

Lec5 - Regression Losses & Metrics

Monday, 1 July 2024 16:13

תוכנית

loss (פונקציית אובדן): פונקציה שמתק מינימום שלה נמצאים פרמטרים של מודל
 metrics (מטרות): מדדי אבסולוטיים (למשל MSE, אבל לא חיוביים)

מטרה: loss/metrics עבור הדיו

מהירות - שיטת מינימום של פונקציה

② * מבוטא נפגרת ראשונה
 בזמנה gradient descent

① * נפגרת ראשונה + שניה

③ * עלא נפגרת

הקדמה: עבור פונקציית loss
 * מרחוק בין y ו- \hat{y} אהיה
 * y שהוא מוצא של מודל


* עדי היום MSE

* פונקציה רציפה

* אטייה <= רציפה

* קוב ממי מיטוב מינימום

* מבוטא נפגרת



General Losses and Metrics

Per-sample error, $e_i = y_i - \hat{y}_i, i = 1, \dots, M$.

Vector notation, $\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}}$.

מספר שורות (בזמנה) גבסים נמוכים
 ↓
 מספר עמודים (בזמנה) גבסים נמוכים

Matrix

MSE (L₂-loss)

$$J(\mathbf{y}, \hat{\mathbf{y}}) = \frac{1}{M} \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \frac{1}{M} \mathbf{e}^T \mathbf{e}$$

$$= \frac{1}{M} \sum_{i=1}^M (y_i - \hat{y}_i)^2 = \frac{1}{M} \sum_{i=1}^M e_i^2$$

Loss

$$\mathcal{L}(\mathbf{y}, \hat{\mathbf{y}}) = \frac{1}{2M} \sum_{i=1}^M e_i^2$$

שיטת מינימום של פונקציה
 * כל חיובי עם regularization

שיטת מינימום של פונקציה
 * כל חיובי עם regularization

שיטת מינימום של פונקציה
 * כל חיובי עם regularization

* Convex = נקודת מינימום גלובלי יחיד

תכונות MSE

* רציף

* אטייה

* מינימום אבסולוטי יחיד

* מבוטא ממוצע - מתאם עם הקלות מובה


* נפגרת יחסית עדיף הטייה

- חוסר סדר

* עכשיו יש כמות אטומים

* "חולשה": רגישות עם outliers

נקודת חריגה



השפעה גדולה על MSE (כיגוד המרחק) של MSE

e	MSE
10	100
100	10,000

root-MSE

שורש של MSE

$$J(\mathbf{y}, \hat{\mathbf{y}}) = \frac{1}{\sqrt{M}} \|\mathbf{y} - \hat{\mathbf{y}}\|$$

$$= \sqrt{\frac{1}{M} \sum_{i=1}^M (y_i - \hat{y}_i)^2} = \sqrt{\frac{1}{M} \sum_{i=1}^M e_i^2}$$

* שונה מ-MSE בגלל ש- $\sqrt{\cdot}$ כ-כז"כ עוזרים
 * MSE - loss
 * MAE - metric
 * MAE used both as loss and metric.
 * δ y
 * δ y
 * δ y

Mean absolute error (MAE)

MAE used both as **loss** and **metric**.

$$\mathcal{L}(\mathbf{y}, \hat{\mathbf{y}}) = \frac{1}{M} \sum_{i=1}^M |y_i - \hat{y}_i| = \frac{1}{M} \sum_{i=1}^M |e_i|$$

* δ y
 * δ y
 * δ y

* ש"מ"י לאז
 * כמות רגיש - outliers
 * נשנה ב"ת' ול"י"ה בשגרה
 * נשנה לאז לבנה (קבועה)
 * אם כששגרה לאז נמוכה
 * עבור MSE: נשנה יורד בהדרגה
 * אם הקטנה השגיאה
 * עשוי לפרוק כפי"ה התכנסות
 * בעיקר בעצירה
 * + מקדם α למטה
 * עבור SD

Huber loss

Goal: Hybrid between MAE and MSE

$$\mathcal{L}(e_i) = \begin{cases} \frac{1}{2} e_i^2 & |e_i| \leq \delta \sim \text{MSE} \\ \delta \left(|e_i| - \frac{1}{2} \delta \right) & \text{otherwise} \sim \text{MAE} \end{cases}$$

* כז"כ
 * כז"כ
 * נקודת איזונים ע"כ
 * חסרון: δ - hyper-parameter
 * כז"כ - δ - hyper-parameter
 * ע"כ אופטימל

Log-cosh loss


Goal: Hybrid between MAE and MSE without hyper-parameters.

$$\mathcal{L}(e_i) = \log \cosh e_i$$


$$\mathcal{L}(e_i) \approx \begin{cases} \frac{e_i^2}{2} & e_i \text{ small} \sim \text{MSE} \\ |e_i| - \log(2) & e_i \text{ large} \sim \text{MAE} \end{cases}$$

$$\frac{\partial}{\partial e_i} \mathcal{L}(e_i) = \tanh e_i$$

* כז"כ
 * אין היפר-פרמטרים
 * חסרון: קבועים ע"כ ע"כ
 * כז"כ ע"כ ע"כ
 * כחוסם למא"ם



סיכום ביניים:
 עיקר ההבדל
 כה התאוששות



עיקר ההבדל
זה בהמוקדם
עם outliers

Mean Squared Logarithmic Error (MLSE)

