

On-line Learning

Μηχανική Μάθηση

ΔΠΜΣ Επιστήμη Δεδομένων και Μηχανική Μάθηση

Γιώργος Αλεξανδρίδης – gealexandri@islab.ntua.gr

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 μια 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 β
 - 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 συναρτήσει 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 η**

- $\eta = \sqrt{\frac{8 \log N}{T}}$, $R_T \leq \sqrt{\frac{T \log N}{2}}$ 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}_ρ : Απώλεια ρ -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(α_0)

```
1   $\alpha \leftarrow \alpha_0$     ▷ 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(α_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(η)

```
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^η 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_∞ για *Winnow*

Βιβλιογραφία

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