

Μάθηση k-τροπικών κατανομών μέσω δοκιμών

Learning k-modal distributions via testing

Ιωσήφ Μουλίνος

Εθνικό Μετσόβιο Πολυτεχνείο

8 Ιουνίου 2017

Επιβλεπόμενη μάθηση

Μη επιβλεπόμενη μάθηση

Μάθηση κατανομής πιθανότητας \equiv Εκτίμηση πυκνότητας πιθανότητας

Λαμβάνοντας δείγματα από την κατανομή p εξάγεται υποθετική
κατανομή \hat{p}

Με υψηλή πιθανότητα $d_{TV}(p, \hat{p}) \leq \epsilon$.

$$d_{TV}(p, q) := \max_{S \subseteq [n]} |p(S) - q(S)| = \frac{1}{2} \|p - q\|_1,$$

$$p(S) = \sum_{i \in S} p(i), \quad [n] = 1, 2, 3, \dots, n$$

Πληροφοριοθεωρητικά, για $\epsilon \geq 1/n^{\Omega(1)}$, η μάθηση μονότονης κατανομής απαιτεί $\Omega(\log(n)/\epsilon^3)$ δείγματα [Birgé 1987]

Παραθέτοντας k μονότονα διαστήματα μήκους n/k , κάθε αλγόριθμος μάθησης k τροπικής κατανομής στο $[n]$, με $\epsilon \geq 1/n^{\Omega(1)}$ απαιτεί $\Omega(k \log(n/k)/\epsilon^3)$

Ζητούμενο

Αλγόριθμος με πολυωνυμικό πλήθος δειγμάτων ως προς τον αριθμό των τρόπων και τον λογάριθμο $\log n$ και χρόνο εκτέλεσης $\text{poly}(k, \log n, 1/\epsilon)$

Αλγόριθμος Birgé

p μη αύξουσα κατανομή στο $[n]$.

1. Διαμέριση του $[n]$ σε I_1, \dots, I_ℓ , $\ell = O(m^{1/3} \cdot (\log n)^{2/3})$.

$$\text{Για } j \in [n] \text{ και } i \in I_j, p_f(i) = \sum_{t \in I_j} p(t) / |I_j|$$

$$d_{TV}(p_f, p) = O(m^{1/3} \cdot (\log n)^{2/3})$$

2. Κατανομή p_r στο $[\ell]$ με $p_r(i) = p(I_i)$ για $i \in [\ell]$

Με τα m δείγματα λαμβάνεται κατανομή \hat{p}_r τ.ω.

$$E[d_{TV}(p_r, \hat{p}_r)] = O(\sqrt{\ell/m}) = O((\log n / (m+1))^{1/3})$$

(ανισότητα Varnik-Chervonenkis)

3. Εξάγεται η κατανομή $(\hat{p}_r)_f$ με στήριγμα το $[n]$

Από βήματα 1 και 2:

$$E[d_{TV}((\hat{p}_r)_f, p_f)] = O(\sqrt{\ell/m}) = O((\log n / (m+1))^{1/3})$$

4. Από βήματα 1 και 3:

$$E[d_{TV}((\hat{p}_r)_f, p)] = O(\sqrt{\ell/m}) = O((\log n / (m+1))^{1/3})$$

Μάθηση σχεδόν μονότονων κατανομών

$$\delta := O((\log n / (m + 1))^{1/3})$$

Στα βήματα 2 και 3 μαθαίνεται η κατανομή p_f σε απόσταση διακύμανσης δ

Ισχυρισμός: Αν p είναι τ -κοντά σε μη αύξουσα κατανομή p^\downarrow τότε η p_f ικανοποιεί $d_{TV}(p_f, p) \leq (2\tau + \delta)$

Απόδειξη: $\tau_j = \|p - p^\downarrow\|_1$ στο διάστημα I_j , τότε $\sum_{i=1}^{\ell} \tau_j \leq \tau$
Birgé $\Rightarrow d_{TV}((p^\downarrow)_f, p^\downarrow) = \delta$ άρα $d_{TV}((p^\downarrow)_f, p) = \delta + \tau$ (1)

