

NMST434 CVIČENIA: OTÁZKY A ODPOVEDE

STANISLAV NAGY

M- A Z-ODHADY (TÝŽDEŇ 7)

Otázka. V prvom cvičení, hned' prvý príklad ste napísali, že \bar{X} je odhad riešenia rovnice $E(X_1 - \mu) = 0$. Čomu ale nerozumiem - pretože, ako to chápem ja, tak M-odhad identifikuje súčasť μ_x , avšak toto μ_x práve minimalizuje funkciu ρ , nie? V skratke - nerozumiem to prepojenie toho M-odhadu a tej strednej hodnoty.

Maximálne vierohodné odhady sú špeciálnym prípadom M-odhadov. Nie všetky M-odhady vychádzajú z maximálne vierohodných odhadov, pre M-odhad si môžem zvoliť akokoľvek funkciu ρ (resp. ψ pre Z-odhad), a typicky M-odhady priamo konštruujem tak, že začнем s funkciou ψ s rozumnými vlastnosťami (napr. obmedzená).

Vzťahy MLE a M-odhadov. V prvom príklade (to je $N(\mu, 1)$ v mojich poznámkach) začнем z MLE odhadu. Vidím, že MLE odhad v modele $N(\mu, 1)$ je definovaný ako M-odhad s funkciou $\rho(x, t) = (x - t)^2$, teda M-odhad identifikuje (odhaduje) parameter rozdelenia daný ako $\arg \min_t E(X - t)^2$. Vieme že toto arg min je práve $t = EX$, takže skutočne M-odhad odhaduje parameter strednej hodnoty. To, že M-odhad identifikuje riešenie rovnice $E(X_1 - \mu) = 0$ dostávam ak formulujem MLE ako Z-odhad pre $\psi(x, t) = (x - t)$. Vtedy skutočne Z-odhad identifikuje riešenie rovnice $E\psi(X, t) = E(X - \mu) = 0$, a riešením je opäť $\mu = EX$.

Predpoklad, že dátá sú z $N(\mu, 1)$ ale vôbec nemusí využívať. Ak by som predpokladal akokoľvek rozdelenie X , a začal priamo s M-odhadom daným funkciou $\rho(x, t) = (x - t)^2$, vidím, že pre túto funkciu dostanem ako M-odhad \bar{X} (výberový priemer), a tento M-odhad identifikuje parameter EX , teda strednú hodnotu. To všetko vychádza priamo z teórie M-odhadov, bez toho aby som akokoľvek použil že som motivačne začal s normálnym rozdelením, alebo s MLE.

To, že ak začнем s MLE pre parameter t , a potom MLE odhad vyjadrim ako M-odhad, a nakoniec sa ukáže že M-odhad skutočne identifikuje parameter t , platí vždy (za splnenia predpokladov MLE, napr. toho že skutočné rozdelenie pochádza z modelu ktorý používam). To je vidieť z toho, že ak $f(x, t)$ je združená hustota náhodného výberu tak MLE definujem ako Z-odhad daný ako riešenie (f' je derivácia f podľa t)

$$f'(x, t)/f(x, t) = 0$$

takže $\psi(x, t) = f'(x, t)/f(x, t)$, a Z-odhad identifikuje parameter $E f'(X, t)/f(X, t) = \int \frac{f'(x, t)}{f(x, t)} f(x, t) dx = \int f'(x, t) dx$, a ten posledný integrál bude 0 ak zameníte poradie derivácie a integrálu. Takže skutočne, za platnosti predpokladaného modelu, váš M- (resp. Z-) odhad správne identifikuje parameter t .

Výhoda toho, že sa na MLE pozeráte ako na M-odhad je tá, že v odvodení as. rozdelenia M-odhadov nepredpokladáte platnosť modelu v ktorom ste začínali pri MLE. As.

E-mail address: nagy@karlin.mff.cuni.cz.

