

REKURENTNÍ ALGORITMY ODHADOVÁNÍ V LINEÁRNÍM REGRESNÍM MODELU

Jana Novovičová, ÚTIA ČSAV Praha

1. Úvod

Rada úloh identifikace, odhadování, rozpoznávání, klasifikace, plánování, filtrace, extrémální regulace vede na úlohu určení extrému funkce při neúplné informaci. K řešení těchto úloh se používají různé rekurentní algoritmy.

V přehledovém článku (1) jsou vytřeny hlavní etapy rozvoje rekurentních algoritmů optimizace při apriorní neurčitosti a uvedeny způsoby optimalizace samotných algoritmů. Je konstatováno, že optimální rekurentní algoritmy jsou velmi citlivé na nesplnění předpokladů, za kterých byly konstruovány, nebo-li nejsou robustní a uvažují se možnosti odstranění této nerobustnosti na základě apriorní informace jak o pozorováních tak i o řešení.

Poznámka. Metodu odhadování pomocí níž odhad θ_n vypočítáme na základě minulého odhadu θ_{n-1} a nového pozorování y_n podle vztahu

$$\theta_n = f(n-1, \theta_{n-1}, y_n), \quad n=1, 2, \dots,$$

kde f je známá funkce, nazýváme rekurentní metoda a příslušné odhady $\theta_1, \theta_2, \dots, \theta_n$ rekurentní odhady.

Rekurentní algoritmy mají řadu předností: jednoduchost výpočtu, malé požadavky na rozsah paměti počítače, možnost zpracování dat v reálném čase, univerzelnost a rozmanitost.

Na příkladu regresní úlohy ukážeme, jak je možné využít apriorní informaci k zvýšení rychlosti konvergence rekurentních algoritmů a učinit je robustními. Vyložený přístup umožní vybrat z různých možných rekurentních algoritmů ten, který je ve vztahu k apriorní informaci v určitém smyslu optimální (2).

2. Formulace problému: základní předpoklady.

Uvažujme obecný lineární regresní model

$$(2.1) \quad y_N = X_N \theta^* + u_N, \quad N = 1, 2, \dots,$$

kde

$\theta^* = (\theta_1^*, \theta_2^*, \dots, \theta_p^*)^T \in R^p$ je neznámý vektor regresních koeficientů;

$X_N = [x_{ij}]_{i=1,2,\dots,N}^{j=1,2,\dots,p}$ je matice typu ($N \times p$) s řádky $x_i^T = (x_{i1}, x_{i2}, \dots, x_{ip}) \in R^p$, $i=1, 2, \dots, N$;

$u_N = (u_1, u_2, \dots, u_N)^T \in R^N$ je vektor náhodných chyb pozorování, u_i jsou nezávislé stejně rozdělené náhodné veličiny s distribuční funkcí F ;

$y_N = (y_1, y_2, \dots, y_N)^T \in R^N$ je vektor nezávislých pozorování takový, že $y_i, i=1, 2, \dots, N$ má distribuční funkci $F(y - x_i^T \theta^*)$.

Úloha: Odhadnout na základě naměřených y_i a naměřených nebo dáných $x_i, i=1, 2, \dots, N$ neznámý vektor θ^* .

Řešení: Je možné použít jak nerekurentní metody (např. metodu maximální věrohodnosti (ML) nebo metodu nejménších čtverců (LS)), tak metody rekurentní (např. typu stochastických approximací (SA) nebo rekurentní metodu nejménších čtverců (RLS)). Ve zmíněných rekurentních metodách se odhad θ_n vypočítá z předcházejícího odhadu θ_{n-1} na základě nové informace (to je veličin y_n , x_n).