Σε κάθε διάστημα I_j , $\|p(I_j) - p^\downarrow(I_j)\|_1 \leq \tau_j$ και οι $p_f, (p^\downarrow)_f$ ομοιόμορφες.

$$\Rightarrow d_{TV}(p_f, (p^\downarrow)_f) \leq \tau$$
 (2)

(1),(2), τριγωνική ανισότητα $\Rightarrow d_{TV}(p_f, p) \leq 2\tau + \delta$

Ο αλγόριθμος Birgé μαθαίνει σχεδόν μονότονη κατανομή με απόσταση διακύμανσης $2\tau + 2\delta$

Μάθηση k -τροπικών κατανομών

Αλγόριθμος Birgé σε $\binom{n}{k}$ των πιθανών ακρότατων σημείων
Καλή δειγματική πολυπλοκότητα, μη αποδοτική χρονική
 $\Omega(n^k)$

Διαμέριση του $[n]$ σε k/ϵ διαστήματα με χονδρικά ϵ/k
πιθανότητα το καθένα

k μη μονότονα διαστήματα

συνολικό σφάλμα $O(\epsilon)$

καλή χρονική πολυπλοκότητα $\text{poly}(k, \log n, 1/\epsilon)$

μεγαλύτερη της επιθυμητής δειγματική,

$\Omega(k/\epsilon)$ φορές Birgé με $\Omega(\log(n)/\epsilon^3) \Rightarrow \Omega(k(\log(n)/\epsilon^4))$

Αλγόριθμος ελέγχου μονοτονίας k -τροπικής κατανομής

Ο αλγόριθμος $T^\uparrow(\epsilon, \delta)$ ($T^\downarrow(\epsilon, \delta)$) χρησιμοποιεί $O(\log(1/\delta)) \cdot (k/\epsilon^2)$ δείγματα από k -τροπική κατανομή.

Απαιτήσεις

(Πληρότητα) Εάν η p είναι μη φθίνουσα (μη αύξουσα), τότε ο T^\uparrow (T^\downarrow) δίνει 'ναι' με πιθανότητα τουλάχιστον $1 - \delta$.

(Συνέπεια) Εάν η p είναι ϵ -μακριά από το να είναι μη αύξουσα (μη φθίνουσα), τότε ο T^\uparrow (T^\downarrow) δίνει 'ναι' με πιθανότητα τω πολύ δ .

Ο αλγόριθμος $T^\uparrow(\epsilon, \delta)$ υλοποιείται επαναλαμβάνοντας τον αλγόριθμο T^\uparrow , $O(k/\tau^2)$ φορές.

Δοκιμαστής $T^\uparrow(\tau)$

Είσοδος: $\tau > 0$: δείγματα της k -τροπικής κατανομής q στο $[n]$

1. Λήψη $\Theta(k/\tau^2)$ δειγμάτων s από την q στο $[n]$
2. Εάν υπάρχει $\ell \in [k]$ και $\{\alpha_i, b_i, c_i\}_{i=1}^\ell \in s \cup n$, με $\alpha_i \leq b_i < c_i < \alpha_{i+1}$, $i \in [\ell - 1]$, τ.ω.
$$\sum_{i=1}^\ell T(\hat{q}, \alpha_i, b_i, c_i - 1) \geq \tau/4$$
τότε απάντησε "όχι", άλλως απάντησε "ναι".

Θεώρημα

Ο αλγόριθμος T^\dagger χρησιμοποιεί $O(k/\tau^2)$ δείγματα της q , εκτελεί $\text{poly}(k/\tau) \cdot \log n$ διφυοπράξεις και ικανοποιεί τις απαιτήσεις πληρότητας και συνέπειας.

Λήμμα

Έστω q k -τροπική κατανομή στο $[n]$ που είναι τ μακριά από το να είναι μη φθίνουσα. Υπάρχει $\ell \in [k]$ και $\{\alpha_i, b_i, c_i\}_{i=1}^\ell \subseteq [n]^{3\ell}$ με $\alpha_i \leq b_i < c_i < \alpha_{i+1}$, $i \in [\ell - 1]$, τ.ω.
$$\sum_{i=1}^\ell T(q, \alpha_i, b_i, c_i) \geq \tau/2$$

Απόδειξη λήμματος με αντιθετοαντιστροφή, μειώνοντας βαθμίδον κατά 1 την τροπικότητα της κατανομής, κρατώντας το σφάλμα ελεγχόμενο (θυμίζει Myerson ironing).

