

# On-line Μάθηση

---

Μηχανική Μάθηση

# Προσέλαση δεδομένων κατά τη μάθηση

- **Μάθηση κατά δέσμη** (*batch learning*)
  - Σταθερή κατανομή δειγματοληψίας δεδομένων
  - Δειγματοληψία σημείων **i.i.d** (*independent & identically distributed*)
  - Σύνολα δεδομένων **εκπαίδευσης** και **ελέγχου**
  - PAC Learning: εύρεση υπόθεσης που **ελαχιστοποιεί** το σφάλμα γενίκευσης
- **On-line Μάθηση** (*On-line learning*)
  - Επεξεργασία ενός δείγματος δεδομένων κάθε χρονική στιγμή
    - **Δεν γίνεται** υπόθεση για την *κατανομή* των δεδομένων, **ούτε ισχύουν** οι **i.i.d** θεωρήσεις
  - «Μεικτή» εκπαίδευση και έλεγχος
  - **Δεν υπάρχει** η έννοια του **σφάλματος γενίκευσης**
    - Απόδοση μετριέται μέσω **μοντέλου σφάλματος** (*mistake model*) και της έννοιας της **μετάνοιας** (*regret*)
  - *Εγγυήσεις* μάθησης προκύπτουν από την **ανάλυση της χειρότερη περίπτωσης** (*worst-case analysis*)
    - Γνωστή και ως **μάθηση με αντιπαλότητα** (*adversarial learning*)

- **Χαρακτηριστικά**
  - **Μικρό** υπολογιστικό *κόστος*
    - *Παραγωγή* προβλέψεων
    - *Ενημέρωση* παραμέτρων μοντέλου
  - **Ευκολία** υλοποίησης
- **Παραδείγματα χρήσης**
  - **Χρηματοοικονομικός** τομέας
    - *Πρόβλεψη* σημερινής *ισοτιμίας* νομισμάτων / μετοχών κλπ
  - **Ειδησεογραφικά** portal
    - *Ποιους* από τους αναγνώστες θα μπορούσε να *ενδιαφέρει* μια «έκτακτη» είδηση;
  - ...

# Γενικό μοντέλο on-line μάθησης

- $T$  γύροι εκπαίδευσης
- Για  $t = 1$  μέχρι  $T$ 
  1. Λήψη δείγματος  $x_t \in \mathcal{X}$
  2. Πρόβλεψη τιμής/ετικέτας  $\hat{y}_t \in \mathcal{Y}$
  3. Λήψη τιμής/ετικέτας  $y_t \in \mathcal{Y}$
  4. Υπολογισμός συνάρτησης κόστους  $L(\hat{y}_t, y_t): \mathcal{Y} \times \mathcal{Y} \rightarrow \mathbb{R}_+$
- Ταξινόμηση:  $Y = \{0,1\}$ ,  $L(y, y') = |y - y'|$
- Παλινδρόμηση:  $Y \in \mathbb{R}$ ,  $L(y, y') = (y - y')^2$
- **Σκοπός** μάθησης
  - Ελαχιστοποίηση σωρευτικής απώλειας  $\sum_{t=1}^T L(\hat{y}_t, y_t)$
- **Κατηγορίες**
  1. Πρόβλεψη με συμβουλή «ειδικού» (*expert advice*)
  2. Γραμμική ταξινόμηση