Obecný přístup ke konstrukci rekurentních algoritmů spočívá v následujícím. Zvolíme nějakou skalerní funkci $\varphi(z)$ (ztrátová funkce) a hledáme minimum funkcionálu

$$(2.2) \quad J(\theta) = E \varphi(y - x^T \theta) = \min_{\theta}$$

Za určitých podmínek nabývá $J(\theta)$ svého minima v bodě θ^* . K minimalizaci lze použít stochastickou gradientní metodu, která dává odhady ve tvaru

$$(2.3) \quad \boldsymbol{\theta}_n = \boldsymbol{\theta}_{n-1} + P_n \boldsymbol{\psi}_n (\mathbf{y}_n - \boldsymbol{\Sigma}_n^T \boldsymbol{\theta}_{n-1}), \quad n=1,2,\dots,$$

kde $\boldsymbol{\psi} = \boldsymbol{\beta}'$, P_n je nějaká matici (koeficient zesílení). Četné konkrétní algoritmy se vzájemně liší způsobem výběru matici P_n a funkce $\boldsymbol{\psi}$.

Ukážeme, že matici P_n a funkci $\boldsymbol{\psi}$ můžeme vybrat na základě apriorní informace, kterou máme k dispozici, v určitém smyslu optimálním způsobem.

Poznámka. Odhad $\hat{\boldsymbol{\theta}}$ neznámého $\boldsymbol{\theta}^*$ určený posloupností $\boldsymbol{\theta}_n$ generovanou algoritmem (2.3) nazýváme odhad odpovídající funkci $\boldsymbol{\psi}$.

Zabyvejme se tedy modelem (2.1) a algoritmem (2.3). Uděláme následující předpoklady.

A1. Distribuční funkce $F(z)$ je symetrická kolem nuly ($F(z) = 1 - F(-z)$).

A2. Vektory $\boldsymbol{\chi}_i, i=1,2,\dots,N$ jsou nezávislé (mezi sebou i s u_i) náhodné stejně rozdělené. Kovarianční matici $\boldsymbol{\Sigma} = E[\boldsymbol{\chi} \boldsymbol{\chi}^T]$ je konečná a pozitivně definitní ($\boldsymbol{\Sigma} > 0$).

A3. Matici P_n mají tvar $P_n = P_n^* P$, kde P je symetrická, $P > 0$, skalárni činitelé $\gamma_n > 0$, $\sum_{n=1}^{\infty} \gamma_n = \infty$, $\sum_{n=1}^{\infty} \gamma_n^2 < \infty$.

A4. Funkce $\boldsymbol{\psi}(z)$, $z \in \mathbb{R}^1$ je lichá ($\boldsymbol{\psi}(-z) = -\boldsymbol{\psi}(z)$) a spojitá až na konečný počet bodů.

$$\text{Označme } E_F \boldsymbol{\psi}^2 = \int \boldsymbol{\psi}^2(z) dF(z)$$

$$\text{a předpokládáme } E_F \boldsymbol{\psi}^2 < \infty.$$

A5. Buď A5₁. Funkce $\boldsymbol{\psi}$ je neklesající; existuje z_0 takové, že pro každé $\epsilon > 0$ platí

$$\begin{aligned} \boldsymbol{\psi}(z_0 + \epsilon) &> \boldsymbol{\psi}(z_0 - \epsilon) \\ F(z_0 + \epsilon) &> F(z_0 - \epsilon); \end{aligned}$$

nebo A5₂. Existuje ryze unimodální hustota $f(z) = dF(z)/dz$, $f(0) < \infty$ ($f(z_1) < f(z_2)$ pro $|z_1| > |z_2|$).

A6. Buď A6₁. $|\boldsymbol{\psi}(z)| \leq \lambda(1 + |z|)$, λ konstanta, $\int_{\mathbb{R}^1} z^2 dF(z) < \infty$, $E[|z|^2] < \infty$;

nebo A6₂. $|\boldsymbol{\psi}(z)| \leq \lambda$ pro všechna $z \in \mathbb{R}^1$.

A7. Funkce

$$m(\alpha) = - \int_{\mathbb{R}^1} \boldsymbol{\psi}(z-\alpha) dF(z)$$

je derivovatelná v nule a $0 < m'(0) < \infty$.

Nyní jsme připraveni zformulovat základní výsledky.

3. Konvergencie a rychlosť konvergencie.

Níže uvedený výsledek ukazuje univerzálnost rekurentních algoritmů tvaru (2.3). Konvergují s pravděpodobností 1 ke skutečné hodnotě $\boldsymbol{\theta}^*$ za dosti obecných předpokladů o náhodných chybách, o funkci $\boldsymbol{\psi}$ a matici P_n .