Έλεγχος ύπαρξης τριάδων $\{\alpha_i, b_i, c_i\}_{i=1}^{\ell} \in s \cup n$, με

$\alpha_i \leq b_i < c_i < \alpha_{i+1}$, $i \in [\ell - 1]$, τ.ω.

$\sum_{i=1}^{\ell} T(\hat{q}, \alpha_i, b_i, c_i - 1) \geq \tau/4$.

Με ωμή δύναμη $\Omega(r^k) \cdot \log n$.

Θεωρούμε $T(\ell) = \max\{\sum_{i=1}^{\ell} T(\hat{q}, \alpha_i, b_i, c_i - 1) \mid \{\alpha_i, b_i, c_i\}_{i=1}^{\ell} \in s \cup n \text{ with } \alpha_i \leq b_i < c_i < \alpha_{i+1}, i \in [\ell - 1]\}$

Με δυναμικό προγραμματισμό

1. Δειγματοληψία της p σε $r = \Theta(1/\tau^2)$ θέσεις του στηρίγματος, $\tau := \epsilon/(100k)$.
2. Διαμέριση του $[n]$ άπληστα σε ℓ διαστήματα με $\mathcal{I} = \{I_i\}_{i=1}^{\ell}$
 1. $I := [1, j_1]$ με $j_1 := \min\{j \in [n] \mid \hat{p}([1, j]) \geq \frac{\epsilon}{10k}\}$
 2. Για $i \geq 1$ εάν $\cup_{j=1}^i I_j = [1, j_i]$ τότε $I_{i+1} := [j_i + 1, j_{i+1}]$, όπου
εάν $\hat{p}([j_i + 1, n]) \geq \epsilon/(10k)$,
 $j_{i+1} := \min\{j \in [n] \mid \hat{p}([j_i + 1, j]) \geq \epsilon/(10k)\}$
άλλως, $j_{i+1} := n$
3. $\tau' := \epsilon/(2000k)$. Λήψη $r' = \Theta((k^2/\epsilon^3) \cdot \log(1/\tau') \log \log(1/\tau'))$ δειγμάτων s της p
4. Ταυτόχρονη εκτέλεση των αλγορίθμων $T^\uparrow(\epsilon, \tau')$ και $T^\downarrow(\epsilon, \tau')$ στις μερικές κατανομές $p_{\cup_{i=1}^j I_i}$ για $j = 1, 2, \dots$, έως εύρεση I_{j_1} για το οποίο οι $T^\uparrow(\epsilon, \tau')$ και $T^\downarrow(\epsilon, \tau')$ επιστρέψουν "όχι" στο $p_{\cup_{i=1}^{j_1} I_i}$.
 $I_{j_1} = [\alpha_{j_1}, b_{j_1}]$ διακρίνονται 2 περιπτώσεις

Εάν $\hat{p}[\alpha_{j_1}, b_{j_1}] \geq 2\epsilon/(10k)$, όρισε $I'_{j_1} := [\alpha_{j_1}, b_{j_1} - 1]$ και το b_{j_1} είναι βαρύ σημείο.

Εάν $\hat{p}[\alpha_{j_1}, b_{j_1}] < 2\epsilon/(10k)$, όρισε $I'_{j_1} := I_{j_1}$.

Ονόμασε το I'_{j_1} αμελητέο διάστημα. Εάν $j_1 > 1$, όρισε το πρώτο υπερδιάστημα να είναι $\cup_{i=1}^{j_1-1} I_i$ και θέσε το $\alpha_1 \in \{\uparrow, \downarrow\}$ σε \uparrow εάν $T \uparrow$ επέστρεψε "ναι" στο $\rho_{\cup_{i=1}^{j_1-1} I_i}$ και θέσε $\alpha_1 = \downarrow$ εάν $T \downarrow$ επέστρεψε "ναι" στο $\rho_{\cup_{i=1}^{j_1-1} I_i}$.