Date: 5. mája 2020.

rozptyl je daný sandwichovým odhadom, ktorý je zložitejší, ale platí aj pri porušení predpokladov MLE. Takže získavate možnosť, ako napr. získať MLE odhady, ale v prípade, že platnosť základných predpokladov nie je splnená, stále dokážete konzistentne odhadovať as. rozdelenie M-odhadu a robiť testy.

Otázka. *Prvá otázka generuje vlastne túto otázku - tá identifikovateľnosť znamená, že sa snažíme nájsť odhady s určitými vlastnosťami? Napr. v normálnom rozdelení, sigma nijak neovplyvňuje tú identifikovateľnosť? Resp. obecne nejaký rušivý parameter?*

Identifikovateľnosť znamená, že ak chcem odhadovať (alebo testovať) o parametre θ , a test založím na M-odhade danom funkciou $\rho(x, t)$, tak $\theta = \arg \min_t E \rho(X, t)$. Takže moje M-odhady skutočne zodpovedajú parametru, ktorý ma zaujímal na začiatku. To musím vždy overiť, pretože inak M-odhady ktoré dostávam budú v skutočnosti odhadovať niečo iné ako parameter θ ktorý ma zaujíma, a sú pre môj problém úplne nanič.

V MLE pre normálne rozdelenie $N(\mu, \sigma^2)$ (druhý príklad na prvej strane poznámok) vidíte, že funkcia $\rho(x, \mu, \sigma^2) = (x - \mu)^2 / \sigma^2 + \log(\sigma^2)$. Pre ľubovoľnú hodnotu σ^2 bude tento výraz minimalizovaný v μ v strednej hodnote práve vtedy ak $E(X - \mu)^2$ je minimalizované, takže opäť identifikujeme $\mu = E X$ a všetko je OK. Pre druhú zložku, po zderivovaní rho podľa σ^2 a jednoduchej úprave dostávam že druhý parameter je identifikovaný ako riešenie $E(X - \mu)^2 - \sigma^2 = 0$, z prvej zložky viem že μ identifikuje $E X$, a teda riešenie v σ^2 je skutočne $E(X - E X)^2$, rozptyl. Opäť OK.

Otázka. *Trochu nerozumiem, ako si tú domácu úlohu 10 formulovať. Ja sa to snažím nejak spojiť s vaším príkladom z cvičení - príklad estimaton of location and scatter.*

Nie, v DÚ žiadny scatter parameter nie je. Iba location parameter. Máte daný nejaký model, tj nejaké rozdelenie s parametrami ϵ a ν , a tri rôzne odhady parametra polohy ktoré sa dajú vyjadriť ako M-odhady. Vašou úlohou je vyjadriť tieto odhady ako M-odhady, a použiť vety 9 alebo 10 na odvodenie as. rozdelenia týchto M-odhadov, za platnosti tohto predpokladaného modelu. Potom chcem nech sa zamyslíte aké parametre vo vašom modele tieto tri rôzne M-odhady identifikujú. Ide o rovnaký parameter, alebo odhadujete vždy niečo iné? A nakoniec, ak ide o rovnaký parameter, ktorý z odhadov sa zdá byť najlepší v zmysle najmenšieho as. rozptylu? Samozrejme v závislosti na parametroch modelu ϵ , ν , a možných ďalších parametroch ktoré sa pri výpočte objavia.

Nakoniec sa zamyslite prečo sa zdá, že pre nejaké hodnoty ϵ , ν je najlepší ten alebo ten odhad. Dávajú tieto asymptotické výsledky nejaký zmysel? Máte k týmto výsledkom nejakú intuiciu?

Otázka. *Chcel som Vás poprosiť o hint, ako sa generujú zmesi rozdelení.*

Zmesi rozdelení sa typicky generujú dvojfázovo. Najprv si generujete náhodný výber z $Alt(p)$ rozdelenia, a každej zložke ak dostanete 0 generujete X z distribučnej funkcie F_0 , ak dostanete 1 generujete X z distribučnej funkcie F_1 . Overte si, že výsledné rozdelenie z ktorého generujete X má (nepodmienene) distribučnú funkciu $p F_1 + (1 - p) F_0$.

