

LOGARITMICKO LINEÁRNÍ MODELY  
PRO POSLOUPNOSTI ZÁVISLÝCH BINÁRNÍCH DAT

Martin Janzura, ÚTIA ČSAV, Praha

S posloupnostmi binárních dat se lze setkat všude tam, kde jsou v pravidelných časových intervalech opakované pozorovány veličiny nabývající pouze dvě hodnoty (např. přítomnost - nepřítomnost příznaku, překročení - neprekročení kritické úrovne apod.). Tyto hodnoty mohou být zcela libovolné, pro jednoduchost je účelné pracovat s dvoubodovou množinou  $\{0,1\}$ .

Při statistickém zpracování takových posloupností dat se obvykle využívá teorie markovských řetězců (libovolného rádu). Pravděpodobnosti přechodu však neposkytuje dostatečně jemný pohled na skutečnou závislostní strukturu a současně se nesnadno odhaduje, jestli rozsah výběru nedostatečný vzhledem k rádu markovosti.

Z těchto důvodů půjdeme cestou zobecnění teorie logaritmicko lineárních modelů, které se osvědčily pro popis simultánní distribuce konečného systému náhodných veličin (viz Bishop, Fienberg a Holland (1975)). Přirozeným zobecněním logaritmicko lineárních modelů pro náhodné posloupnosti obdržíme modely známé v oblasti statistické fyziky pod pojmem gibbsovské náhodné posloupnosti.

### 1. Gibbsovské náhodné posloupnosti

Vyjděme od definice logaritmicko lineárního modelu pro simultánní rozdělení konečného systému binárních náhodných veličin.

Pro libovolnou množinu  $V$  označme  $k(V) = \{\Lambda \subset V : 0 < |\Lambda| < \infty\}$  systém všem konečných neprázdných podmnožin ( $|\Lambda|$  značíme kardinalitu množiny  $\Lambda$ ).

Předpokládejme nejprve, že množina  $V$  je konečná, tedy  $|V| < \infty$ . Pravděpodobnostní míra  $\mu^U$  definovaná na  $\{0,1\}^V$  vyhovuje logaritmicko lineárnímu modelu, jestliže existuje systém reálných konstant

$$U = \left\{ U_A \right\}_{A \in k(V)}$$

tak, že platí

$$(1) \quad \log \mu^U(x_V) = \sum_{A \in k(V)} U_A \prod_{s \in A} x_s - q(U)$$

pro každé  $x_V \in \{0,1\}^V$ .

kde

$$q(U) = \log \sum_{y_V \in \{0,1\}^V} \exp \left\{ \sum_{A \in k(V)} U_A \prod_{s \in A} y_s \right\}$$

je logaritmus příslušné normovací konstanty.

Ekvivalentní definice má tvar

$$(2) \quad \log \mu^U(x_{\{t\}} | x_{V \setminus \{t\}}) = \\ = \sum_{A \in k(V), A \ni t} u_A \prod_{s \in A} x_s - \log \left[ 1 + \exp \left\{ \sum_{A \in k(V), A \ni t} u_A \prod_{s \in A \setminus \{t\}} x_s \right\} \right]$$

pro každé  $t \in V$ ,  $x_V \in \{0,1\}^V$ .

Hodnoty  $u_A$ ,  $A \in k(V)$  se nazývají interakcemi, celý systém  $U = \{u_A\}_{A \in k(V)}$  se ve statistické fyzice nazývá potenciál.

Samočty model je pak určen systémem nenulových interakcí. Pro  $A \subset k(V)$  budeme psát  $U \in M_A$  jestliže  $u_A = 0$  pro každé  $A \in k(V) \setminus A$ . Priznaní  $A \in M_A$  je zřejmě monotonní, tj. pro  $B \subset A$  platí  $M_B \subset M_A$ .