# Πρόβλεψη με συμβουλή «ειδικού»

Prediction with expert advice

# Πρόβλεψη με συμβουλή «ειδικού»

- Σε κάθε γύρο, εκτός του δείγματος δεδομένων, το μοντέλο λαμβάνει τις **συμβουλές**  $N$  «ειδικών»
- **Αλγόριθμος**
  - Για  $t = 1$  μέχρι  $T$ 
    1. **Λήψη** δείγματος  $x_t \in \mathcal{X}$  και συμβουλών  $y_{t,i} \in \mathcal{Y}, i \in [1, N]$
    2. **Πρόβλεψη** τιμής/ετικέτας  $\hat{y}_t \in \mathcal{Y}$
    3. **Λήψη** τιμής/ετικέτας  $y_t \in \mathcal{Y}$
    4. Υπολογισμός συνάρτησης **κόστους**  $L(\hat{y}_t, y_t): L: \mathcal{Y} \times \mathcal{Y} \rightarrow \mathbb{R}_+$
- **Σκοπός μάθησης**
  - *Ελαχιστοποίηση μετάνοιας (regret)*
    - διαφοράς μεταξύ σωρευτικής απώλειας και απώλειας του καλύτερου «ειδικού»
    - $\text{Regret}(T) = R_T = \sum_{t=1}^T L(\hat{y}_t, y_t) - \min_N \sum_{t=1}^T L(y_{t,i}, y_t)$

# Μοντέλο Οριοθέτησης Λαθών

- **Mistake Bound Model**
  - Πόσα λάθη κάνει το μοντέλο μέχρι να μάθει μιας έννοια;
  - Έννοια (*concept*): απεικόνιση από τον χώρο των δεδομένων στον χώρο των ετικετών
- **Ορισμοί**
  - $M_{\mathcal{A}}(c) = \max_{x_1 \dots x_T} |\text{mistakes}(\mathcal{A}, c)|$ 
    - **Μέγιστος** αριθμός λαθών που κάνει ο αλγόριθμος  $\mathcal{A}$  για να μάθει την έννοια  $c$
  - $M_{\mathcal{A}}(\mathcal{C}) = \max_{c \in \mathcal{C}} M_{\mathcal{A}}(c)$ 
    - **Μέγιστος** αριθμός λαθών που κάνει ο αλγόριθμος  $\mathcal{A}$  για να μάθει οποιαδήποτε έννοια στην κλάση εννοιών  $\mathcal{C}$
- Επιθυμούμε να **θέσουμε όριο**  $M$  στο  $M_{\mathcal{A}}(\mathcal{C})$

# Αλγόριθμος HALVING

HALVING( $\mathcal{H}$ )

```
1  $\mathcal{H}_1 \leftarrow \mathcal{H}$ 
2 for  $t \leftarrow 1$  to  $T$  do
3     RECEIVE( $x_t$ )
4      $\hat{y}_t \leftarrow$  MAJORITYVOTE( $\mathcal{H}_t, x_t$ )
5     RECEIVE( $y_t$ )
6     if ( $\hat{y}_t \neq y_t$ ) then
7          $\mathcal{H}_{t+1} \leftarrow \{c \in \mathcal{H}_t : c(x_t) = y_t\}$ 
8     else  $\mathcal{H}_{t+1} \leftarrow \mathcal{H}_t$ 
9 return  $\mathcal{H}_{T+1}$ 
```

- Απλός αλγόριθμος, με αρκετά **καλά όρια**

- $\mathcal{H}$  πεπερασμένος χώρος υποθέσεων

- **Όρια**

- $M_{HALVING}(\mathcal{H}) \leq \log_2 |\mathcal{H}|$

- Αν  $opt(\mathcal{H})$  βέλτιστο όριο λάθους ( $opt(\mathcal{H}) \leq M_{HALVING}(\mathcal{H})$ ), επιπρόσθετα ισχύει  $VCdim(\mathcal{H}) \leq opt(\mathcal{H})$



# Αλγόριθμος Σταθμισμένης Πλειοψηφίας

WEIGHTED-MAJORITY( $N$ )

```
1 for  $i \leftarrow 1$  to  $N$  do
2      $w_{1,i} \leftarrow 1$ 
3 for  $t \leftarrow 1$  to  $T$  do
4     RECEIVE( $x_t$ )
5     if  $\sum_{i: y_{t,i}=1} w_{t,i} \geq \sum_{i: y_{t,i}=0} w_{t,i}$  then
6          $\hat{y}_t \leftarrow 1$ 
7     else  $\hat{y}_t \leftarrow 0$ 
8     RECEIVE( $y_t$ )
9     if ( $\hat{y}_t \neq y_t$ ) then
10        for  $i \leftarrow 1$  to  $N$  do
11            if ( $y_{t,i} \neq y_t$ ) then
12                 $w_{t+1,i} \leftarrow \beta w_{t,i}$ 
13            else  $w_{t+1,i} \leftarrow w_{t,i}$ 
14 return  $w_{T+1}$ 
```

