

ZÁKLADY GNOSTICKÉ TEORIE DAT

P. Kovanic

SOUHRN

Gnostická teorie dat je pokusem o matematický model poznávání kvantitativních vlastností světa na působení neurčitosti, o které není známo, zde vyhovuje statistickým předpokladům. Z jediného axioma se dokazují významné zákonitosti jednotlivých dat, z nichž lze za použití druhého axioma odvodit vlastnosti datových souborů a jejich charakteristiky použitelné k robustnímu odhadování polohy, měřítka i distribučních funkcí datových souborů, k testování homogenity souborů apod.

MATEMATICKÁ DATA VERSUS REÁLNÁ DATA

Statistická teorie je vybudována pro data generovaná myšlenými matematicko-statistickými modely, nebo pro data podle těchto modelů vypočtená, či fyzikálně sestrojená tak, aby vlastnosti dat dobré approximovaly vlastnosti matematicky definovaných dat. Praktická použitelnost statistických metod je pak podmíněna shodou vlastností skutečných dat s teoretickými. Takovou shodu často nelze zaručit, dokonce někdy ani rozpoznat pro nedostatečné množství dat, proměnnost situací, nestacionarnost atp. Nemůžeme-li ale přisoudit datům statistické vlastnosti a přesto potřebujeme vybudovat teorii vedoucí k metodám použitelným pro spracování dat, musíme najít jejich jinou důležitou vlastnost, z níž lze teorii odvodit: Reálná data přijímaná za základ gnostické teorie jsou výsledky buď měření nebo čítání reálných kvantit. Z teorie měření vyplývá, že tato data jsou striktně kladná a konečná. V praxi se setkáváme i s daty, která byla získána dodatečnou transformací výsledků měření nebo čítání, mají např. posunutou nulu ap. Ta musí být před dosazením do gnostických vzorců transformována do požadované primární formy.

GNOSTICKÁ TEORIE JEDNOTLIVÝCH DAT

První axiom a jeho důsledky pro teorii kvantifikace

Shrnuje stručně gnostickou teorii jednotlivých dat dle /1/, kde jsou uvedeny přesnější formulace tvrzení i s důkazy. Nechť "z" je skutečný výsledek kvantifikace, tj. měření nebo čítání, vyjádřený číslem a nechť " z_0 " je (ideální) hodnota, kterou bychom dostali jako výsledek kvantifikace, kdyby byl proces kvantifikace zbaven jakékoli neurčitosti. První axiom gnostické teorie pak charakterizuje model reálných dat takto:

$$z = z_0 \xi \quad (z, z_0, \xi \in \mathbb{R}_+)$$

/1/

Snadno zjistíme, že množina transformací zobrazujících jakoukoliv datovou položku tvaru /1/ na sebe či najinou položku dat, lišící se pouze parametrem ξ charakterizujícím vliv neurčitosti tvoří komutativní grupu, jejíž strukturní operaci je násobení operátorů. Veličina "z" dle /1/ je však bilineární funkce proměnných z_0 a ξ . Základna proměnných

$$x = z_0 \text{ch} \Omega \quad y = z_0 \text{sh} \Omega \quad / \text{kde } \Omega = \ln \xi / \quad /2/$$

pak dává možnost přiřadit každé položce dat (z) typu /1/ dvourozměrový vektor $y^T := (x, y)^T$ a také $x^T := (y, x)^T$, přičemž $z = x + y$. Pro nezávislost z_0 ani ξ nedovedeme takový rozklad dat uskutečnit, ale jeho teoretický tvar nám dovoluje odvozovat důležité závěry. Především zjištujeme, že množina matic K zobrazujících vektory typu y na sebe nebo najiné y' , tvoří komutativní grupu, jejíž strukturní operaci je běžné maticové násobení. Tato grupa je izomorfni jednak s grupou operátorů ξ na \mathbb{R}_+ a jednak s grupou Lorentzových transformací na dvourozměrné varietě vektorů. Lze dokázat, že metriku na této varietě nemůžeme libovolně zadat, ta je již určena, neboť jediná metrika invariantní k Lorentzovým transformacím je pseudoeuklidovská metrika. Jako důsledek prvního axioma tedy dostáváme, že vliv kvantifikační neurčitosti na reálná data lze matematicky modelovat jako ortogonální rotaci vektorů v Minkowské rovině,