Poznámka: V obecné definici logaritmicko lineárního modelu se uvažují libovolné funkce  $u_A(x_A)$  namísto zde uvedeného speciálního tvaru  $u_A \prod_{s \in A} x_s$ . Pak je ale třeba v zájmu jednoznačnosti doplnit definici o nějaké normující vazbě, aby zůstalo kýchých  $2^{|V|-1}$  volných parametrů. Tomu se zde užitím speciálního tvaru funkcí vyhneme při zachování plné obecnosti, tj. pro každou kladnou pravděpodobnostní míru  $\mu$  na  $\{0,1\}^V$  existuje výše uvedené vyjádření ve formě logaritmicko lineárního modelu.

Nahradíme nyní konečnou množinu  $V$  prostorem celých čísel  $Z$  a budeme uvažovat pouze omezené potenciály

$$U = \{u_A\}_{A \in k(Z)}$$

t.j.  $\sum_{A \in k(Z), A \ni t} |u_A| < \infty$  pro každé  $t \in Z$ .

Rekneme, že distribuce  $\mu^U$  na  $\{0,1\}^Z$  je gibbsovská vzhledem k potenciálu  $U$ , jestliže definice (2) platí pro  $V = Z$  (zde jsme potřebovali předpoklad omezenosti, aby nekonečné součty konvergovaly).

Definici (1) nelze přímo použít, neboť pro  $V = Z$  by neměla dobrý smysl, a kdybychom tímto způsobem definovali systém konečně rozměrných distribucí  $\{\mu_V^U\}_{V \in k(Z)}$ , nebyl by tento systém nutně konzistentní.

Lze pouze definici rozšířit na systém všech konečně rozměrných podmínených distribucí

$$\{\mu_{V|Z \setminus V}^U\}_{V \in k(Z)}$$

předpisem

$$\log \mu_{V|Z \setminus V}^U(x_V | x_{Z \setminus V}) = \sum_{A \in k(Z), A \cap V \neq \emptyset} u_A \prod_{s \in A} x_s - q_V^U(x_{Z \setminus V})$$

pro každé  $V \in k(Z)$ , kde

$$q_V^U(x_{Z \setminus V}) =$$

$$= \log \sum_{y_V \in \{0,1\}^V} \exp \left\{ \sum_{A \in k(V), A \cap V \neq \emptyset} u_A \prod_{s \in A \cap V} y_s \prod_{s \in A \setminus V} x_s \right\}$$

je opět logaritmus příslušné normovači konstanty.

V dalším se budeme zabývat pouze stacionárními potenciály, tj.  $U_A = U_{A+t}$  pro každé  $A \in k(\mathbb{Z})$ ,  $t \in \mathbb{Z}$ . Označíme  $k_+(\mathbb{Z}) = \{A \in k(\mathbb{Z}): \min\{j \in A\} = 0\}$ . Model je zde opět určen systémem nenulových interakcí, tj. pro  $A \in k_+(\mathbb{Z})$  píšeme  $U \in M_A$  jestliže  $U_A = 0$  pro  $A \in k_+(\mathbb{Z}) \setminus A$ .

Jestliže  $|A| < \infty$ , určuje systém podmíněných distribucí  $\{M_U^V | Z \setminus V\}_{V \in k(\mathbb{Z})}$  (který je ovšem jednoznačně dán systémem  $\{M_{\{t\}}^U | Z \setminus \{t\}\}_{t \in \mathbb{Z}}$ ) a jelikož je potenciál stacionární, tak dokonce staci  $M_{\{0\}}^U | Z \setminus \{0\}$  jednoznačným způsobem gibbsovskou distribuci  $\mu^U$  na  $\{0,1\}^{\mathbb{Z}}$ . Tato distribuce je pak stacionární a ergodická. (To pro  $|A| = \infty$  nemusí být pravda. Nejen že není zaručena jednoznačnost, ale může existovat i nestacionární distribuce.)