- **Στάθμιση** της άποψης κάθε «ειδικού» ως προς το **ρυθμό** που κάνει **λάθη**
- Αρχικά οι  $N$  ειδικοί έχουν το ίδιο βάρος
- Πρόβλεψη ο **σταθμισμένος μέσος όρος** των προβλέψεων των «ειδικών»
- Σε περίπτωση που κάποιος κάνει **λάθος**, το **βάρος** του **μειώνεται** κατά παράγοντα  $\beta$ 
  - Για  $\beta = 0$  παίρνουμε τον αλγόριθμο HALVING

# Αλγόριθμος Σταθμισμένης Πλειοψηφίας: Όρια

- $m_T$ : αριθμός **λαθών** του αλγορίθμου μετά από  $T \geq 1$  γύρους
- $m_T^*$ : αριθμός **λαθών** του **καλύτερου** από τους  $N$  «ειδικούς»

- Ισχύει: 
$$m_T \leq \frac{\log N + m_T^* \log \frac{1}{\beta}}{\log \frac{2}{1+\beta}}$$

- Η παραπάνω σχέση εγγυάται **άνω όριο** της μορφής
  - $m_T \leq O(\log N) + Km_T^*$ ,  $K$  σταθερά
  - Από τη στιγμή που ο *πρώτος όρος* μεταβάλλεται *λογαριθμικά* σε σύγκριση με το πλήθος των «ειδικών», στην πράξη το **πλήθος** των **λαθών** του αλγορίθμου *εξαρτάται* από μια **σταθερά** επί το **πλήθος** των **λαθών** του **καλύτερου** «ειδικού»
- Ωστόσο, οι **ντετερμινιστικοί αλγόριθμοι** **δεν επιτυγχάνουν** καλά **όρια** για τη **μετάνοια**
  - **Δεν μπορούν** να τη «φράξουν» γραμμικά συναρτήσεσι του **πλήθους** των γύρων ( $R_T \neq o(T)$ )
  - Λύση: χρήση **randomized** αλγορίθμων

# Randomized Αλγόριθμος Σταθμισμένης Πλειοψηφίας

RANDOMIZED-WEIGHTED-MAJORITY ( $N$ )

```
1  for  $i \leftarrow 1$  to  $N$  do
2       $w_{1,i} \leftarrow 1$ 
3       $p_{1,i} \leftarrow 1/N$ 
4  for  $t \leftarrow 1$  to  $T$  do
5      RECEIVE( $\mathbf{l}_t$ )
6      for  $i \leftarrow 1$  to  $N$  do
7          if ( $l_{t,i} = 1$ ) then
8               $w_{t+1,i} \leftarrow \beta w_{t,i}$ 
9          else  $w_{t+1,i} \leftarrow w_{t,i}$ 
10      $W_{t+1} \leftarrow \sum_{i=1}^N w_{t+1,i}$ 
11     for  $i \leftarrow 1$  to  $N$  do
12          $p_{t+1,i} \leftarrow w_{t+1,i}/W_{t+1}$ 
13  return  $\mathbf{w}_{T+1}$ 
```

- Στην περίπτωση αυτή, ο αλγόριθμος καλείται να **επιλέξει** από  $N$  πιθανές δράσεις (όχι «ειδικοί»)
- Σε κάθε γύρο, υπολογισμός κατανομής  $\mathbf{p}_t$  πάνω στις δράσεις
  - Αρχικά ομοιόμορφη
- Λήψη διανύσματος απώλειας  $\mathbf{l}_t$
- **Επαναπροσδιορισμός συνεισφοράς δράσης** όπως στην περίπτωση του ντετερμινιστικού αλγορίθμου σταθμισμένης πλειοψηφίας