při níž se body reprezentující reálná data pohybují po pseudoeuklidovské kružnici, tj. po euklidovské hyperbole. Relativní délka dráhy tohoto pohybu může tedy být snadno vyčíslena, je rovna veličině $|z_0|$ o níž se snadno přesvědčíme, že vyhovuje jednoduchému variacionnímu principu: je to maximum z možných relativních délek drah pohybů mezi zadánymi koncovými body po různých křivkách. V tomto smyslu tedy lze hovořit o tom, že vliv kvantifikaci neurčitosti maximalizuje snahodnocení reálných dat.

Theorie estimačních transformací a ideální gnostický cyklus

Máme ale zajímá i další transformace dat, estimační. Ta má výsledku kvantifikace (2) přivedit odhad \hat{z}_0 . V dvourozměrné reprezentaci je stanovení estimační transformace ekvivalentní malezem dráhy po níž se má pohybovat konec vektoru y nebo z_0 , aby se nakonec dostal co nejbliže k bodu $(z_0, 0)^T$ nebo $(0, z_0)^T$. Abychom stanovili nejlepší dráhu estimační transformace, studujeme dále kvantifikační transformace Lorentzova typu, o nichž si dokážeme, že splňují podmínky homogeneity, dvojité symetrie a rovnoramenné regularity. Matematický zápis těchto vlastností je však hyperbolickou verzí známých podmínek analytičnosti funkce komplexní proměnné. Estimační transformace plně duální ke kvantifikaci je proto daná euklidovským ortogonálním otáčením vektorů v Gaussově rovině. Vyhovuje podmínce analytičnosti Cauchy-Riemanna a příslušné dráha odpovídá opačnému variačnímu principu: její relativní délka je minimální, duálně k (2) platí pro estimační dráhu

$$x = r \cos \omega \quad y = -r \sin \omega \quad /3/$$

kde

$$r = \sqrt{x^2 + y^2} \quad /4/$$

$$\operatorname{tg} \omega = -\operatorname{th} \Omega \quad /5/$$

Z obou druh, kvantifikační a estimační, lze sestrojit uzavřený cyklus transformací, který nazveme ideálním gnostickým cyklem. Tento cyklus hraje významnou úlohu jako vzor pro postup skutečného procesu odhadování, lze dokázat jeho důležitost extremlní vlastnosti.

Charakteristiky nepodobnosti gnostických událostí

Gnostickou událostí je skutečnost, že byl získán výsledek kvantifikace tvaru /1/. Za gnostické události užíváme proto přijmout i vektor y a z_0 mající složky x, y tvaru /2/ nebo /3/, jejichž součet dá datovou položku tvaru /1/. V předešlém odstavci jsme se přesvědčili o plodnosti geometrického přístupu, který dovolil odvodit důležité vlastnosti matematického modelu neurčitosti s úvah o metrice. Zůstáváme geometrickému přístupu věrni při posuzování vztahů mezi dvěma událostmi s využitím pojmu podobnosti, který však oproti běžnému zobecníme tak, abychom vyčerpali všechny aspekty podobnosti. Dvě gnostické události y a y' mající složky x, y a x', y' budeme považovat za δ, ϵ -podobné, jestliže platí

$$x/y = \delta \cdot (x'/y')^\epsilon \quad \text{kde } \delta = \pm 1 \text{ a } \epsilon = \pm 1 \quad /6/$$