Označme  $[n] = \{1, \dots, n\}$  pro každé  $n \in \mathbb{Z}$ . Pak platí

$$\lim_{n \rightarrow \infty} \frac{1}{n} q_U^{[n]}(x_{Z \setminus [n]}) = q(U)$$

stejnometře v  $x \in \{0,1\}^{\mathbb{Z}}$  pro každý omezený stacionární potenciál  $U$ .

Nechť  $|A| < \infty$ . Potom  $q$  zúženou na  $M_A$  lze chápat jako silně konvexní reálnou analytickou funkci na  $\mathbb{R}^A$ . Označíme-li

$$C_A = \left\{ x \in \{0,1\}^{\mathbb{Z}} : \prod_{i \in A} x_i = 1 \right\} \text{ pro } A \in k(\mathbb{Z}),$$

potom zejména platí

$$\nabla q(U) = \left\{ \frac{\partial q}{\partial U_A}(U) \right\}_{A \in A} = \left\{ \mu^U(C_A) \right\}_{A \in A}$$

$$\nabla^2 q(U) =$$

$$= \left\{ \frac{\partial^2 q}{\partial U_A \partial U_B}(U) \right\}_{A, B \in A} = \left\{ \sum_{k=-\infty}^{\infty} \left[ \mu^U(C_A \cap T^{-k} C_B) - \mu^U(C_A) \mu^U(C_B) \right] \right\}_{A, B \in A}$$

kde  $T : \{0,1\}^{\mathbb{Z}} \rightarrow \{0,1\}^{\mathbb{Z}}$  je posunutí definované předpisem  $T(x)_n = x_{n+1}$  pro každé  $x \in \{0,1\}^{\mathbb{Z}}$ ,  $n \in \mathbb{Z}$ . Přitom  $\nabla q(U)$  i  $\nabla^2 q(U)$  jsou spojité jako funkce  $U \in M_A$  a  $\nabla^2 q(U) > 0$  pro každé pevné  $U \in M_A$ .

Plati také

$$q(U) = r^{-1} \log \lambda_{\max}(Q_U),$$

kde  $r = r(A) = \max_{A \in A} \max\{j \in A\}$  a  $Q_U$  je tzv. transfer matice definovaná předpisem

$$Q_U(x_{[r]}, z_{[r]}) = \\ = \exp \left\{ \sum_{A \in A} U_A \sum_{l=1}^r \prod_{k \in (A+l) \cap [r]} x_k \cdot \prod_{k \in (A+l-r) \cap [r]} z_k \right\}$$

pro každé  $x_{[r]}, z_{[r]} \in \{0,1\}^{[r]}$ . Matice  $Q_U$  je čtvercová, dimenze  $2^r \times 2^r$  a skladnými elementy, je tedy jednoznačně dano její v absolutní hodnotě největší vlastní číslo  $\lambda_{\max}(Q_U)$ , které je reálné kladné. Tímto způsobem se v praxi hodnoty funkce  $q$  vypočítají.

Vlastnou výsledků vykazují se gibbsovských náhodných posloupností lze nalézt v klasické monografii Kullta (1969).

## 2. Odhadý interakce a testování submodelu

Předpokládáme, že pozorovaná posloupnost binárních dat

$$x_{[N]} = (x_1, \dots, x_N) \in \{0, 1\}^N$$

je generována nějakou gibbsovskou distribucí  $\mu^{U^0}$  s neznámým potenciálem  $U^0 \in M_A$ ,  $A \in \mathcal{L}_+(V)$ .  $|A| < \infty$ . Naším prvním úkolem je odhadnout tento potenciál chápáný jako vektorový parametr.