Veta 1. ("konzistence") Za předpokladů A1-A6 odhad $\boldsymbol{\theta}_n$ v algoritmu (2.3) konverguje k $\boldsymbol{\theta}^*$ skoro jistě.

Důkaz. Opírá se o obecné výsledky teorie stochastických approximací Robbins-Monroova typu(3).

Skutečnost, že algoritmus konverguje, nestačí pro rozhodnutí, který algoritmus použít. Rozhodující je rychlosť konvergence. Zde vzniká řada obtíží (4). Za prvé existují různé charakteristiky rychlosti konvergence (je možné odhadovat $E\|\boldsymbol{\theta}_n - \boldsymbol{\theta}^*\|^2$, $E(J(\boldsymbol{\theta}_n) - J(\boldsymbol{\theta}^*))$, $P(\|\boldsymbol{\theta}_n - \boldsymbol{\theta}^*\| \leq \epsilon_n)$, $P(J(\boldsymbol{\theta}_n) \leq J(\boldsymbol{\theta}^*) + \epsilon_n)$ atd.). Za druhé, obvykle se podaří získat pouze odhady shora těchto charakteristik. Prítom není jasné, do jaké míry je možné důvěřovat podobným odhadům a vybírat algoritmus na jejich základě. Tento těžkosti odpadají, jestliže uvažujeme asymptotickou rychlosť konvergence. Dokážeme-li, že pro odhad pořízený rekurentním vztahem je $\sqrt{n}(\boldsymbol{\theta}_n - \boldsymbol{\theta}^*)$ asymptoticky normální s nulovým středem a asymptotickou kovarianční maticí K (dále ASKO), pak K není pouze odhadem shora, ale adekvátní charakteristikou chování rekurentního procesu pro velká n . Tato charakteristika je vyčerpávající, neboť jak známo, normální rozdělení je úplně popsané středem a kovarianční maticí. Jestliže se ukáže, že pro jeden algoritmus je K menší (v maticovém

smyslu) než pro jiný, pak i libovolná rozumná skalární charakteristika přesnosti pro první algoritmus je lepší. To co bylo řečeno, objasňuje, proč další závěry a srovnání algoritmů je založeno na asymptotické rychlosti konvergence.

VĚTA 2. ("asymptotická normalita"). Nechť jsou splněny předpoklady A1-A7, $\gamma_n = 1/n$ a matici $A = -m'(0)P\Sigma + 1/2 I$ je stabilní (I je jednotková matice), pak $\sqrt{n}(\theta_n - \theta^*)$ má asymptoticky p-rozměrné normální rozdělení s nulovým středem a ASKO K , to je

$$\mathcal{L}(\sqrt{n}(\theta_n - \theta^*)) \xrightarrow{n \rightarrow \infty} N_p(0, K),$$

kde K je řešení maticové rovnice

$$(3.1) \quad A K + K A^T = -E_P \psi^2 P \Sigma P.$$

Důkaz: Je založen na obecných výsledcích o asymptotické normalitě odhadů stochastických approximací Robbins-Monrova typu (3).

Tudíž asymptotická rychlosť konvergence algoritmu měřená maticí K , závisí na vlastnostech chyb pozorování, na funkci ψ a na matici P_n .

Ve dvou speciálních případech může být maticová rovnice (3.1) vyřešena explicitně.

i) Nechť $P = \gamma_M \Sigma^{-1}$, to je $P_n = (\gamma_M/n) \Sigma^{-1}$ - maticový koeficient zesílení. Potom pro $2 \cdot m'(0) \gamma_M > 1$ je matice A stabilní a

$$K_M = \frac{\gamma^2 E_P \psi^2}{2 \gamma M'(0) - 1} \Sigma^{-1}.$$

ii) Nechť $P = \gamma_S I$, to je $P_n = (\gamma_S/n) I$ - skalární koeficient zesílení. Jestliže $2 \cdot m'(0) \cdot k \cdot \gamma_S > 1$, $k = (\|\Sigma^{-1}\|)^{-1}$, pak A je stabilní a

$$K_S = \frac{\gamma^2 E_P \psi^2}{4 m'(0)} (2 I - A^{-1}).$$

Dříve než přistoupíme k otázce výběru algoritmu optimálního ve smyslu největší asymptotické rychlosti konvergence, uvedeme příklady rekurentních algoritmů odpovídajících různým funkcím ψ .