M- a Z-ODHADY (TÝŽDEŇ 8)

Otázka. *Ve vašich poznámkách k M- a Z-odhadům na webu na straně 6 dole - symboly X a Y používáte ako označení generického vektoru z něhož pochází ten náhodný výběr? Tedy Y je náh. veličina, X je náh vektor délky p ? Pak pri výpočtu $\psi(x, y, \beta) = -2x(y - x^\top \beta)$ platí, že násobím číslo (-2) krát vektor (x) krát číslo $(y - x^\top \beta)$? A podobně ve výpočtu Sigma matice: $X(Y - X^\top \beta)(Y - X^\top \beta)^\top X^\top$ je vlastně vektor * číslo * vektor?*

Áno, X a Y sú generické náhodné veličiny, tj X je stĺpcový vektor s dimensiou povedzme p , a Y je skalár. Ďalej presne ako píšete - ψ je stĺpcový vektor p funkcií, a Σ je $p \times p$ matica.

Otázka. V úkolu HW11, môžeme predpokladať homoskedasticitu — tj. $\text{var}(Y|X) = \text{var}(\varepsilon|X) = \sigma^2$? Nebo máme obecné predpoklady, že $\text{var}(Y|X) = \sigma^2(X)$, tedy niejaká funkce (tj. heteroskedasticita)? Pokud nemáme homoskedasticitu, jak môžu porovnať odhad s odhadom LAD, ktorý má tvar využívajúci hustotu ε (tedy pre normálni rozdelení i její rozptyl). Napadá mě pouze použít odhad ve stejném tvaru, jen použít podmíněnou hustotu $\varepsilon|X$, čímž pak tato hustota môže mít rozptyl $\sigma^2(X)$. Uvažuju správně?

V predpokladoch homoskedasticita nie je, takže ak riešenie dokážete odvodiť aj bez nej, nepredpokladajte ju. Ak sa to ukáže ako zásadný problém, môžete si príklad zjednodušiť a pridať rozumné ďalšie predpoklady. V porovnaní s LAD sa bude stačiť obmedziť na homoskedastický model, čo bude špeciálny prípad výsledkov z (i)-(iii). Nemusíte odvodzovať sandwichové odhady pre heteroskedastické LAD.

Otázka. K zadání HW12: Pochopil jsem to správně, že v (i) máme 2 rovnice a máme určiť kdy $a = \alpha$ a zároveň $b = \beta$? Potom v úloze (ii) tedy máme pouze 1 rovnici (derivovanou podle b , resp a) a máme pro ni určiť, kdy $b = \beta$ resp. $a = \alpha$? Postupuji podobne jako ve vašich poznámkách na straně 7, využívám derivace, protože funkce ρ je konvexní a identifikuju pomocí toho vztahu pro ψ . Je tahle úvaha správně, nebo jsem špatne zadání pochopil?

Áno, v časti (i) máte určiť podmienky za ktorých platia obe rovnice zároveň. V časti (ii) slabšie podmienky, kedy stačí, aby platila jedna z rovníc. Postup bude podobný ako v poznámkach na str. 7.

EM-ALGORITMUS (TÝŽDEŇ 10)

Otázka. HW14: Čo je myslené ako measure of uncertainty? Je to niečo ako metrika, ktorá má zobraziť úspešnosť/neúspešnosť klasifikátora?

Ak sa bod x rozhodnete zaradiť do zmesi i , dokážete nejak číselne vyjadriť ako „istý“ si týmto zaradením ste? Ak to dokážete nejakým spôsobom kvantifikovať (napr. u pozorovania x som si na 99% istý že patrí do skupiny 1) tak táto charakteristika je to, čo myslíme „measure of uncertainty“.