Za číselnou charakteristiku δ, ϵ -nepodobnosti pak přijmeme rozdíl obou těchto poměrů. Dosazením z /2/ se pak přesvědčíme, že charakteristikami nepodobnosti v případě kvantifikace jsou hyperbolické siny a cosiny součtu a rozdílu parametrů neurčitosti Ω obou událostí. S použitím /3/ dostaneme pro estimační další čtyři charakteristiky nepodobnosti, obyčejné siny a cosiny součtu a rozdílu parametrů ω spjatých s parametry Ω vztahem /5/. Obvyklá "trojúhelníková" podobnost odpovídající hodnotám $\delta = 1$ a $\epsilon = 1$ nás na tomto místě zajímá nejméně, protože pouze ostatní tři kombinace hodnot δ a ϵ umožňují kvantitativně charakterizovat kvalitu gnostické události novým způsobem, charakteristikami "nepodobnosti sobě". Pro $y' = y$ jsou totiž numerickými charakteristikami nepodobnosti mezi y a y' (tedy nepodobnosti mezi y a y) hyperbolické siny a cosiny dvojnásobného argumentu Ω a obyčejné siny a cosiny dvojnásobného argumentu ω . Zapišme explicitní výrazy pro tyto charakteristiky i snadno odvoditelné vztahy mezi nimi vyplývající z /5/:

$$f := \cos 2\omega = 1/\operatorname{ch} 2\Omega = (x^2 - y^2)/(x^2 + y^2) = 2/(\xi^2 + \xi^{-2}) \quad /7/$$

$$h_q := \operatorname{sh} 2\Omega = -2xy/(x^2 + y^2) = (\xi^2 - \xi^{-2})/2 = -h_\omega/2 \quad /8/$$

$$h_\omega := \operatorname{sin} 2\omega = -2xy/(x^2 + y^2) = -(\xi^2 - \xi^{-2})/(\xi^2 + \xi^{-2}) = -h_q \quad /9/$$

$$\xi := x/z_0 = (x/y)/z_0 \quad /10/$$

V předcházejícím odstavci jsme se již setkali s maticemi \underline{K} typu

$$\underline{K}_q(\Omega) = \begin{pmatrix} \text{cha} & \text{aha} \\ \text{sha} & \text{cha} \end{pmatrix}$$

/11/

zahrnujícími jednu gnostickou událost tvaru /2/ na jinou. Taková matice je prvkem komutativní grupy izomorfní s Lorentzovou grupou. Druhým k /11/ je estimační operátor

$$\underline{K}_e(\omega) = \begin{pmatrix} \text{cece} & -\text{sine} \\ \text{sine} & \text{cece} \end{pmatrix}$$

/12/

který je také prvkem komutativní grupy. Ta však již izomorfní s Lorentzovou grupou není. Součiny matic z obou grup již jednoznačně spojeny nejsou i když prvky obou grup jsou vzájemně jednoznačně přiřazeny vztahem /5/. Uvedené veličiny a vztahy nám postaďují k vyslovění (a podle /1/ i k důkazům) těchto důležitých tvrzení:

- 1) Vliv neurčitosti na data lze modelovat jako ortogonální otáčení vektoru v rovině (operátorem $\underline{K}_q(\Omega)$ nad Minkowského rovinou nebo operátorem $\underline{K}_e(\omega)$ nad Euklidovou rovinou).
- 2) Veličiny $\underline{K}_q^2(\Omega) = \underline{K}_q(2\Omega)$ a $\underline{K}_e^2(\omega) = \underline{K}_e(2\omega)$ se při takových transformacích chovají jako tenzory.
- 3) Veličiny f, f^\dagger, h_q a h_e /7/-/9/, číselné charakteristiky nepodobnosti gnostických událostí sobě se shodují se složkami těchto tensorů.

Platí tedy identity

$$\underline{K}_q^2(\Omega) = \begin{pmatrix} f^{-1} & h_q \\ h_q & f^{g_1} \end{pmatrix} \quad \underline{K}_e^2(\omega) = \begin{pmatrix} f & -h_e \\ h_e & f \end{pmatrix}$$

/13/

a my máme důvod nazvat tyto veličiny tenzory nepodobnosti. Vidíme, že charakterizují nekalitu dat způsobenou neurčitostí.