# Randomized Αλγόριθμος Σταθμισμένης Πλειοψηφίας: Όρια

- **Λάθος** στον γύρο  $t$ :  $L_t = \sum_{i=1}^N p_{t,i} l_{t,i}$ 
  - Θεωρούμε δυαδική απώλεια  $l_{t,i} \in \{0,1\}$
- **Λάθος** μετά από  $T$  γύρους:  $\mathcal{L}_T = \sum_{t=1}^T L_t$
- **Λάθος** ενέργειας  $i$  μετά από  $T$  γύρους:  $\mathcal{L}_{T,i} = \sum_{t=1}^T l_{t,i}$
- Ελάχιστο **λάθος** ενεργειών:  $\mathcal{L}_T^{\min} = \min_i \mathcal{L}_{T,i}$
- «Μετάνοια»:  $R_T = \mathcal{L}_T - \mathcal{L}_T^{\min}$
- **Θεώρημα**
  - Για  $\beta \in [\frac{1}{2}, 1)$  και για  $T \geq 1$  **ισχύει**:  $\mathcal{L}_T \leq \frac{\log N}{1-\beta} + (2 - \beta)\mathcal{L}_T^{\min}$
  - Επιπρόσθετα για  $\beta = \max\{\frac{1}{2}, 1 - \sqrt{\frac{\log N}{T}}\}$  **ισχύει**  $\mathcal{L}_T \leq \mathcal{L}_T^{\min} + 2\sqrt{T \log N}$ 
    - Άρα  $R_T \leq 2\sqrt{T \log N}$  οπότε  $R_T = O(\sqrt{T})$  και η μέση μετάνοια ανά γύρο  $\frac{R_T}{T}$  μειώνεται με ρυθμό  $O(\frac{1}{\sqrt{T}})$

# Αλγόριθμος Εκθετικής Σταθμισμένης Πλειοψηφίας

EXPONENTIAL-WEIGHTED-AVERAGE ( $N$ )

```
1  for  $i \leftarrow 1$  to  $N$  do
2       $w_{1,i} \leftarrow 1$ 
3  for  $t \leftarrow 1$  to  $T$  do
4      RECEIVE( $x_t$ )
5       $\hat{y}_t \leftarrow \frac{\sum_{i=1}^N w_{t,i} y_{t,i}}{\sum_{i=1}^N w_{t,i}}$ 
6      RECEIVE( $y_t$ )
7      for  $i \leftarrow 1$  to  $N$  do
8           $w_{t+1,i} \leftarrow w_{t,i} e^{-\eta L(\hat{y}_{t,i}, y_t)}$ 
9  return  $\mathbf{w}_{T+1}$ 
```

- Ντετερμινιστικός αλγόριθμος
- $L$  κυρτή (*convex*) συνάρτηση σφάλματος και λαμβάνει τιμές στο  $[0,1]$ 
  - $L_{t,i}$  συνολικό σφάλμα  $i$ -οστού «ειδικού» μετά από  $t$  γύρους

# Αλγόριθμος Εκθετικής Σταθμισμένης Πλειοψηφίας: Όρια

- Για *κυρτή* συνάρτηση **σφάλματος**  $L \in [0,1]$ , για  $\eta > 0$  και για κάθε ακολουθία ετικετών  $y_1 \dots y_T \in \mathcal{Y}$ , η «μετάνοια» του αλγορίθμου ικανοποιεί τη σχέση  $R_T \leq \frac{\log N}{\eta} + \frac{\eta T}{8}$