Předpokládejme, že jsou splněny předpoklady A1-A3. Zavedeme označení $\Delta_n = (y_n - x_n^T \theta_{n-1})$.

A) Proporcionalní algoritmus: $\psi(z) = z$.

$$\theta_n = \theta_{n-1} + P_n x_n \Delta_n.$$

Jestliže má náhodná chyba omezený rozptyl $E u^2 = \sigma^2$, $E \|x\|^4 < \infty$, pak $\theta_n \xrightarrow{a.s.} \theta^*$. Pro $P_n = (\gamma/n) \Sigma^{-1}$, $\gamma > 1/2$ je $K = \sigma^2 \gamma^2 (2\gamma - 1)^{-1} \Sigma^{-1}$.

B) Znaménkový algoritmus: $\psi(z) = \text{sign}(z)$.

$$\theta_n = \theta_{n-1} + P_n x_n \text{sign}(\Delta_n).$$

Myšlenka znaménkového algoritmu připadá Fabiánovi, konvergenci dokázal Poljak.

C) Releový algoritmus s intervalem necitlivosti:

$$\psi(z) = \begin{cases} 0, & |z| \leq d, \\ \text{sign}(z), & |z| > d. \end{cases}$$

Jestliže d je bodem růstu funkce $F(z)$, pak podle věty 1 $\theta_n \rightarrow \theta^*$ skoro jistě. Jestliže v okolí bodu d existuje $f(z)$ spojitá v d , $f(d) > 0$, pak lze použít větu 2.

D) Proporcionalní algoritmus s namycením:

$$\psi(z) = \begin{cases} z, & |z| \leq d, \\ d \cdot \text{sign}(z), & |z| > d. \end{cases}$$

Jestliže $F(z)$ není konstantní v intervalu $(-d, d)$, pak platí věta 1. Je-li $F(z)$ spojitá v d , pak je použitelná věta 2.

E) Proporcionalní algoritmus s usoknutím:

$$\psi(z) = \begin{cases} z, & |z| \leq d, \\ 0, & |z| > d. \end{cases}$$

Funkce ψ není rostoucí. Za předpokladu A5₂ algoritmus konverguje. Jestliže $f(z)$ je spojitá

v A, pak platí věta 2.

4. Optimální algoritmus.

Vzhledem k tomu, co bylo řečeno v odstavci 3 zvolíme přístup k optimálnitě algoritmu (2.3) založený na asymptotické rychlosti konvergence. Matice K , která je mírou asymptotické rychlosti konvergence algoritmu tvaru (2.3), závisí na distribuční funkci F , na funkci ψ a na matici P_n .

i) Výběr matice P_n .

Lze dokázat, že mezi všechny algoritmy (2.3) s danou funkcií ψ a F má minimální ASKO ten algoritmus, ve kterém

$$P_n = (n \cdot m'(0) \Sigma)^{-1},$$

tudíž volba $\gamma = (m'(0))^{-1}$ vede na algoritmus s ASKO

$$(4.1) \quad K(\psi, F) = \frac{E_F \psi^2}{(m'(0))^2} \sum^{-1} = \sigma^2(\psi, F) \Sigma^{-1}.$$

Asymptotická kovarianční matice daná (4.1) je shodná s asymptotickou kovarianční maticí M-odhadu.

ii) Výběr funkce ψ .

Abychom mohli vybrat funkci ψ , která minimalizuje matici $K(\psi, F)$ musíme udělat některé doplňující předpoklady.

A8. Existuje hustota $f(z) = dF(z)/dz$, je absolutně spojitá a má konečnou Fisherovou informaci

$$J(f) = \int_{\mathbb{R}^d} (f'(z)/f(z))^2 f(z) dz < \infty.$$

$$A9. \quad m'(0) = - \int_{\mathbb{R}^d} \psi f'(z) dz.$$

Věta 3. ("asymptotická optimálnita odhadů"). Nechť jsou splněny A1-A2, existuje absolutně spojitá hustota $f(z) = dF(z)/dz$, přičemž $\psi = -f'/f$ vyhovuje předpokladům A4-A7 a je splněn A9, pak algoritmus

$$(4.3) \quad \theta_n = \theta_{n-1} + (n J(f) \Sigma)^{-1} x_n \psi(\Delta_n),$$
$$\psi(z) = -(log f(z))'$$

je asymptoticky eficientní.