Změny informace jednotlivé položky způsobené neurčitostí

Složky tensorů nepodobnosti dále hrají významnou úlohu, stojí proto za to je pojmenovat:

f^{-1} nervivnost

f výroost

h_q kvantifikáční irrelevance

h_e estimační irrelevance

Při kvantifikaci se kvantifikáční irrelevance mění od 0 do hodnoty h_q . Vypočteme střední hodnotu úhlu 2Ω na tomto intervalu, veličinu

$$I_q = \int_{h_q}^{h_q} 2\omega dh \quad /14/$$

Hodnota h_q dosažená na konci kvantifikace odpovídá hodnotě estimační irrelevance h_e počátku estimace. PM estimaci se pak tato irrelevance bude měnit od h_e do nuly. Vypočteme střední hodnotu úhlu 2Ω na tomto intervalu:

$$I_e = \int_{h_e}^{h_e} 2\omega dh \quad /15/$$

Použijeme-li pro nějaké komplexní p ($p \neq 0, p \neq 1$) funkci

$$H_p = -p \ln p - (1-p) \ln(1-p) \quad /16/$$

kde pod $n(\cdot)$ rozumíme hlavní hodnotu a zavedeme-li označení

$$p_q = (1 + \sqrt{-1} h_q)/2 \quad p_e = (1 + h_e)/2 \quad /17/$$

dostaneme integrály /14/ a /15/ ve tvaru

$$I_q = H_{1/2} - H_{p_q} \quad /18/$$

$$I_e = H_{1/2} - H_{p_e} \quad /19/$$

Veličiny I_q a I_e interpretujeme jako změny informace v kvantifikáční a estimační části ideálního gnostického cyklu. K takové interpretaci je několik závažných důvodů přesto, že jsme tyto veličiny odvodili pro jedinou položku dat a není dán žádný obvyklý pravděpodobnostní model:

- 1) Obě veličiny I_q i I_e jsme odvodili jako rozdíly funkce H mající formu shodnou se statistickou entropií termodynamického systému a tudíž i s Shannonovou informací binárního pravděpodobnostního systému.
- 2) PM využívání veličiny dat z od ideální hodnoty I_q klesá od nuly monotoničně a při návratu veličiny z od se zmenší (pozorované) hodnoty k ideální (tento návrat se nazývá T) roste monotoničně od nuly. Pro každou pozoro-

vanou hodnotu $z_1 \neq z_0$ vžak platí

$$I_q(z_1/z_0) + I_a(z_1/z_0) < 0 \quad (0 < z_1/z_0 < \infty)$$

/20/

což interpretujeme jako nemocnost "nepřavit" estimací zcela strátu informace způsobenou vlivem neurčitosti, a to ani v případě ideálního gnostického cyklu.

- 3) Parametry funkcí H podobně jako pravděpodobnost v případě Shannonovy informace jsou veličiny p_q a p_a použitelné jako číselné charakteristiky očekávání, že neznámá veličina z_0 má hodnotu převyšující pozorovanou hodnotu.
4) Změna polí veličin I_q a I_a jsou úměrná změnám termodynamické entropie. V gnostickém cyklu tedy dochází ke změnám informace na úkor změn entropie a naopak. Hypotéza o existenci konverze entropie na informaci a naopak byla vyslověna velice dříve, zde máme matematický model této konverze pro obecný případ neurčitosti každé jednotlivé datové položky.

Po přijetí informační interpretace funkcí I_q a I_a lze přistoupit k formulaci významného tvrzení o optimalitě ideálního gnostického cyklu.

Ideální gnostický cyklus a jeho informační optimalita

Ideální hodnotě z_0 můžeme přiřadit dva vzájemně duální vektory $u_0^T = (z_0, 0)$ a $u_0^T = (0, z_0)$. Byl-li výsledek skutečné kvantifikace z_s , jsou příslušné gnostické události v dvourozměrovém tvaru $u_s^T = (x_s, y_s)$ a $u_s^T = (y_s, x_s)$, přičemž složky x_s, y_s mají tvar /2/ při kvantifikaci s úhlem Ω_s a při estimaci tvar /3/ s úhlem ω_s a amplitudou $r_s = \sqrt{x_s^2 + y_s^2}$. Kvantifikační část dráhy ideálního gnostického cyklu (IGC) představuje oblouk Minkowského kružnice vycházející z bodu u_0 a končící v bodě u_s (z hlediska euklidovského zobrazení je to oblouk rovnoosé hyperboly). Z bodu u_s pak IGC pokračuje podél oblouku obyčejné kružnice o poloměru r_s až do bodu $u_s^T = (r_s, 0)$ a do původního výchozího bodu u_0 , se cyklus uzavírá pohybem představujícího bodu podél úsečky $u_s u_0$. Ke každému takovému IGC graficky znázorněnemu jako

$$\text{IGC} := \overbrace{u_0 u_s} \parallel \overbrace{u_s u_s^T} \parallel \overbrace{u_s^T u_0}$$

