

מבוא ללמידה חישובית - תרגול אחרון

סיכום הקורס

אלגוריתמים

Unsupervised

Clustering:

- K-means -
- Gaussian mixture model (EM) -
- Spectral Clustering -

Dim. Reduction

- (kernel) PCA -

Supervised

Binary Classification:

- Naïve Bayes -
- Hyperplane algorithms -
 - (Hard) SVM •
 - Soft Margin SVM •
 - Kernel SVM •
- לינארי -
- פולינומיאלי -
- גאוסיאני -
- ... -
- (Margin +) Perceptron •
- Winnow •
- (עם עיגול) Logistic Regression -
- k-NN (+ kernel) -
- Decision Trees -
- Boosting -
 - Random Forest •
 - Stacking, Bagging •
 - AdaBoost •

Multiclass Classification:

- אסטרטגיות להמרה של אלגוריתם שלומד בינארית לאלגוריתם שלומד קטגוריאלית: -
 - One VS. All •
 - One VS. One •
 - k-NN -
 - Naïve Bayes -

Regression:

- Linear Regression -
- Lasso •
- Ridge •
- Logistic Regression -
- SVR (SVM for regression) -

כלים

אופטימיזציה

- EM -
- Gradient Descent -
- Coordinate Descent -
- Linear Programming -
- Quadratic Programming -

סטטיסטיקה

- Maximum Likelihood -
- MAP- Maximum A-posteriori estimator -

אחרים

- PAC -
- SVD -

PCA

$$X = \left(\begin{array}{c|c|c} \bar{x}_1 & \dots & \bar{x}_n \\ \hline \bar{x}_1 & \dots & \bar{x}_n \\ \hline & \dots & \end{array} \right) \left. \vphantom{\begin{array}{c|c|c} \bar{x}_1 & \dots & \bar{x}_n \\ \hline \bar{x}_1 & \dots & \bar{x}_n \\ \hline & \dots & \end{array}} \right\} d$$

n

מניחים: $\sum_{i=1}^n \bar{x}_i = \bar{0}$
 PCA: מחשב וקטורים עצמיים של XX^T .
 סיבוכיות: $O(d^2 \cdot n + d^3)$.

מה קורה אם $n \ll d$?

$$X = \boxed{} = \boxed{U} \boxed{\Sigma} \boxed{V^T}$$

נעשה פירוק לפי SVD:

$$X = U\Sigma V^T$$

ונרצה את $\bar{u}_1, \dots, \bar{u}_n \in \mathbb{R}^d$

$$XX^T = (U\Sigma V^T)(V\Sigma^T U^T) = U \cdot \text{diag}(\sigma_1^2, \dots, \sigma_n^2, 0, \dots, 0) \cdot U^T$$

$$X^T X = V \cdot \text{diag}(\sigma_1^2, \dots, \sigma_n^2) \cdot V^T$$

נניח שפירקנו ספקטרלית את $X^T X$:

- קיבלנו את V (כלומר $\bar{v}_1, \dots, \bar{v}_n \in \mathbb{R}^n$)
- ואת $\sigma_1^2, \dots, \sigma_n^2$

ניזכר ש:

$$X\bar{v}_i = (U\Sigma V^T)\bar{v}_i = U\Sigma\bar{e}_i = U \cdot (\sigma_i \cdot \bar{e}_i) = \sigma_i \cdot U\bar{e}_i = \sigma_i \cdot \bar{u}_i$$

לכן:

$$X\bar{v}_i = \sigma_i \cdot \bar{u}_i$$

אז אפשר לחשב את $\bar{u}_1, \dots, \bar{u}_n$ כך:

$$\bar{u}_i = \frac{1}{\sigma_i} \cdot X\bar{v}_i$$

סיבוכיות:

חישוב $X^T X$: $O(n^2 \cdot d)$

פירוק ספקטרלי: $O(n^3)$
 חישוב \bar{u} מתוך \bar{v} : $O(n^2 \cdot d)$
 סך הכול: $O(n^2 \cdot d + n^3 + n^2 \cdot d) = O(n^2 \cdot d + n^3)$

שאלה ממבחן

א. נתונה בעיית רגרסיה, שמקבילה לבעיית האופטימיזציה:

$$\min_{a,b} \sum_{i=1}^n |y - ax_i - b|$$

כאשר $x_1, \dots, x_n, y \in \mathbb{R}$ וגם $a, b \in \mathbb{R}$. לאיזה מודל הסתברותי הבעיה מתאימה?

תשובה: המודל-

$$y_i = ax_i + b + \varepsilon_i$$

$$\varepsilon_i \sim \text{Laplace}(0,1)$$

$$\Pr(\varepsilon_i = x) = \frac{1}{2} e^{-|x|}$$

ואז Maximum Likelihood של המודל שקול לבעיית המינימיזציה.

הסבר:

$$\begin{aligned} \log L(a, b; \{x_i, y_i\}) &= \sum_{i=1}^n \log \left(\Pr_{a,b}(y_i | x_i) \right) = \sum_{i=1}^n \log \left(\Pr_{a,b}(y_i - ax_i - b) \right) = \\ &\quad \downarrow \\ &\quad \varepsilon_i = \text{ולכן מתפלג לפלס} \\ &= \sum_{i=1}^n \log \frac{1}{2} - |y_i - ax_i - b| \end{aligned}$$

ב. איך פותרים? עם LP?
 נמציא משתנים חדשים:

$$\gamma_i = y - ax_i - b$$

ואז:

$$\begin{aligned} \min_{a,b,\gamma} \sum_{i=1}^n \gamma_i \\ \text{s. t.} \\ \gamma_i \geq y - ax_i - b \\ \gamma_i \geq -(y - ax_i - b) \end{aligned}$$