Pro  $U \in M_A$  a  $\theta \in R^d$  označme

$$F_A(U, \theta) = q(U) = \sum_{A \in A} U_A \theta_A.$$

Z vlastnosti funkce  $q$  na  $M_A$  plynou

$$\text{i)} \quad U^1 = U^2 \quad \text{práve když } \nabla q(U^1) = \nabla q(U^2)$$

$$\text{ii)} \quad F_A(U^0, \theta^0) = \min_{U \in M_A} F_A(U, \theta^0) \quad \text{práve když } \nabla q(U^0) = \theta^0.$$

Odhad  $U^N$  parametru  $U^0$  tedy získáme minimizací funkce  $F_A(U, \theta^N)$ , kde za  $\theta^N$  vezmeme odhad vektoru  $\nabla q(U^0) = \{\mu^{U^0}(c_A)\}_{A \in A}$ . Tedy

$$\theta_A^N = (N - r(A))^{-1} \sum_{i=1}^{N-r(A)} \prod_{j \in A} x_{j+i} \quad \text{pro každé } A \in A$$

(zde  $r(A) = \max\{k \in A\}$ ). Pokud minimum neexistuje, dodefinujeme  $U^N$  libovolně.

**Věta:** Odhad  $U^N$  je konzistentní a asymptoticky normální, tj.

$$U^N \xrightarrow{D} U^0 \quad a.s. \quad \left[ \begin{matrix} \mu^{U^0} \\ \vdots \end{matrix} \right]$$

$$\frac{1}{N^{\frac{1}{2}}} (U^N - U^0) \sim N \left( 0, (\nabla^2 q(U^0))^{-1} \right) \text{ v distribuci } \left[ \begin{matrix} \mu^{U^0} \\ \vdots \end{matrix} \right].$$

**Dоказ:** Věta 3.2, Jantura (1986).

Rekneme, že máme podezření, že bychom mohli napozorované data vysvětlit pomocí jednoduššího modelu  $B \subset A$ . Budeme tedy testovat hypotézu

$$H^0 : U^0 \in M_B$$

proti alternativě

$$H^1 : U^0 \in M_A \setminus M_B.$$

Zavedeme statistiku

$$G^N = \min_{U \in M_B} F_A(U, \theta^N) - \min_{U \in M_A} F_A(U, \theta^N),$$

která je definovaná, pokud existuje  $U_A^N \in M_A$ , v němž nabývá minima funkce  $F_A(\cdot | \theta^N)$ . Potom se totíž v nejukém  $U_B^N \in M_B$  nabude i minima funkce  $F_A(\cdot | \theta^N)$  zadané na  $M_B$ .

Můžeme také psát

$$G^N = H \begin{pmatrix} U_A^N \\ \mu \\ U_B^N \end{pmatrix},$$

Kde  $H(\cdot | \cdot)$  je 1-divergence dáná pro obecné  $\mu$ ,  $\nu$  výrazem

$$H(\mu|\nu) = \lim_{n \rightarrow \infty} n^{-1} \int \log \frac{\mu(x[n])}{\nu(x[n])} d\mu(x),$$

pokud jsou integrály definovány a limita existuje (pro gibbsovské  $\mu$ ,  $\nu$  je  $H(\mu|\nu)$  konečná).

Pokud se minima nenabývá, můžeme  $G^N$  dodefinovat libovolně.

Věta: Pro každý  $U^0 \in M_B$  platí

$$Z.N.G^N \xrightarrow{f} \chi_f^2 \text{ v distribuci } \begin{bmatrix} U^0 \\ \mu \end{bmatrix},$$

kde  $f = |A \setminus B|$ .

Důkaz: Věta 4.2, Janzura (1988b).

Hypotézu tedy zamítáme, jestliže statistika  $Z.N.G^N$  přesahne příslušný kvantil rozdělení  $\chi^2$  s  $|A \setminus B|$  stupni volnosti.

### 3. Použití

Ve statistických úlohách se systém  $A$  (určující model) považuje za známý, přičemž teoreticky může být zcela libovolný konečný. V praxi však existují dvě závažná omezení. V první řadě je zde omezení na "řád"  $r = r(A)$ , které je dáno výpočetními možnostmi, neboť je třeba opakovat počítat největší vlastní číslo transfer matice  $Q_U$ , která je rádu  $2^r \times 2^r$ . Je tudíž třeba predpokládat zhruba  $r < 10$ .