- **Βέλτιστο  $\eta$**

- $\eta = \sqrt{\frac{8 \log N}{T}}$ ,  $R_T \leq \sqrt{\frac{T \log N}{2}}$  και  $\frac{R_T}{T} = O\left(\sqrt{\frac{\log N}{T}}\right)$

- **Μειονέκτημα** ότι εξαρτάται από το **πλήθος** των γύρων (ορίζοντα)  $T$

- **Τρυκ διπλασιασμού** (*doubling trick*)

- Χωρίζουμε τον χρόνο σε *περιόδους*  $[2^k, 2^{k+1} - 1]$  διάρκειας  $2^k$ ,  $k \in [0, n]$ , θέτουμε  $T \geq 2^n - 1$  και

- επιλέγουμε  $\eta_k = \sqrt{\frac{8 \log N}{2^k}}$  σε κάθε περίοδο

- Τότε ισχύει  $R_T \leq \frac{\sqrt{2}}{\sqrt{2}-1} \sqrt{\frac{T \log N}{2}} + \sqrt{\frac{\log N}{2}}$

# Γραμμική ταξινόμηση

Linear Classification

# Perceptron



PERCEPTRON( $\mathbf{w}_0$ )

```
1  $\mathbf{w}_1 \leftarrow \mathbf{w}_0$   $\triangleright$  typically  $\mathbf{w}_0 = \mathbf{0}$ 
2 for  $t \leftarrow 1$  to  $T$  do
3   RECEIVE( $\mathbf{x}_t$ )
4    $\hat{y}_t \leftarrow \text{sgn}(\mathbf{w}_t \cdot \mathbf{x}_t)$ 
5   RECEIVE( $y_t$ )
6   if ( $\hat{y}_t \neq y_t$ ) then
7      $\mathbf{w}_{t+1} \leftarrow \mathbf{w}_t + y_t \mathbf{x}_t$   $\triangleright$  more generally  $\eta y_t \mathbf{x}_t, \eta > 0$ .
8   else  $\mathbf{w}_{t+1} \leftarrow \mathbf{w}_t$ 
9 return  $\mathbf{w}_{T+1}$ 
```

- **On-line** έκδοση του αλγορίθμου
- $\mathbf{w}_t$ : διάνυσμα βαρών
  - Επίπεδο διαχωρισμού κλάσεων
  - Ενημέρωση μόνο σε περίπτωση σφάλματος
- Ο αλγόριθμος βελτιστοποιεί αντικειμενική συνάρτηση
  - $F(\mathbf{w}) = \frac{1}{T} \sum_{t=1}^T \max(0, -y_t(\mathbf{w} \mathbf{x}_t))$
  - Κυρτή, αλλά όχι διαφορίσιμη



# Perceptron: Επίπεδο διαχωρισμού



# Perceptron: Όρια για γραμμικά διαχωρίσιμες κλάσεις

- Έστω  $x_1 \dots x_T \in \mathbb{R}^N$  ακολουθία Τσημείων με  $\|x_t\| \leq r, \forall t \in [1, T]$  για  $r > 0$ . Υποθέτουμε ότι **υπάρχει**  $\rho > 0$  και  $v \in \mathbb{R}^N$  έτσι ώστε  $\rho \leq \frac{y_t(vx_t)}{\|v\|}$ . Τότε το **πλήθος** των ενημερώσεων που πραγματοποιεί ο αλγόριθμος είναι *φραγμένο* από τον λόγο  $\frac{r^2}{\rho^2}$ 
  - **Κανονικοποιημένο** περιθώριο (*margin*)
- **Παρατηρήσεις**
  - **Αυστηρό** όριο, που δεν εξαρτάται από το **πλήθος** των διαστάσεων των δεδομένων, ούτε από τη σειρά τους
  - Σε περίπτωση που οι **κλάσεις** **δεν είναι** γραμμικά **διαχωρίσιμες**, ο αλγόριθμος **δεν συγκλίνει**
  - Για *μικρά περιθώρια*, η σύγκλιση μπορεί να είναι **πολύ αργή** ( $\Omega(2^N)$ )

