míčky různých typů, barev a velikostí, které jsme s pomocí různě nakloněné roviny uvedli do pohybu. Míčky se dále pohybovaly po různých podložkách, které se lišily materiálem s rozdílnými vlastnostmi, a díky tomu bylo možné různě kombinovat parametry, čímž bylo možné získat různá nastavení experimentu. Svou roli sehrály i povětrnostní podmínky.

2 Model sítě

Bayesovská síť je struktura podmíněné nezávislosti. Vychází ze vztahu opačné podmíněné pravděpodobnosti, který udává Bayesův vzorec.

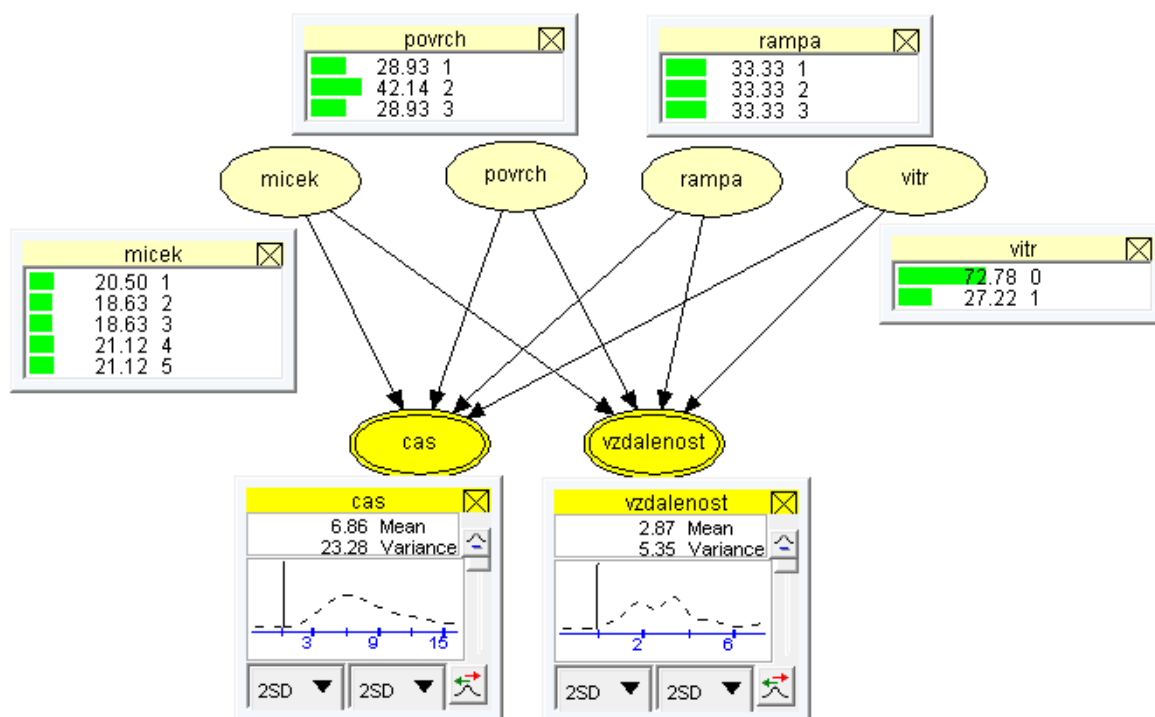
$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

Chceme-li vypočítat neznámou pravděpodobnost A podmíněno B, můžeme k tomu využít opačné podmíněné pravděpodobnosti. Díky tomu lze prohodit příčinu a důsledek (např. pokud chceme určit pravděpodobnou příčinu pádu letadla, použijeme k tomu známé podmíněné pravděpodobnosti pádu z důvodu selhání jednotlivých součástí).

K pokusu jsme využili řadu proměnných: typ míčku, povrch, náklon rampy a vliv prostředí. Na těchto proměnných byly závislé hodnoty času a uražené vzdálenosti. Výčet proměnných znázorňuje tabulka 1.

Míčky	Povrchy	Rampy	Vítr
Hopík	Koberec	Malý náklon	Aktivní
Skvošovák	Asfalt	Střední náklon	Neaktivní
Rachoťák	Dlaždice	Velký náklon	-
Basebalový	-	-	-
Tenisák	-	-	-