5. Επανάλαβε το βήμα 4 ξεκινώντας από το επόμενο διάστημα I_{j_1+1} βρες το αριστερότερο διάστημα I_{j_2} για το οποίο αμφότερα τα $T \uparrow$ και $T \downarrow$ επιστρέφουν "όχι" στο $\rho_{\cup_{i=1}^{j_1} I_i}$.

Συνέχισε μέχρι όλα τα διαστήματα ως το I_ℓ να έχουν χρησιμοποιηθεί. Έστω S_1, \dots, S_t τα υπερδιαστήματα που λαμβάνονται μέσω της παραπάνω διαδικασίας και $\alpha_1, \dots, \alpha_t \in \{\uparrow, \downarrow\}^t$ η ακολουθία μονοτονίας τους.

6. Λάβε $m = \Theta(k \cdot \log(n/k)/\epsilon^3)$ δείγματα s' από την p . Για κάθε υπερδιάστημα $S_i, i \in [t]$, τρέξε τον αλγόριθμο A^{α_i} στην υπό συνθήκη κατανομή p_{S_i} της p , χρησιμοποιώντας δείγματα από το $s' \cup S_i$. Έστω \tilde{p}_{S_i} η υπόθεση που λαμβάνεται.
7. Δώσε την υπόθεση $h = \sum_{i=1}^t \hat{p}(S_i) \cdot \tilde{p}_{S_i} + \sum_j \hat{p}(\{b_j\}) \cdot 1_{b_j}$.

Θεώρημα

Υπάρχει αλγόριθμος Έλεγχος-Υπόθεσης $P(h_1, h_2, \epsilon', \delta')$ που δεδομένων δύο υποθέσεων h_1, h_2 για την p , παράμετρο ακρίβειας ϵ' και παράμετρο εμπιστοσύνης δ' , λαμβάνει $m = O(\log(1/\delta')/\epsilon'^2)$ δείγματα από την p και επιστρέφει υπόθεση $h \in \{h_1, h_2\}$. Εάν μία εκ των h_1, h_2 έχει $d_{TV}(h_i, p) \leq \epsilon'$, τότε με πιθανότητα $1 - \delta'$ η υπόθεση h που επιστρέφει ο αλγόριθμος Έλεγχος-Υπόθεσης έχει $d_{TV}(h, p) \leq 6\epsilon'$.

Απόδειξη

\mathcal{W} στήριγμα του p ,

$$\mathcal{W}_1 = \mathcal{W}_1(h_1, h_2) := \{w \in \mathcal{W} \mid h_1(w) > h_2(w)\}$$

$$p_1 = h_1(\mathcal{W}_1), q_1 = h_2(\mathcal{W}_1)$$

$$p_1 > q_1 \text{ και } d_{TV}(h_1, h_2) = p_1 - q_1$$

1. αν $p_1 - q_1 \leq 5\epsilon'$ ισοπαλία, δώσε κάποιο h_j , άλλως
2. $m = O\left(\frac{\log(1/\delta')}{\epsilon'^2}\right)$ δείγματα s_1, \dots, s_m από την p ,
 $\tau = \frac{1}{m} |\{i \mid s_i \in \mathcal{W}_1\}|$
3. αν $\tau > p_1 - \frac{3}{2}\epsilon'$ επίστρεψε h_1 νικητή, άλλως
4. αν $\tau < q_1 + \frac{3}{2}\epsilon'$ επίστρεψε h_2 νικητή, άλλως
5. ισοπαλία, δώσε κάποιο h_j

Εάν $d_{TV}(p, h_1) \leq \epsilon'$

αν $d_{TV}(p, h_2) > 6\epsilon' \Rightarrow$ πιθανότητα ο h_1 να μην είναι νικητής $\leq e^{-m\epsilon'^2/2}$

αν $d_{TV}(p, h_2) > 4\epsilon' \Rightarrow$ πιθανότητα ο h_2 νικητής $\leq e^{-m\epsilon'^2/2}$