Důkaz. Závislost $K(\psi, f)$ na ψ je obsažena ve skalárním činiteli $\sigma^2(\psi, f)$ před pozitivně definitní maticí Σ v (4.1). Pomocí Cauchy-Buniakovského nerovnosti dostaneme

$$\sigma^2(\psi, f) = \frac{\int_{\mathbb{R}^d} \psi^2 f dz}{(\int_{\mathbb{R}^d} \psi f' dz)^2} \geq \frac{1}{\int_{\mathbb{R}^d} (f'/f)^2 f dz} = (J(f))^{-1}$$

a rovnost nastane právě tehdy, když $\psi = k \cdot f'/f$, k je libovolná konstanta. Tudíž pro $\psi = -(log f)'$ dostaneme

$$K(\psi, f) = (J(f) \Sigma)^{-1},$$

což je Rao-Cramerova dolní hranice pro nestranné odhady a tudíž odhad (4.3) je asymptoticky eficientní.

Jinými slovy věta 3 říká, že rekurentní odhad (4.3) je asymptoticky optimální nejen mezi všechny rekurentními odhady, ale mezi všechny nestrannými odhady (tím i nerekurentními).

Speciálně použijeme-li k řešení úlohy odhadu vektoru θ^* v modelu (2.1) metodu ML, to je

$$\theta_n = \arg \min_{\theta} \sum_{i=1}^n \rho(y_i - x_i^T \theta), \quad \rho(z) = -\log f(z),$$

nedostaneme lepší odhady. Algoritmus (4.3) je možné považovat za rekurentní verzi metody ML.

V matici zesílení P_n vystupuje kovarianční matice Σ . Ještěže informace o rozdělení vstupních veličin chybí, pak tato matice není známá. V tom případě můžeme matici Σ nahradit její výběrovou hodnotou $\Sigma_n = n^{-1} \sum_{i=1}^n x_i x_i^T$ a maticový koeficient zesílení můžeme vypočítat

rekurentně

$$P_n = (n \mathcal{J}(f) \Sigma_n)^{-1} = (\mathcal{J}(f) \sum_{i=1}^n x_i x_i^T)^{-1} = (\mathcal{J}(f) \sum_{i=1}^{n-1} x_i x_i^T + \mathcal{J}(f) x_n x_n^T)^{-1} = \\ P_{n-1} - \frac{P_{n-1} x_n x_n^T P_{n-1}}{(\mathcal{J}(f))^{-1} + x_n^T P_{n-1} x_n}$$

Asymptoticky optimální algoritmus má pak tvar

$$(4.4) \quad \theta_n = \theta_{n-1} + P_n x_n \Psi(\Delta_n), \quad \Psi(z) = -(log f(z))', \\ P_n = P_{n-1} - \frac{P_{n-1} x_n x_n^T P_{n-1}}{(\mathcal{J}(f))^{-1} + x_n^T P_{n-1} x_n}$$

Dá se dokázat, že při libovolném počátečním P_0 jsou asymptotické vlastnosti (4.3) a (4.4) stejné.

Pro normální rozdělení chyb přechází algoritmus (4.4) v rekurentní metodu LS.

Asymptoticky optimální rekurentní algoritmus představuje spojení dvou algoritmů: algoritmu odhadu řešení úlohy a algoritmu pro matici zesílení. První závisí na pozorováních, druhý pouze na vstupních veličinách.

5. Robustní optimální rekurentní algoritmus

Abychom mohli použít optimální algoritmus (4.4), musíme znát hustotu pravděpodobnosti rozdělení náhodných chyb. Malé odchyly od předpokladů, za kterých byly optimální algoritmy konstruovány, vedou k velkým odchylkám odhadů od optimálního řešení. Jinými slovy tyto algoritmy nejsou robustní.