Další omezení je na kardinalitu množin v systému  $A$ , tedy  $C(A) = \max |A|$ . Toto omezení je dáno rozsahem výměru  $N$ . Jestliže by totiz nebyl rozsah výběru  $N$  dostatečně velký vzhledem k  $2^{|A|}$  možných konfigurací  $x_A \in \{0,1\}^A$ , byl byl odhad  $\theta_A^N$  pravděpodobně velmi nepřesný. Zde se ukazuje účelné (a v mnoha praktických úlohách také zcela postačující) uvažovat pouze párové interakce, tj.  $A = \{A_t = \{0,1\}\}_{t=0, \dots, r}$ .

Potom již můžeme  $\theta_{A_t}^N$  odhadnout s rozumnou přesností i při poměrně malém rozsahu výběru  $N$  a bez dalšího omezení na  $r$ . Jedná se pak vlastně o odhad jakýchsi "kovariancí"  $\mu^{U^0} (x_0=1, x_t=1)$ .

Uvažujme například úlohu predikce. Máme napozorovaná data  $(x_1, \dots, x_N) \in \{0,1\}^N$  a předpokládáme, že generující náhodná posloupnost  $\mu$  je markovské rádu  $R$ . Pro optimální predikci (ve smyslu minimální pravděpodobnosti chyby) je třeba umět vyjádřit podíl

$$L_{\mu}(x_{[R]}) = \frac{\mu^{(1|x_{[R]})}}{\mu^{(0|x_{[R]})}} \text{ pro každé } x_{[R]} \in \{0,1\}^R.$$

Věta: Pro každé  $U \in M_A$ ,  $r(U) = R$ , platí

$$L_U(x_{[R]}) = [\lambda_{\max}(Q_U)]^{\frac{1}{R}} \frac{r_U(x_{[R]})}{r_U(\vec{x}_{[R]})} = 1,$$

kde  $r_U$  je levý vlastní vektor příslušný vlastnímu číslu  $\lambda_{\max}(Q_U)$  a konfigurace  $\vec{x}_{[R]}$  je dána tak, že  $\vec{x}_1 = 0$ ,  $\vec{x}_i = x_{i-1}$  pro  $i = 2, \dots, R$ .

Důkaz: Důsledek věty 1. Janzura (1988a).

Jestliže tedy  $N$  je "malé" ve srovnání s  $2^{R+1}$ , budeme postupovat takto:

1. Předpokládáme, že  $\mu$  je gibbsovské s nejvýše párovými interakcemi, tj.  $\mu = \mu_U^R$ ,  $U \in M_A$ ,  $A_R = \{0,1\}_{i=0, \dots, R}$ .
2. Odhadneme  $U$  postupem uvedeným v části 2.
3. Spočteme  $L = L_U(x_N, \dots, x_{N-R+1})$ . Jestliže  $L > 1$ , predikujeme  $x_{N+1} = 1$ .

Tato metoda funguje poměrně spolehlivě. Jsou-li předpoklady o párových interakcích alespoň zhruba splněny, jsou získané výsledky zjevně lepsi, než kdybychom se pokoušeli z dat odhadovat pravděpodobnosti  $\mu^{(1|x_{[R]})}$  (viz Janzura (1988a)).

#### Literatura

Bishop, Y. M. M., Fienberg, S. E., Holland, P. W. (1975) Discrete Multivariate Analysis: Theory and Practice. MIT Press, Cambridge, Mass.

Janzura, M. (1986) Estimating interactions in binary data sequences. Kybernetika 22, 277-284.

Janzura, M. (1988a) Prediction in zero-one random sequences. Problems of Control and Information Theory, Vol. 17(1), 15-22.

Janzura, M. (1988b) Test for submodel in Gibbs-Markov binary random sequences (v rukopisu).

Ruelle, D. (1969) Statistical Mechanics. Rigorous Results. Benjamin, New York.