/21/

existuje ovšem duální cyklus

$$\text{c}_c \text{IGC} := \overbrace{c_u^T c_{u_s}} \parallel \overbrace{c_{u_s}^T c_{u_s^T}} \parallel \overbrace{c_{u_s^T} c_u}$$

/22/

který při zobrazení v rovině (x, y) je s IGC symetrický vzhledem k ose kvadrantu. Třetí, uzavírající přímkovou část cyklu nazýváme atenuací, protože pohyb podél přímky procházející počátkem souřadnic lze představit jako důsledek změny měřítka či "zeslabení" veličin nějakým atenuátorem. Cyklus je tedy definován jako posloupnost tří na sebe navazujících myšlených pohybů v rovině:

$$\text{IGC} := \text{Kvantifikace} // \text{Estimace} // \text{Atenuace}$$

probíhajících po již stanovených dráhách. Představme si vžak jiný uzavřený cyklus VGC vzniklý z IGC malou variací při zafixovaných koncových bodech z_0 a z_s . Pro každý takový cyklus je v /1/ dokázáno, že platí

$$\oint \text{d}I \leq \oint \text{d}I < 0$$

VOC IGC

/23/

kde I značí postupně při vyříšení integrálu I_q , I_a a I_a , přičemž I_a je změna informace při atenuaci (ta je nulová, protože změna měřítka nemění poměr $y(x)$). Analogická nerovnost platí i pro duální cykly ${}_c \text{IGC}$ a ${}_c \text{VGC}$. Od tuk plyně, že IGC je optimální v tom smyslu, že minimalizuje ztráty informace způsobené neurčitostí. V tomto smyslu je IGC vzorem pro praktické odhadování, k němuž se budeme snažit co nejvíce přiblížit.

GNOSTICKÁ TEORIE DATOVÉHO Souboru

Charakteristiky datového souboru by měly reprezentovat společné vlastnosti jednotlivých dat. Mají být určeny tak, aby jejich neurčitost byla menší než "průměrná" neurčitost jednotlivých dat. K tomu je třeba data složit podle nějakého kompozičního zákona. Prosté sečítání dat běžné při vytváření průměrů se neosvědčilo v případech, kdy se počítává robustnost odhadu vůči odlehlym pozorováním. V robustní statistice

dostává každá položka dat při vytváření odhadu parametru polohy či měřítka svou individuální váhu závislou na vzdálenosti této položky od hodnoty parametru polohy. V gnostické teorii /2/ je taková individuální váha určena druhým axiomem této teorie, který stanovuje kompoziční zákon pro skládání dat.

Druhý axiom gnostické teorie

Nechť $Z(z_0, n)$ je datový soubor sestavený z dat z_1, \dots, z_n majících tvar /1/. Charakteristikou souboru Z nazveme funkci všech těchto dat a z_0 . Za charakteristickou událost souboru Z přijmeme událost $u_c^T = (z_0 \operatorname{ch} \Omega_c, z_0 \operatorname{sh} \Omega_c)$ v případě kvantifikace a $u_c^T = (r_c \cos \omega_c, -r_c \sin \omega_c)$ v případě estimace, přičemž veličiny Ω_c, ω_c jsou charakteristiky souboru Z .

