

ΣΥΓΚΡΙΣΗ ΜΟΝΤΕΛΩΝ

Αναπλ. Καθηγ. Στελιος Ζήμερας
Τμήμα Στατιστικής και Αναλογιστικών –
Χρηματοοικονομικών Μαθηματικών
Πανεπιστήμιο Αιγαίου
Σαμος

2021

ΕΙΣΑΓΩΓΗ

Επιλογή Μοντέλου (model selection):

- το μοντέλο που έχει την απαιτούμενη πολυπλοκότητα χρησιμοποιώντας την εκτίμηση του λάθους γενίκευσης
- Αφού κατασκευαστεί μπορεί να χρησιμοποιηθεί στα δεδομένα ελέγχου για να προβλέψει σε ποιες κλάσεις ανήκουν
- Για να γίνει αυτό πρέπει να ξέρουμε τις κλάσεις των δεδομένων ελέγχου

ΕΙΣΑΓΩΓΗ

- Μέτρα (metrics) για την εκτίμηση της απόδοσης του μοντέλου
- Πως να εκτιμήσουμε την απόδοση ενός μοντέλου
- Τι θα μετρήσουμε

- Μέθοδοι για την εκτίμηση της απόδοσης
- Πως μπορούνε να πάρουμε αξιόπιστες εκτιμήσεις
- Πως θα το μετρήσουμε

- Μέθοδοι για την σύγκριση μοντέλων
- Πως να συγκρίνουμε τη σχετική απόδοση δύο ανταγωνιστικών μοντέλων

ΕΙΣΑΓΩΓΗ

- Αφού κατασκευαστεί ένα μοντέλο, θα θέλαμε να αξιολογήσουμε/εκτιμήσουμε την ποιότητα του/την ακρίβεια της ταξινόμησης που πετυχαίνει
- Έμφαση στην ικανότητα πρόβλεψης του μοντέλου παρά στην αποδοτικότητα του (πόσο γρήγορα κατασκευάζει το μοντέλο ή ταξινομεί μια εγγραφή, κλιμάκωση κλπ.)

Μέτρα για την απόδοση της εκτίμησης

- Επικεντρώνονται στην προβλεπτική ικανότητα ενός μοντέλου
- Πίνακας (μήτρα) σύγχυσης Confusion Matrix

| | πρόβλεψη PREDICTED CLASS | | |
|-------------------------|--------------------------|-------------|-------------|
| | Class=Yes | Class=No | |
| πραγματική ACTUAL CLASS | Class=Yes | f_{11} TP | f_{10} FN |
| | Class=No | f_{01} FP | f_{00} TN |

TP (true positive) f_{11}
FN (false negative) f_{10}
FP (false positive) f_{01}
TN (true negative) f_{00}

f_{ij} : αριθμός των εγγραφών της κλάσης i που προβλέπονται ως κλάση j

Μέτρα για την απόδοση της εκτίμησης

Πιστότητα - Accuracy

$$\text{Accuracy} = \frac{f_{11} + f_{00}}{f_{11} + f_{00} + f_{01} + f_{10}} = \frac{TP + TN}{TP + TN + FP + FN}$$

Λόγος Λάθους

$$\text{Error rate} = \frac{f_{01} + f_{10}}{f_{11} + f_{00} + f_{01} + f_{10}}$$

| | πρόβλεψη PREDICTED CLASS | | |
|-------------------------|--------------------------|-------------|-------------|
| | Class=Yes | Class=No | |
| πραγματική ACTUAL CLASS | Class=Yes | f_{11} TP | f_{10} FN |
| | Class=No | f_{01} FP | f_{00} TN |



$$\text{ErrorRate}(C) = 1 - \text{Accuracy}(C)$$

Μέτρα για την απόδοση της εκτίμησης

Έστω ένα πρόβλημα με 2 κατηγορίες

- Παραδείγματα από την κατηγορία 0 = 9990
- Παραδείγματα από την κατηγορία 1 = 10