Tabulka 1: Stavby proměnných

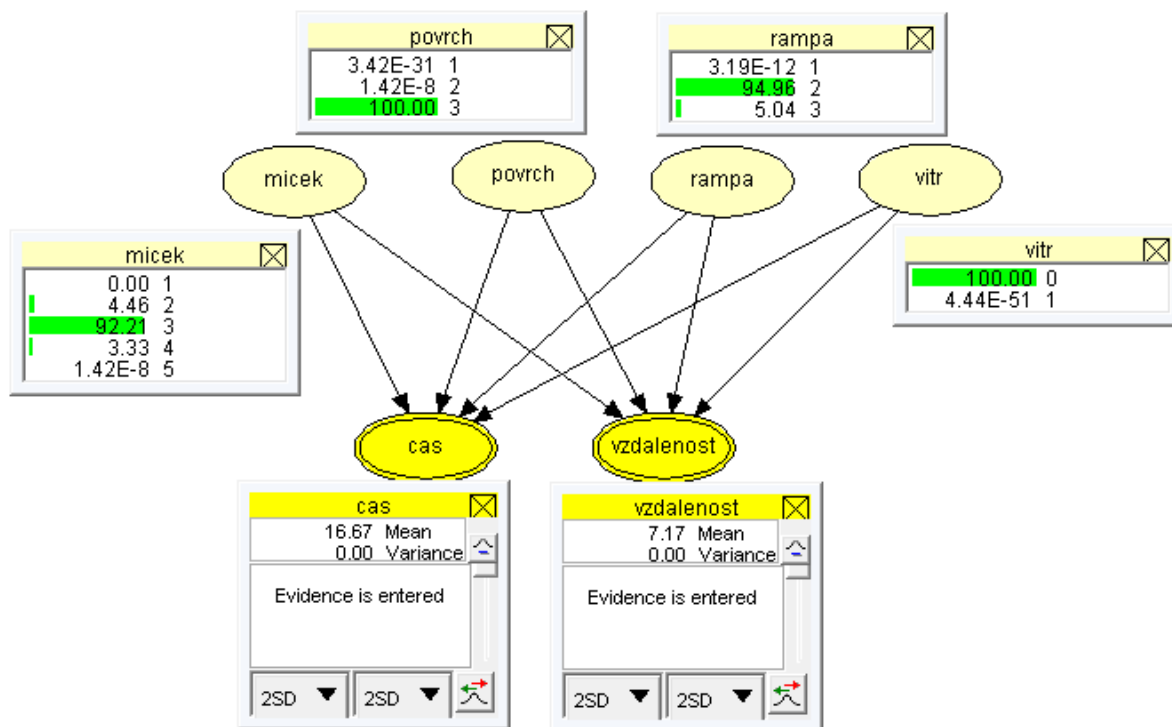


Obrázek 1: Model sítě

Naměřená data byla zanesena do tabulkového procesoru a exportována do programu Hugin Researcher [1]. Na základě předpokládaných vztahů jednotlivých veličin byl v tomto programu vytvořen model Bayesovské sítě, který je zobrazen na obrázku 1. Model znázorňuje souvislosti mezi proměnnými. Tento model jsme pomocí 156 pokusných měření s využitím EM algoritmu naučili jeho parametry. Takto naučený model chceme využít pro vyvození pravděpodobného nastavení parametrů (míček, povrch, rampa, vítr) ze dvou známých veličin (čas, vzdálenosti)

K otestování kvality sítě jsme využili 42 pokusných měření, která nebyla využita EM algoritmem k učení sítě. Při vložení naměřených hodnot do některých proměnných, program přepočítá pravděpodobnosti výskytu ostatních. Této funkce jsme využili zadáním proměnných času a vzdálenosti, pro zjištění ostatních parametrů jednotlivých měření.

Odhady modelu byly porovnány s reálnými testovanými údaji. Díky tomuto jsme schopni vypočítat přesnost odhadu u jednotlivých proměnných. Pro názornost uvádíme přesná data v tabulce 2. Nejvyšší úspěšnost byla zaznamenána u větru, kde se nám podařilo dosáhnout absolutní shody, tj. 100%. Naopak nejnižší byla schopnost detekovat jednotlivé míčky, což přikládáme velké podobnosti jejich vlastností. Jejich odlišnost by se zřejmě projevila při nasbírání většího množství dat. Velmi vysoká byla rovněž schop-



Obrázek 2: Vkládání dat do modelu

Míčky	Povrchy	Rampy	Vítr
33%	83%	61%	100%

Tabulka 2: Úspěšnost odhadu proměnných

nost rozpoznat terén. Příkladáme to rozmanitosti jednotlivých povrchů. Střední a vysoký náklon rampy měl na počáteční rychlost míčku podobný vliv, tudíž byla procentuální úspěšnost snížena na 61%. Úspěšnost správného odvození pro každou neznámou činí 69%.

Z důvodu časové náročnosti získávání dat bohužel nebylo možné nashromáždit větší množství případů, což by pravděpodobně zlepšilo funkci sítě. Dále mohla hrát roli nepřesnost měření a povětrnostní podmínky. I když není procentuální úspěšnost nejvyšší, model prokazuje dostatečnou přesnost výpočtu pravděpodobnosti i za ztížených podmínkách.

3 Shrnutí

Podařilo se vytvořit plně funkční prototyp Bayesovské sítě, který splnil požadavky tohoto experimentu. Funkční model odvozoval námi naměřené hodnoty z adekvátní přesností. Výsledkem naší práce je 156 pokusů, jejichž výsledky byly použity pro učení sítě a dalších 42 pro její otestování. Úspěšnost správného určení proměnné byla 69%. Síť lze i nadále vylepšovat, a tudíž zvyšovat její přesnost.

Poděkování

Není možné slovy dostatečně ocenit pomoc ze strany Ing. Martina Plajnera, který celý projekt usměrňoval a vedl nás ke zdárnému výsledku. Děkujeme mu za prohloubení našich znalostí, ale i za poskytnutí laboratorních prostor a nástrojů pro experiment.

Reference

- [1] Hugin Expert. *HUGIN Researcher Software*. <http://www.hugin.com/index.php>. 2015 [cit: 16-06-2015].
- [2] Hugin Expert. *Stud Farm Example*. <http://www.hugin.com/technology/samples/stud-farm>. 2015 [cit: 16-06-2015].
- [3] J. Vomlel. *Uvod do Bayesovskych siti*. <http://staff.utia.cas.cz/vomlel/slides/presentace-medic-info-new-1250.pdf>. 2008 [cit: 16-06-2015].
- [4] *Bayesova věta*. http://www.wikiskripta.eu/index.php/Bayesova_v%C4%9Bta. 2015 [cit: 16-06-2015].