Druhý axiom gnostické teorie říká, jak určit charakteristiky Ω_c a ω_c :

$$K_q^2(\Omega_c) = \frac{1}{w_q^2} \sum_{i=1}^n K_q^2(\Omega_i) \quad K_e^2(\omega_c) = \frac{1}{w_e^2} \sum_{i=1}^n K_e^2(\omega_i) \quad /24/$$

kde

$$w_q^2 = \operatorname{Det} \left(\sum_{i=1}^n K_q^2(\Omega_i) \right) \quad w_e^2 = \operatorname{Det} \left(\sum_{i=1}^n K_e^2(\omega_i) \right) \quad /25/$$

jsou normalizační váhy. Gnostický kompoziční zákon tedy skládá vlivy jednotlivých dat souboru silně nelineárně tak, aby tenzory nepodobnosti charakteristické události souboru byly normovanými součty tensorů nepodobnosti jednotlivých dat. Tensorový charakter sčítaných veličin zajišťuje formální správnost takového skládání, dále však uvidíme, že pro právě tento způsob skládání je i závažný přímý důvod - zajištění konsistence gnostické teorie s relativistickou fyzikou. Takový výběr axioma skládání dat se ovšem podstatně liší od často heuristických a formálních důvodů vedoucích k pravidlům pro vážení dat přijímaným v mnoha desítkách metod robustní statistiky.

Důsledky druhého axioma

Ze vztahu /17/ snadno získáme charakteristiky Ω_c a ω_c :

$$2\Omega_c = \operatorname{arctg} (\bar{h}_q/f^{-1}) \quad 2\omega_c = \operatorname{arctg} (\bar{h}_e/f) \quad /26/$$

přičemž symbol \bar{q} značí zde i dále aritmetický průměr hodnot q_1, \dots, q_n . Veličina Ω_c má povahu charakteristické chyby dat hodnocené z hlediska kvantifikačního procesu, zatímco ω_c odpovídá chybě dat měřené v estimační matrice. Lze ukázat, že při slabé neurčitosti dat (malé relativní chyba všech dat souboru) se všechny charakteristiky $\Omega_c, -\omega_c, \bar{h}_q$ i \bar{h}_e liší od průměrné relativní chyby dat pouze o veličinu $O(\epsilon^2)$, kdež je největší absolutní hodnota relativní chyby dat. Uvedené čtyři veličiny tedy představují různá gnostická zobecnění relativních chyb dat platná i pro případy silné neurčitosti. Jejich užitečnost je v tom, že se liší stupněm robustnosti vůči odlehlym pozorováním.

Ve vztazích /19/ vystupují i dvě další důležité veličiny, průměrná nevěrnost f^{-1} a průměrná věrnost f . Při výpočtu normalizačních vah podle /18/ se čtverce těchto veličin mohou rozepsat pomocí veličin f^{-2} a f^2 a pomocí průměru součinu irrelevancí. Poslední z těchto veličin nabízí možnost zobecnění korelačních koeficientů, zatímco odchyly prvních čtyř veličin od 1 představují gnostická zobecnění výběrových rozptylu. Lze se přesvědčit, že všechny čtyři veličiny $(f^{-1}-1)/2, (1-f)/2, (f^{-2}-1)/4$ a $(1-f^2)/4$ se při omezení všech relativních chyb hodnotou ϵ liší od relativní hodnoty výběrového rozptylu o veličinu $O(\epsilon^3)$. Všechny čtyři veličiny tedy jsou gnostickými zobecněními výběrového rozptylu. Lze ukázat, že se vzájemně liší stupněm robustnosti vůči odlehlym pozorováním.

Gnostická teorie datových souborů nám tedy nabízí řadu charakteristik různé robustnosti. Závislost těchto veličin na neznámé ideální hodnotě z_0 umožnuje formulovat a řešit problém odhadování ideální hodnoty jako úlohu extremalizace vybrané charakteristiky. V dalším příspěvku /4/ je uvedeno souhrnné řešení takového problému.

O KONSISTENCI GNOSTICKÉ TEORIE

Za konsistentní považujeme teorii odvozenou pomocí nějakého jazyka či kalkulu formálně správně z nerozporného a úplného systému axiomů. Takovou vlastnost "vnitřní" či vertikální konsistence zatím můžeme gnostické teorii přisoudit (dokud nebude dokázán opak). U teorie, která má poskytovat model nějakého výsledku skutečnosti je však důležitá i jiná, "vnější" či "horizontální" konsistence: vzhledem k "nyní" nepochybným teorím "sousedních" výsledků skutečnosti. Lze ukázat /3/, že gnostická teorie je v souladu s teorií měření, s relativistickou fyzikou a s klasickou termodynamikou a že za určitých zvláštních podmínek, které umožňuje stanovit dává gnostická teorie výsledky konvergující k výsledkům klasické (robustní) statistické teorie a teorie informace. Lze rovněž ukázat, že tak rozsáhlou návaznost na jiné teorie existující statistická teorie neprokazuje.