- Εάν ένα μοντέλο προβλέπει ότι κάθε τι ανήκει στην κατηγορία 0, η ακρίβεια είναι $9990/10000 = 99.9\%$

- Η ακρίβεια σε αυτή την περίπτωση είναι παραπλανητική γιατί το μοντέλο αποτυγχάνει να ανιχνεύσει οποιοδήποτε από τα παραδείγματα που ανήκουν στην κατηγορία 1

Μέτρα για την απόδοση της εκτίμησης

Μέτρα Εκτίμησης

Πίνακας Κόστους

| | PREDICTED CLASS | | |
|--------------|-----------------|----------------------------|---------------------------|
| | $C(i j)$ | Class=Yes | Class=No |
| ACTUAL CLASS | Class=Yes | $C(\text{Yes} \text{Yes})$ | $C(\text{No} \text{Yes})$ |
| | Class=No | $C(\text{Yes} \text{No})$ | $C(\text{No} \text{No})$ |

$C(i|j)$: κόστος λανθασμένης ταξινόμησης ενός παραδείγματος της κλάσης i ως κλάση j □

Μέτρα για την απόδοση της εκτίμησης

| | PREDICTED CLASS | | |
|--------------|-----------------|--------------------|--------------------|
| | C(i j) | Class = + | Class = - |
| ACTUAL CLASS | Class = + | TP F_{11} | FN F_{10} |
| | Class = - | FP F_{01} | TN F_{00} |

Αρνητική τιμή κόστους σημαίνει επιπρόσθετη «επιβράβευση» σωστής πρόβλεψης

$$C(M) = \mathbf{TP} \times C(+, +) + \mathbf{FN} \times C(+, -) + \mathbf{FP} \times C(-, +) + \mathbf{TN} \times C(-, -)$$

$$C(+, +) = C(-, -) = 0 \rightarrow \text{όχι επιβράβευση}$$

$$C(+, -) = C(-, +) = 1 \rightarrow \text{κάθε λάθος μετρά 1}$$

Παράδειγμα

Υπολογισμός του Κόστους της Ταξινόμησης

| Cost Matrix | PREDICTED CLASS | | |
|--------------|-----------------|----|-----|
| | C(i j) | + | - |
| ACTUAL CLASS | + | -1 | 100 |
| | - | 1 | 0 |

| Model M_1 | PREDICTED CLASS | | |
|--------------|-----------------|-----|-----|
| | | + | - |
| ACTUAL CLASS | + | 150 | 40 |
| | - | 60 | 250 |

Accuracy = 80%

Cost = 3910

| Model M_2 | PREDICTED CLASS | | |
|--------------|-----------------|-----|-----|
| | | + | - |
| ACTUAL CLASS | + | 250 | 45 |
| | - | 5 | 200 |

Accuracy = 90%

Cost = 4255

Μέτρα Εκτίμησης

Ταξινόμηση που λαμβάνει υπό όψιν της το κόστος

Κατασκευή Δέντρου Ταξινόμησης

1. Επιλογή γνωρίσματος στο οποίο θα γίνει η διάσπαση
2. Στην απόφαση αν θα ψαλιδιστεί κάποιο υπο-δέντρο
3. Στον καθορισμό της κλάσης του φύλλου

Μέτρα Εκτίμησης

- Έστω $p(j)$ τον ποσοστό των εγγραφών του κόμβου που ανήκουν στην κλάση j
- Τότε,

Leaf-label = $\max p(j)$, το ποσοστό των εγγραφών της κλάσης j που έχουν ανατεθεί στον κόμβο

Δίνουμε την κλάση i στον κόμβο που έχει το ελάχιστο:

$$\sum_j p(j)C(j,i)$$

Κόστος εναντίον Ακρίβειας

| Μετρήσεις | ΠΡΟΒΛΕΥΘΕΙΣΑ | | |
|------------|--------------|-----------|----------|
| ΠΡΑΓΜΑΤΙΚΗ | | Class=Yes | Class=No |
| | Class=Yes | a | b |
| | Class=No | c | d |