Příčinou nerobustnosti asymptoticky optimálních algoritmů je jejich informační neurčitost: vycházíme totiž z toho, že všechny předpoklady, na jejichž základě byl algoritmus zkonstruován, jsou přesné, zatím co mají pouze přibližný charakter. Proto při konstrukci optimálních algoritmů je třeba brát v úvahu apriorní informaci, která je k dispozici (i když většinou obecného charakteru) a tak odstranit informační neurčitost. Apriorní informace o pozorováních zahrnuje apriorní informaci o náhodných chybách pozorování a apriorní informaci o vstupních veličinách.

Apriorní informace může být vyjádřena zadáním nějaké třídy rozdělení, do které patří neznámé hustoty pravděpodobnosti. Typickými třídami je třída všech hustot rozdělení pravděpodobnosti, třída rozdělení s omezeným rozptylem, třída směsi dvou rozdělení, třída finitních rozdělení nebo třída přibližně finitních rozdělení.

Konstrukci asymptoticky optimálního robustního algoritmu použijeme Huberův přístup k robustnosti (5).

V souladu s Huberovou myšlenkou budeme předpokládat, že je známa pouze nějaká třída rozdělení náhodných chyb a optimálním rekurentním algoritmem budeme rozumět minimaxově optimální vzhledem ke třídě rozdělení. V tomto smyslu bude zkonstruovaný algoritmus robustní.

Předpokládejme, že je známa třída \mathcal{F} , do níž patří hustota náhodných chyb. Potom pro algoritmus (2.3) a $P_n = (n \cdot n'(0) \Sigma)^{-1}$ s libovolnou funkcí $\Psi(z)$ za platnosti předpokladů věty 2 má ASKO tvar

$$K(\Psi, f) = \frac{\mathbb{E}_f \Psi^2}{\left(\int \Psi f' dz \right)^2 \Sigma^{-1}} = \sigma^2(\Psi, f) \Sigma^{-1},$$

které je pro dané Ψ minimální.

Vybereme nyní $\Psi = \Psi_0$ optimálně ve smyslu minimaxu skalárního činitele $\sigma^2(\Psi, f)$, to je pro optimální Ψ bude platit

$$(5.1) \quad \sup_{f \in \mathcal{F}} \sigma^2(\psi, f) = \inf_{\psi} \sup_{f \in \mathcal{F}} \sigma^2(\psi, f).$$

Řešení této úlohy spočívá v nalezení "nejméně příznivé" hustoty třídy \mathcal{F} .

Definice: Nejméně příznivou hustotou třídy \mathcal{F} nazýváme hustotu f_* , pro kterou platí

$$\mathcal{J}(f) \leq \mathcal{J}(f) < \infty \quad \text{pro všechna } f \in \mathcal{F}.$$

Odpověď na otázku, která volba ψ_* vede ke splnění (5.1) dává následující větu.

VĚTA 4. ("minimaxovost odhadu"). Nechť \mathcal{F} je konvexní třída rozdělení majících absolutně spojitu hustotu f s $\mathcal{J}(f) < \infty$ a nechť existuje $f \in \mathcal{F}$ pro které $\mathcal{J}(f_*) \leq \mathcal{J}(f)$ pro všechna $f \in \mathcal{F}$. Nechť $f \in \mathcal{F}_*$

$$\psi_* = -f'_*/f_* = -(\log f_*)'$$

splňují předpoklady A1, A2, A4-A7. Potom odhady dané algoritmem

$$(5.2) \quad \theta_n = \theta_{n-1} + (n \cdot m'_F(0) \Sigma)^{-1} \mathbf{x}_n \psi_*(\Delta_n),$$

kde

$$m'_F(0) = - \int_{R^d} \psi_*(z) f'(z) dz$$

jsou asymptoticky normální s ASKO

$$K(\psi_*, f) \leq K(\psi_*, f_*) = (\mathcal{J}(f_*) \Sigma)^{-1}.$$

Jinými slovy pro libovolné $f \in \mathcal{F}$ je zaručena kvalita odhadu matici $K(\psi_*, f_*)$.