Literatura:

- /1/ Kovanic P., Gnostical theory of individual data, v tisku
- /2/ Kovanic P., Gnostical theory of small samples of real data, v tisku
- /3/ Kovanic P., On relations between information and physics, v tisku (články vyjdou v časopise Problems of control and information theory, č. 4, 5 a 6, r. 1984)
- /4/ Kovanic P., Gnostické algoritmy zpracování dat, Sborník ROBUST '84, MFF-UK (1984)

GNOSTICKÉ ALGORITMY ZPRACOVÁNÍ DAT

Pavel Kovanic

SOUHRN

Příspěvek podává stručnou informaci o současném stavu algoritmizace robustních estimacních metod založených na gnostické teorii dat. Jde zejména o odhadování parametrů polohy jednorozměrových datových souborů, jejich měřítka, distribuční funkce a hustoty pravděpodobnosti. Souhrnně je popsán systém pro interaktivní gnostickou analýzu datových souborů na osobním počítači.

GNOSTICKÉ PARAMETRY POLOHY A MĚŘITKA

Gnostická teorie stručně vyložená v jiném příspěvku v tomto sborníku /1/ nepoužívá statistický model. Přesto však nabízí charakteristiky datových souborů blížící se svým smyslem tomu, k čemu statistika používá některé parametry svých modelů, k vystílení polohy a variability datového souboru. Gnostický model dat doplněný oproti /1/ o parametr měřítka má tvar

$$z_i = z_0 \exp(s \Omega_i)$$

/1/

kde z_i je i-tá položka datového souboru $Z(n, z_0, s)$ obsahujícího n výsledků kvantifikace (tj. měření nebo čítání) kvantity, která by se při ideálních podmínkách kvantifikace zobrazila jako číslo z_0 , tzv. ideální hodnota. Veličina Ω_i charakterizuje vliv neurčitosti na i-tou položku dat a veličina " s " je měřítko. Především tyto dvě veličiny budeme odhadovat při zpracování datových souborů.

GNOSTICKÁ OPTIMALITA ODHADE POLOHY

V předchozím příspěvku /1/ je uvedena dvojice gnostických charakteristik K_q a K_e , které mají smysl sebeoněné "střední" chyby dat. Jsou to kvantifikační a estimacní irrelevance, složky tensoru nepodobnosti. Tamtéž jsou uvedeny čtyři gnostická sebeoněrnostní výběrového rozptylu určená odchylkami průměrné věrnosti F , průměrné nevěrnosti f' a průměru čtverců těchto veličin od jedničky. Za nejlepší gnostický odhad J-tého typu můžeme přijmout veličinu z_j extenzivující některou ze šesti

uváděných charakteristik datového souboru $Z(n, z_0, s)$. Každý z takto získaných odhadů má důležitou interpretaci jak je vidět z Tab. 1:

Typ odhadu	Podmínka	Interpretace optimality odhadu
z_{qI}	$\frac{df}{dz_0} = 0$	Minimalizace intenzity ztráty informace při kvantifikaci
z_{qF}	$\frac{df}{dz_0} = 0$	Minimální zvýšení termodynamické entropie při kvantifikaci
z_{qS}	$H_q = 0$	1) Minimalizace celkové kvantifikační ztráty informace 2) Kvantifikační symetrie dat
z_{eS}	$H_e = 0$	1) Maximalizace celkového estimačního zvýšení informace 2) Estimační symetrie dat
z_{eF}	$\frac{df}{dz_0} = 0$	Maximální snížení entropie při estimaci
z_{eI}	$\frac{df}{dz_0} = 0$	1) Maximalizace intenzity zvyšování informace při estimaci 2) Maximalizace hustoty pravděpodobnosti

Tab. 1: Přehled optimizačních podmínek pro stanovení gnostických odhadů parametru polohy a jejich teoretická interpretace. Symbol \bar{q} značí aritmetický průměr n-tice veličin q_1, \dots, q_n .