Η ακρίβεια είναι ανάλογη του κόστους εάν

$$1. C(\text{Yes}|\text{No})=C(\text{No}|\text{Yes}) = q$$

$$2. C(\text{Yes}|\text{Yes})=C(\text{No}|\text{No}) = p$$

$$N = a + b + c + d$$

$$\text{Accuracy} = (a + d)/N$$

| Κόστη | ΠΡΟΒΛΕΥΘΕΙΣΑ | | |
|------------|--------------|-----------|----------|
| ΠΡΑΓΜΑΤΙΚΗ | | Class=Yes | Class=No |
| | Class=Yes | p | q |
| | Class=No | q | p |

$$\text{Cost} = p (a + d) + q (b + c)$$

$$= p (a + d) + q (N - a - d)$$

$$= q N - (q - p)(a + d)$$

$$= N [q - (q-p) \times \text{Accuracy}]$$

Μέτρα Ακρίβειας

| | | PREDICTED CLASS | |
|--------------|-----------|-----------------|----------|
| | | Class=Yes | Class=No |
| ACTUAL CLASS | Class=Yes | TP | FN |
| | Class=No | FP | TN |

False positive rate: Το ποσοστό των αρνητικών παραδειγμάτων που ταξινομούνται λάθος (δηλαδή, ως θετικά)

$$FPR = \frac{FP}{TN + FP}$$

False negative rate: Το ποσοστό των θετικών παραδειγμάτων που ταξινομούνται λάθος (δηλαδή, ως αρνητικά)

$$FNR = \frac{FN}{TP + FN}$$

Μέτρα Ακρίβειας

| Μετρήσεις | ΠΡΟΒΛΕΥΘΕΙΣΑ | | |
|------------|--------------|-----------|----------|
| ΠΡΑΓΜΑΤΙΚΗ | | Class=Yes | Class=No |
| | Class=Yes | a | b |
| | Class=No | c | d |

Precision (p) = $\frac{a}{a+c}$ Πόσα από τα παραδείγματα που ο ταξινομητής έχει ταξινομήσει ως θετικά είναι πραγματικά θετικά Όσο πιο μεγάλη η ακρίβεια, τόσο μικρότερος ο αριθμός των FP


Recall (r) = $\frac{a}{a+b}$ Πόσα από τα θετικά παραδείγματα κατάφερε ο ταξινομητής να βρει Όσο πιο μεγάλη η ανάκληση, τόσο λιγότερα θετικά παραδείγματα έχουν ταξινομεί λάθος (=TPR)

F - measure (F) = $\frac{2rp}{r+p} = \frac{2a}{2a+b+c}$ Τείνει να είναι πιο κοντά στο μικρότερο από τα δύο
Υψηλή τιμή σημαίνει ότι και τα δύο είναι ικανοποιητικά μεγάλα

Μέτρα Ακρίβειας

- Πως μπορούμε να πάρουμε αξιόπιστες εκτιμήσεις της απόδοσης
- Η απόδοση ενός μοντέλου μπορεί να εξαρτάται από πολλούς παράγοντες εκτός του αλγορίθμου μάθησης:
 1. Κατανομή των κλάσεων
 2. Το κόστος της λανθασμένης ταξινόμησης
 3. Το μέγεθος του συνόλου εκπαίδευσης και του συνόλου ελέγχου

Καμπύλη Μάθησης



- Η καμπύλη μάθησης δείχνει πως μεταβάλλεται η πιστότητα (accuracy) με την αύξηση του μεγέθους του δείγματος
- Επίδραση δείγματος μικρού μεγέθους:
 - Bias in the estimate
 - Variance of estimate

ROC (Receiver Operating Characteristic Curve)

- Η καμπύλη ROC δείχνει τα TPR [TruePositiveRate] (στον άξονα των y) προς τα FPR [FalsePositiveRate] (στον άξονα των x)
- Η απόδοση κάθε ταξινομητή αναπαρίσταται ως ένα σημείο στην καμπύλη ROC