# Perceptron: Όρια για μη-γραμμικά διαχωρίσιμες κλάσεις

- Έστω  $\mathbf{x}_1 \dots \mathbf{x}_T \in \mathbb{R}^N$  ακολουθία  $T$  σημείων με  $\|\mathbf{x}_t\| \leq r, \forall t \in [1, T]$  για  $r > 0$ .  
Έστω  $\mathcal{J}$  το σύνολο των επαναλήψεων κατά τις οποίες ο αλγόριθμος ενημέρωσε τα βάρη του. Τότε το πλήθος των ενημερώσεων  $M_T = |\mathcal{J}|$  που πραγματοποιεί ο αλγόριθμος **φράσσεται** από το όριο

$$\bullet M_T \leq \inf_{\rho > 0, \|v\|_2 \leq 1} \left( \frac{r}{\rho} + \sqrt{\|\mathbf{I}_\rho\|_1} \right)^2, \mathbf{I}_\rho = \left( \max_{t \in \mathcal{J}} \left\{ 0, 1 - \frac{y_t(vx_t)}{\rho} \right\} \right)$$

- $\mathbf{I}_\rho$ : Απώλεια  $\rho$ -Hinge
- $v$ : διάνυσμα βαρών
- $\inf(S)$ : **μέγιστο κάτω φράγμα** (*infimum*) συνόλου  $S$ 
  - ο μεγαλύτερος πραγματικός αριθμός ο οποίος είναι μικρότερος ή ίσος με κάθε αριθμό που περιέχεται στο  $S$

- Ένα **λιγότερο ισχυρό όριο** ισχύει και για τη  $L_2$  νόρμα

$$\bullet M_T \leq \inf_{\rho > 0, \|v\|_2 \leq 1} \left( \frac{r}{\rho} + \sqrt{\|\mathbf{I}_\rho\|_2} \right)^2$$

# Dual Perceptron

DUALPERCEPTRON( $\alpha_0$ )

```
1  $\alpha \leftarrow \alpha_0$   $\triangleright$  typically  $\alpha_0 = \mathbf{0}$ 
2 for  $t \leftarrow 1$  to  $T$  do
3   RECEIVE( $\mathbf{x}_t$ )
4    $\hat{y}_t \leftarrow \text{sgn}(\sum_{s=1}^T \alpha_s y_s (\mathbf{x}_s \cdot \mathbf{x}_t))$ 
5   RECEIVE( $y_t$ )
6   if ( $\hat{y}_t \neq y_t$ ) then
7      $\alpha_t \leftarrow \alpha_t + 1$ 
8   else  $\alpha_t \leftarrow \alpha_t$ 
9 return  $\alpha$ 
```

- **Επέκταση γραμμικής διαχωρισιμότητας** σε χώρους **μεγαλύτερων** διαστάσεων
- Προϋποθέτει ότι έχουμε **διαθέσιμα**  $T$  δείγματα με τις *ετικέτες* τους
- Διάνυσμα συντελεστών  $\alpha \in \mathbb{R}^T$  που ανατίθεται σε κάθε δείγμα  $\mathbf{x}_t$
- $\mathbf{w} = \sum_{s=1}^T \alpha_s y_s \mathbf{x}_s$ 
  - Ενημέρωση ισοδύναμη με προσθήκη όρου  $y_t \mathbf{x}_t$  στο  $\mathbf{w}$
  - Συσχέτιση με Perceptron

# Kernel Perceptron

KERNELPERCEPTRON( $\alpha_0$ )

```
1  $\alpha \leftarrow \alpha_0$     ▷ typically  $\alpha_0 = \mathbf{0}$ 
2 for  $t \leftarrow 1$  to  $T$  do
3     RECEIVE( $x_t$ )
4      $\hat{y}_t \leftarrow \text{sgn}(\sum_{s=1}^T \alpha_s y_s K(x_s, x_t))$ 
5     RECEIVE( $y_t$ )
6     if ( $\hat{y}_t \neq y_t$ ) then
7          $\alpha_t \leftarrow \alpha_t + 1$ 
8     else  $\alpha_t \leftarrow \alpha_t$ 
9 return  $\alpha$ 
```