ROVNICE PRO ODHAD GNSTICKÉHO PARAMETRU POLOHY

Dosazením do podmínek optimality dostáváme pro všechn 6 případů z Tab. 1 jedinou rovnici

$$\sum_{i=1}^n ((z_e/z_i)^{2/s} - (z_i/z_e)^{2/s}) / ((z_0/z_i)^{2/s} + (z_i/z_0)^{2/s})^M = 0 \quad /2/$$

kde exponent M je určen Tab. 2:

Odhad	z_{qI}	z_{qF}	z_{qS}	z_{eS}	z_{eF}	z_{eI}
M	-1	0	0	1	2	3

Tab. 2: Exponent M pro rovnici /1/ odhadu parametru polohy z_0 .

Důsledkem volby exponentu M je stupeň a druh robustnosti odhadu (blíže viz /2/). Pro $M=3$ je odhad maximálně robustní a pro $M=-1$ citlivý k odlehlym pozorováním.

ODHAD MĚŘÍTKA A HUSTOTY DATOVÉHO SOUBORU

Odhad parametru měřítka je spjat s hustotou dat interpretovatelnou jako gnostický odhad hustoty pravděpodobnosti datového souboru. Ten je dán vzorcem

$$P = \frac{1}{n} \sum_{i=1}^n 4 / ((z_i/z)^{2/s} + (z/z_i)^{2/s})^2 \quad /3/$$

Kde má smysl průměrné pravděpodobnosti, že neznámá veličina z_0 je větší než z, podmíněně tím, že data mají hodnoty z_1, \dots, z_n . Známe-li parametr měřítka, můžeme tedy z dat sestrojit odhad hustoty pravděpodobnosti, aniž bychom potřebovali statistický model. Vzorec /3/ můžeme však také použít k získání algoritmu pro odhadování parametru měřítka. Teoretický prostředek k tomu najdeme opět v gnostické teorii: za nejlepší odhad parametru měřítka přijmeme tu jeho hodnotu, která zaručuje shodu mezi průměrnou nepravděpodobností dat a mezi střední nepodobností vypočtenou pomocí odhadnuté hustoty pravděpodobnosti jako funkci parametru měřítka.

SYSTÉM PROGRAMŮ PRO GHOSTICKOU ANALÝZU DAT

V současné době již existuje programová realizace algoritmů vyplývajících z gnostické teorie, umožňujících detailní analýzu jednorozměrových datových souborů. Je vytvořena jako interaktivní systém programů v jazyce BASIC pro osobní počítač SINCLAIR ZX-81 s pamětí 16K. Má následující funkce:

- 1/ Vstup dat z klávesnice. Data mohou odpovídat buď multiplikativnímu nebo aditivnímu modelu vlivu neurčitosti.
- 2/ Vyběr typu operace na datech
- 3/ Odhadování parametru polohy pro volitelnou robustnost (parametr M, viz Tab. 2)
- 4/ Odhadování parametru měřítka s volitelnou robustností
- 5/ Odhadování hranic datového souboru
- 6/ Odhadování pravděpodobnosti $P(z_0 > z)$
- 7/ Odhadování hustoty pravděpodobnosti dP/dz
- 8/ Testování hypotéz o homogenitě datového souboru a určování počtu shluků
- 9/ Určování vah jednotlivých dat
- 10/ Uspořádávání dat
- 11/ Odhadování základních statistických charakteristik datového souboru
- 12/ Numerický i grafický výstup výsledků

Tento programový systém byl vyzkoušen na různých aplikacích a prokázal výhodné vlastnosti gnostických algoritmů. Výsledky dávají naději, že touto cestou získají vědecká pracoviště účinný a flexibilní nástroj pro zkoumání vlastností malých datových souborů.

Literatura:

- 1/ Kovanic P., Základy gnostické teorie dat, Sborník ROBUST '84, MFF-UK (1984).