Vzhledem k tomu, že pro $f = f_*$ je algoritmus (5.2) asymptoticky eficientní (věta 3), je (5.2) asymptoticky optimální ve smyslu minimaxu vzhledem ke třídě \mathcal{F} .

6. Použití optimálního robustního rekurentního algoritmu.

Abychom mohli použít algoritmus (5.2) potřebujeme:

A) na základě apriorní informace určit třídu \mathcal{F} a najít $f_* = \arg \min_{f \in \mathcal{F}} \mathcal{J}(f)$

V článku (6) jsou nalezeny nejméně příznivé hustoty pro několik tříd;

B) vzhledem k tomu, že neznáme skutečnou hustotu f , approximovat $m'_F(0)$ nahrazením f empirickou hustotou

$$m'_F(0) \approx n^{-1} \sum_{i=1}^n \psi'_*(y_i - \mathbf{x}_i^T \theta^*) \approx n^{-1} \sum_{i=1}^n \psi'_*(y_i - \mathbf{x}_i^T \theta_{i-1}) = n^{-1} \sum_{i=1}^n \psi'_*(\Delta_i);$$

C) v případě, že chybí informace o rozdělení vstupních veličin, nahredit neznámou matici Σ její výběrovou hodnotou $\Sigma_n = n^{-1} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T$

a odpovídající matici P_n počítat rekurentně

$$P_n = P_{n-1} - \frac{P_{n-1} \mathbf{x}_n \mathbf{x}_n^T P_{n-1}}{(\psi'_*(\Delta_n))^{-1} + \mathbf{x}_n^T P_n \mathbf{x}_n};$$

D) znát počáteční podmínky θ_0 , P_0 . Vhodně zvolené počáteční podmínky zvyšují rychlosť konvergence. Je vhodné zvolit za počáteční odhad θ_0 v algoritmu (5.3) odhad metodou LS pro malé N_0 a položit $P_0 = (\mathbf{x}_N^T \mathbf{x}_N)^{-1}$.

Použitím identity

$$P_n \mathbf{x}_n = \frac{P_{n-1} \mathbf{x}_n}{(\psi'_*(\Delta_n))^{-1} + \mathbf{x}_n^T P_{n-1} \mathbf{x}_n}$$

a označení

$$\mathbf{v}_n = \mathbf{P}_{n-1} \mathbf{x}_n , \quad r_n = \mathbf{x}_n^T \mathbf{v}_n .$$

můžeme algoritmus přepsat na tvar

$$(6.1) \quad \begin{aligned} \theta_n &= \theta_{n-1} + \frac{1}{(\psi'(\Delta_n))^{-1} + r_n} \mathbf{v}_n \psi'_e(\Delta_n) , \\ \mathbf{P}_n &= \mathbf{P}_{n-1} - \frac{1}{(\psi'(\Delta_n))^{-1} + r_n} \mathbf{v}_n \mathbf{v}_n^T . \end{aligned}$$

v případě, že $\psi'_e(\Delta) = 0$, položíme $\psi'_e(\Delta) = (1/\Delta)\psi_e(\Delta)$.

Příklady optimálních robustních algoritmů

A_R) $\mathcal{F}_1 = \{f: f(z) \text{ spojitá v } 0, f(0) \geq a > 0\}$ - třída libovolných ne degenerovaných rozdělení. Potom f_e je hustota Laplaceova rozdělení, $\psi_e = 2a \operatorname{sign}(z)$. Tudiž znaménkový algoritmus je robustní optimální algoritmus, jestliže chybí informace o rozdělení náhodných chyb pozorování.

B_R) $\mathcal{F}_2 = \{f: \int z^2 f(z) dz \leq \sigma^2\}$. Pak f_e je hustota normálního rozdělení $N(0, \sigma^2)$, $\psi_e = z/\sigma^2$. Proporcionalní algoritmus je optimální robustní ve třídě rozdělení s omezeným rozptylem.