απόδειξη

$r = p(W_1)$, τότε $|r - p_1| \leq \epsilon'$

Ορίζουμε $\{Z_j\}_{j=1}^m$ δείκτριες τυχαίες συναρτήσεις με $Z_j = 1$ ανν

$s_j \in \mathcal{W}_1$, τότε $\tau = \frac{1}{m} \sum_{j=1}^m Z_j$

$E[\tau] = E[Z_j] = r$ Z_j ανεξάρτητες άρα από φράγμα Chernoff

$Pr[\tau \leq r - \epsilon'/2] \leq e^{-m\epsilon'^2/2} \Rightarrow Pr[\tau \leq p_1 - 3\epsilon'/2] \leq e^{-m\epsilon'^2/2}$

αν $d_{TV}(p, h_2) > 6\epsilon'$, απο τριγ. ανισότητα

$p_1 - q_1 = d_{TV}(h_1, h_2) > 5\epsilon'$ και θα σταματήσουμε στο βήμα

3 με πιθανότητα $> 1 - e^{-m\epsilon'^2/2}$

αν $p_1 - q_1 \leq 5\epsilon'$ ισοπαλία, άλλως $p_1 - q_1 > 5\epsilon'$ και ο h_2

ανακηρύσσεται νικητής με πιθανότητα τω πολύ $e^{-m\epsilon'^2/2}$

Έστω ότι έχουμε αλγόριθμο που με εμπιστοσύνη $9/10$ μαθαίνει την k -τροπική κατανομή με ακρίβεια ϵ . Για να ωθήσουμε την πιθανότητα σε $1 - \delta$, τρέχουμε τον αλγόριθμο $O(\log(1/\delta))$ φορές και χρησιμοποιείται ο Έλεγχος-Υπόθεσης σε κατάλληλο διαγωνισμό για επιλογή της κατάλληλης υπόθεσης.

Λήμμα

Έστω p τυχαία κατανομή επί του \mathcal{W} . Έστω D_ϵ συλλογή N κατανομών στο \mathcal{W} τ.ω. υπάρχει $q \in D_\epsilon$ με $d_{TV}(p, q) \leq \epsilon$. Τότε υπάρχει αλγόριθμος που χρησιμοποιεί $O(\epsilon^{-2} \log N \cdot \log(1/\delta))$ δείγματα από την p και με πιθανότητα $1 - \delta$ εξάγει κατανομή $p' \in D_\epsilon$ που ικανοποιεί την $d_{TV}(p, p') \leq 6\epsilon'$.

Εκτελούνται $O(\log(1/\delta))$ επαναλήψεις αλγορίθμου μάθησης που παράγει ϵ -ακριβή υπόθεση με πιθανότητα $\geq 9/10$.

Τότε με πιθανότητα αποτυχίας τ ω πολύ $\delta/2$, τουλάχιστον μία από τις υποθέσεις που παράγονται είναι ϵ κοντά στην πραγματική κατανομή που ικανοποιεί τις προϋποθέσεις του λήμματος.

Με $O(\epsilon^{-2} \log N \cdot \log(1/\delta))$ δείγματα μαθαίνουμε με ακρίβεια $\delta\epsilon$ και εμπιστοσύνη $1 - \delta/2$.

Συνολική δειγματική πολυπλοκότητα:

$O(\log(1/\delta)) \times \text{πολυπλ. αλγ. μάθησης} + O(\epsilon^{-2} \log N \cdot \log(1/\delta))$.

Κεντρικό θεώρημα

Έστω p οποιαδήποτε άγνωστη κατανομή k τρόπων στο $[n]$.

Υπάρχει αλγόριθμος που χρησιμοποιεί

$(\frac{k \cdot \log(n/k)}{\epsilon^3} + \frac{k^2}{\epsilon^3} \log(\frac{k}{\epsilon}) \cdot \log \log \frac{k}{\epsilon}) \cdot \tilde{O}(\log \frac{1}{\delta})$ δείγματα της p , εκτελεί

$\text{poly}(k, \log n, 1/\epsilon, \log(1/\delta))$ διφυοπράξεις και με πιθανότητα

$1 - \delta$ δίνει υπόθεση \hat{p} στο $[n]$ τ.ω. η απόσταση ολικής

διακύμανσης μεταξύ των p και \hat{p} είναι τω πολύ ϵ .

(\tilde{O} : πολυλογαριθμικός όρος. Π.χ. ως $\tilde{O}(a \log b)$ συμβολίζεται

όρος της μορφής $O((a \log b) \cdot (\log(a \log b))^c)$)