Table 6.1: Example of MLSE

מטרה: הבדלים לשמורגים בערכי y
 ינוק צינמי צדו

$$J(y_i, \hat{y}_i) = \frac{1}{M} \sum_{i=1}^M (\log(y_i + 1) - \log(\hat{y}_i + 1))^2$$


$$= \frac{1}{M} \sum_{i=1}^M \log\left(\frac{y_i + 1}{\hat{y}_i + 1}\right)^2$$

שאר
היחס
ש
סימטרי
חסרון
העיקרי

True Values	Predicted Values	MSE Loss	MSLE Loss
40	30	100	0.078168
4000	3000	100000000	0.082714
20	10	100	0.07886
20	30	100	0.02861

* כי כפי שאפשר לראות $\log(0) \rightarrow -\infty$
 * קיים גם גרסה

Root MLSE (RMLSE)



מטריקה

- * משמשים להשוואה בין מודלים
- * בד"כ בתחום בין 0 ל-1
- * מובנים לאנשים

Relative squared error (RSE)

ממד MSE

$$J(y_i, \hat{y}_i) = \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} = \frac{MSE}{\text{Var}[y]} = \frac{\|y - \hat{y}\|^2}{\|y - \bar{y}\|^2}$$

* הקטנת שומת השגיאה
 * יש קרוב ל-0

* עבור חיצו עונאי
 חיצו הכוונת

$$\hat{y} = E[y]$$

$$\Rightarrow MSE = \text{Var}[y]$$

- * הקטנת שונות היציאה
- * ישר קרוב $0 < \delta \leq 1$ ישר טוב
- * בציב קטן $1 - \delta$

$$\Rightarrow MSE = Var[y]$$

$$R^2$$


$$R^2 = 1 - RSE$$

$$R^2 \in [0, 1]$$

ישר טוב \leftarrow גנסיקות חריגות שפיל.

הנזק הנזק

ההכרה הנזק



$$y = b$$

$$MSE = \sum_i (y_i - b)^2$$

$$\frac{d}{db} MSE = \sum_i (y_i - b) \cdot (-1) = 0$$

$$\sum_{i=1}^M y_i - \sum_{i=1}^M b = 0$$

$\underbrace{\sum_{i=1}^M b}_{M \cdot b}$

$$MSE = \sum_i (y_i - \bar{y})^2 \leftarrow b = \frac{1}{M} \sum_{i=1}^M y_i = \bar{y}$$

$$= Var[y]$$

* תוצאה שלא נעדרת גשמים אחרים
 \leftarrow צבי על מודל מכוסס כניסות נוספות
 חתף מנין ליהיה ישר טוב.

Relative absolute error (RAE)

Normalized MAE loss.

$$J(y_i, \hat{y}_i) = \frac{\sum_i |y_i - \hat{y}_i|}{\sum_i |y_i - \bar{y}|} = \frac{MAE}{\sum_i |y_i - \bar{y}|}$$

Closer to 0 is better.

True Values	Predicted Values	Absolute Error	MAPE
100	60	40	40%
20	60	40	300%

Mean Absolute Percentage Error (MAPE)

שיאה יחסית
 באחוז

Scaled error metric.

$$J = \frac{1}{M} \sum_{j=1}^M \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (6)$$

- * Beware of small denominator! יני קטן
- * Can exceed 100%.

משפחה של פוני loss
 מראה: עלטן מספר פרמטרים במקום

שיטה: סוג של יקנה על loss עבור מספר פרמטרים לצד

בעיה: הרבה פרמטרים \leftarrow overfit

סיבוכות חישוב
 עלא צדוק שיפוי אמיתי של ביצועים

- N is the number of parameters,
- M is the number of data-points.

\times δ היטות: אימבוסטור MSE
 * יש ביסוס תאורטי "עמוק"
 * אמנות עשהיה של
 מודלים צומים בעל: אמבר
 פרמטרים שונה

Akaike's Final Prediction Error (FPE)

Akaike's Final Prediction Error (FPE) criterion provides a measure of model quality.

$$FPE = MSE \frac{1 + N/M}{1 - N/M} = MSE \frac{M + N}{M - N} \quad (6.16)$$

MSE + נוסחה לקוסטור אמבר
 נקובת M
 אמבר פרמטרים N
 ↓
 אמנות אמבר

Akaike's Information Criterion Penalize the number of parameters,

$$\Delta AIC = 2N + M \ln(MSE) \quad (6.17)$$


AICc is AIC with a correction for small sample sizes

$$AICc = AIC + 2N \frac{N + 1}{M - N - 1} \quad (6.18)$$

אמבר התקף אמנות
 עשהיה של מודלים
 ↓
 בוחרים מודל עם
 אמבר מינימלי

Bayesian Information Criterion (BIC)

$$BIC = M \ln(MSE) + N \ln(M)$$



צומת אמבר

צומת של מודל פולינומלי
 * צורם אובסרואציה של
 - γ - פרמטר Regular
 - δ - עבר Huber loss
 עברור כל loss בעבר
 * כל שיטה: תוצאה קצת
 אמר

```
function loss = huber_loss(y,yh,delta)
```

```
e = abs(y - yh);
loss = zeros(size(e));
idx = e <= delta;
loss(idx) = e(idx).^2/2;
loss(~idx) = delta*e(~idx) - delta^2/2;
loss = mean(loss);
```

$$\longleftrightarrow \mathcal{L}(e_i) = \begin{cases} \frac{1}{2}e_i^2 & |e_i| \leq \delta \\ \delta \left(|e_i| - \frac{1}{2}\delta \right) & \text{otherwise} \end{cases}$$

```
end
function loss = log_cosh_loss(y,yh)
loss = mean(log(cosh(y-yh)));
```

```
end
function loss = mae_loss(y,yh)
e = abs(y - yh);
loss = mean(e);
end
```