C_R) $\mathcal{F}_3 = \{f: f = (1-\epsilon) f_N + \epsilon h, f_N \text{ je hustota } N(0, \sigma^2), h \text{ je libovolná}\}$ - třída ϵ -normálních rozdělení (normálních s ϵ -přiměsí). Potom $\psi_e = z/\sigma^2$ v intervalu $(-d, d)$ a $\psi_e = (d/\sigma^2) \operatorname{sign}(z)$ vně intervalu $(-d, d)$. Jinými slovy proporcionalní algoritmus s nasycením je optimální robustní ve třídě přibližně normálních rozdělení. Závislost d na ϵ a σ je uvedena např. v (6).

D_R) $\mathcal{F}_4 = \{f: f = (1-\epsilon) f_R + \epsilon h, f_R = 1/2d \text{ pro } |z| \leq d, f_R = 0 \text{ pro } |z| > d, h \text{ je libovolná hustota}\}$ - třída přibližně rovnoramenných rozdělení. Potom $\psi_e(z) = 0$ pro $|z| \leq d$, $\psi_e(z) = ((1-\epsilon)/(\epsilon d)) \operatorname{sign}(z)$ pro $|z| > d$; to znamená, že reeleový algoritmus s intervalem necitlivosti je optimální robustní pro tuto třídu.

7. Doplňující poznámky.

a) Výsledky o rychlosti konvergence a z nich udělané závěry mají asymptotický charakter. Optimální robustní algoritmy pracují dobře i při malých n , jak ukazují zkušenosti s jejich používáním.

b) Uvažovali jsme pouze lineární model. Všechny výsledky platí též pro model

$$y_n = \varphi(\mathbf{x}_n)^T \boldsymbol{\theta}^* + u_n, \quad n=1, 2, \dots$$

Pro nelineární model

$$y_n = g(\mathbf{x}_n, \boldsymbol{\theta}^*) + u_n, \quad n=1, 2, \dots$$

je možné použít stejný algoritmus jako (2.3)

$$\theta_n = \theta_{n-1} + P_n V_\Theta g(\mathbf{x}_n, \boldsymbol{\theta}_{n-1}) \psi(g(\mathbf{x}_n, \boldsymbol{\theta}_{n-1}) - y_n)$$

s doplňujícími předpoklady o funkci g

$$(g(\mathbf{x}, \boldsymbol{\theta}) - g(\mathbf{x}, \boldsymbol{\theta}^*)) (\nabla_{\boldsymbol{\theta}} g(\mathbf{x}, \boldsymbol{\theta})^T (\boldsymbol{\theta} - \boldsymbol{\theta}^*)) \geq 0$$

pro všechna \mathbf{x} , $\boldsymbol{\theta}$ a také podmínky na růst funkce podle $\boldsymbol{\theta}$.

c) Uvažované algoritmy byly rekurentními modifikacemi odhadů typu

$$(7.1) \quad \boldsymbol{\theta}_n = \arg \min_{\boldsymbol{\theta}} \sum_{i=1}^n \varphi(y_i - \mathbf{x}_i^T \boldsymbol{\theta}) .$$

Speciálním případem (7.1) jsou odhady metodou ML a M-odhadu Hubera. Konvergenci těchto odhadů je možné dokázat za slabších předpokladů než jejich rekurentní verze. Avšak z výpočetního hlediska jsou méně vhodné-explicitní tvar odhadu (7.1) dostaneme pouze ve vyjímečných případech a je třeba uchovávat v paměti počítače všechna $y_1, \mathbf{x}_1, i=1, 2, \dots, n$.

Literature

- (1) Tsyplkin Ya.Z.(1979).Adaptive optimization algorithms under apriori uncertainty.Automation and Remote Control,6,94-108.
- (2) Poljak B.T. and Tsyplkin Ya.Z.(1980).Adaptive estimation Algorithms.Automation and Remote Control,3,71-84.
- (3) Nevelson M.B. and Has'minskij R.Z.(1972).Stochastic approximation a recursive estimation, Moscow.
- (4) Poljak B.T. and Tsyplkin Ya.Z.(1980).Optimal adaptive pseudogradient algorithms.Automation and Remote Control,8,74-84.
- (5) Huber P.J.(1964).Robust estimation of a location parameter.Ann.Math.Statist.35,73-101.
- (6) Tsyplkin Ya.Z. and Poljak B.T.(1977).Robustized maximum likelihood method.In Dynamics of Systems,vol.12,Gorkij University Press,22-46.