- **Dual Perceptron**

- υπολογίζει εσωτερικά γινόμενα μεταξύ των δειγμάτων δεδομένων

- **Kernel Perceptron**

- επέκταση της έννοιας του εσωτερικού γινομένου με τη χρήση **συμμετρικού και θετικά ορισμένου πυρήνα** (*Positive Definite Symmetric – PDS*)

# Winnow

WINNOWN( $\eta$ )

```
1  $w_1 \leftarrow \mathbf{1}/N$ 
2 for  $t \leftarrow 1$  to  $T$  do
3   RECEIVE( $\mathbf{x}_t$ )
4    $\hat{y}_t \leftarrow \text{sgn}(\mathbf{w}_t \cdot \mathbf{x}_t)$ 
5   RECEIVE( $y_t$ )
6   if ( $\hat{y}_t \neq y_t$ ) then
7      $Z_t \leftarrow \sum_{i=1}^N w_{t,i} \exp(\eta y_t x_{t,i})$ 
8     for  $i \leftarrow 1$  to  $N$  do
9        $w_{t+1,i} \leftarrow \frac{w_{t,i} \exp(\eta y_t x_{t,i})}{Z_t}$ 
10    else  $\mathbf{w}_{t+1} \leftarrow \mathbf{w}_t$ 
11 return  $\mathbf{w}_{T+1}$ 
```

- **Επέκταση** Perceptron με πολλαπλασιαστική μεταβολή των βαρών
- $Z_t$ : Παράγοντας κανονικοποίησης
- Αν  $y_t$  και  $\mathbf{x}_{t,i}$  έχουν ίδιο πρόσημο  $w_{t,i}$  αυξάνεται
  - Αλλιώς μειώνεται

# Winnow: Όρια

- **Σχέση Winnow με τον Αλγόριθμο Σταθμισμένης Πλειοψηφίας**
  - Αν  $x_{t,i} \in \{-1, +1\}$  το  $\text{sgn}(w_t x_t)$  συμπίπτει με την ψήφο της πλειοψηφίας
  - Ο πολλαπλασιασμός με  $e^\eta$  ή  $e^{-\eta}$  των βαρών των ορθών/εσφαλμένων προβλέψεων είναι ισοδύναμος με τον πολλαπλασιασμό με  $\beta = e^{-2\eta}$  των βαρών των λανθασμένων προβλέψεων του Α.Σ.Π.
- **Αντίστοιχες συσχετίσεις** βρίσκονται και με άλλους αλγορίθμους
  - *Boosting*, Perceptron
- Έστω  $x_1 \dots x_T \in \mathbb{R}^N$  ακολουθία  $T$  σημείων με  $\|x_t\|_\infty \leq r_\infty, \forall t \in [1, T]$  για  $r_\infty > 0$ . Υποθέτουμε ότι υπάρχει  $\rho_\infty > 0$  και  $v \in \mathbb{R}^N, v \geq 0$  έτσι ώστε  $\rho_\infty \leq \frac{y_t(vx_t)}{\|v\|}$ . Τότε το **πλήθος** των ενημερώσεων που πραγματοποιεί ο αλγόριθμος είναι **φραγμένο** από τον λόγο  $2 \frac{r_\infty^2}{\rho_\infty^2} \log N$ 
  - **Παρόμοιο** όριο με *Perceptron* αλλά για διαφορετικές νόρμες
    - $L_1$  για το *Perceptron* και  $L_\infty$  για *Winnow*

# Βιβλιογραφία

1. *M. Mohri, A. Rostamizadeh, A. Talwalker* – **Foundations of Machine Learning**
  - Κεφάλαιο 8