Πόσα από τα θετικά
βρίσκει

$$\text{TPR} = \frac{TP}{TP + FN}$$

Πόσα από τα αρνητικά
βρίσκει

$$\text{FPR} = \frac{FP}{TN + FP}$$

ROC (Receiver Operating Characteristic Curve)



(TP,FP): (0,0): όλα σημειώνονται ως αρνητική κλάση

(1,1): όλα σημειώνονται ως θετική κλάση

(1,0): ιδανική ταξινόμηση

Διαγώνιος: Τυχαία εκτίμηση κλάσης


$$TPR = \frac{TP}{TP + FN}$$

$$FPR = \frac{FP}{TN + FP}$$

ROC (Receiver Operating Characteristic Curve)

Καλοί ταξινομητές κοντά στην αριστερή πάνω γωνία του διαγράμματος

Κάτω από τη διαγώνιο Πρόβλεψη είναι το αντίθετο της πραγματικής κλάσης



Αποτίμηση Μοντέλου

- Δοσμένων δύο μοντέλων, έστω M_1 και M_2 , ποιο είναι καλύτερο;

M_1 ελέγχεται στο D_1 (size= n_1), error rate = e_1

M_2 ελέγχεται στο D_2 (size= n_2), error rate = e_2

Έστω D_1 και D_2 είναι ανεξάρτητα

Αν τα n_1 και n_2 είναι αρκετά μεγάλα, τότε:

$$e_1 \sim N(\mu_1, \sigma_1)$$

$$e_2 \sim N(\mu_2, \sigma_2)$$

$$\hat{\sigma}_i = \frac{e_i(1-e_i)}{n_i}$$

Αποτίμηση Μοντέλου

Για να ελέγξουμε αν η απόδοση διαφέρει
στατιστικά σημαντικά: $d=e1-e2$



$d \sim N(d_t, \sigma_t^2)$ όπου d_t είναι η πραγματική
διαφορά



Αφού τα $D1$ και $D2$ είναι ανεξάρτητα, η
διασπορά τους προστίθεται

$$\begin{aligned}\sigma_t^2 &= \sigma_1^2 + \sigma_2^2 \cong \hat{\sigma}_1^2 + \hat{\sigma}_2^2 \\ &= \frac{e1(1-e1)}{n1} + \frac{e2(1-e2)}{n2}\end{aligned}$$



επίπεδο
εμπιστοσύνης $(1-\alpha)$

$$d_t = d \pm Z_{\alpha/2} \hat{\sigma}_t$$

Παράδειγμα

Έστω: M1: $n_1 = 30$, $e_1 = 0.15$
M2: $n_2 = 5000$, $e_2 = 0.25$

$$d = |e_2 - e_1| = 0.1$$

$$\hat{\sigma}_d = \frac{0.15(1-0.15)}{30} + \frac{0.25(1-0.25)}{5000} = 0.0043$$

Σε επίπεδο εμπιστοσύνης 95%, $Z_{\alpha/2} = 1.96$

$$d_t = 0.100 \pm 1.96 \times \sqrt{0.0043} = 0.100 \pm 0.128$$



=> το διάστημα περιέχει το 0 => η διαφορά δεν είναι στατιστικά σημαντική

Αξιολογήσεις

Μετρικές Αξιολόγησης Μεθόδων Κατηγοριοποίησης

| | Χρόνος Εκπαίδευσης | Χρόνος Εκτέλεσης | Ανοχή στο Θόρυβο | Χρήση Προϋπάρχουσας Γνώσης | Ακρίβεια | Κατανοησιμότητα |
|------------------|--------------------|------------------|------------------|----------------------------|----------|-----------------|
| Δέντρα Απόφασης | Μικρός | Μικρός | Μικρή | Όχι | Μέτρια | Καλή |
| Νευρωνικά Δίκτυα | Μεγάλος | Μικρός | Καλή | Όχι | Καλή | Μικρή |
| Bayesian Μέθοδοι | Μεγάλος | Μικρός | Καλή | Ναι | Καλή | Καλή |