


## Βασικές Έννοιες

- ▶ **Σύμπαν** (domain) **X**: σύνολο (παρα)δειγμάτων για κατηγοριοποίηση, όπως περιγράφονται με βάση χαρακτηριστικά.
  - ▶ Έστω όλα τα μήλα: **X = Βάρος x Όγκος x Περίμετρος x Χρώμα**
- ▶ **Κατηγορίες** (labels) **Y** (εστιάζουμε σε  $|Y| = 2$ , π.χ.  $Y = \{-1, +1\}$  ή  $Y = \{0, 1\}$ )
  - ▶ Για μήλα: **Y = { Άνοστο, Νόστιμο }**
- ▶ **Υπόθεση** (hypothesis, concept, classifier) **h : X → Y**
  - ▶ Κατηγοριοποιεί μήλο («παράδειγμα») ως άνοστο ή νόστιμο με βάση χαρακτηριστικά.
  - ▶ Για  $|Y| = 2$ , υπόθεση **h ⊆ X** (σύνολο νόστιμων μήλων).
- ▶ **Στόχος**: δεδομένων ορθά **κατηγοριοποιημένων** παραδειγμάτων, υπολογισμός υπόθεσης **h : X → Y** που κατηγοριοποιεί **ορθά όλα(;) τα** παραδείγματα στο X.
  - ▶ Δοκιμάζοντας **λίγα** μήλα, μαθαίνουμε να αποφεύγουμε **όλα** τα άνοστα!
  - ▶ Στατιστική (λίγα παραδείγματα) και υπολογιστική (ταχύτητα) **αποδοτικότητα**.



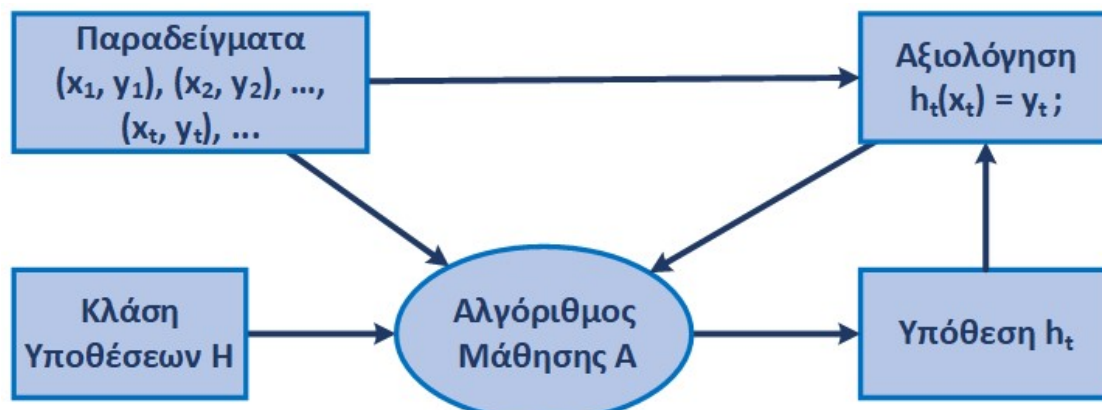
## Άμεση Μάθηση (Online Learning)

- ▶ Κάθε χρονική στιγμή  $t = 1, 2, \dots$  (επ' άπειρον):
  - ▶ Επιλέγουμε **υπόθεση**  $h_t : X \rightarrow Y$
  - ▶ Εμφανίζεται **παράδειγμα**  $x_t \in X$
  - ▶ Τοποθετούμε παράδειγμα  $x_t$  στην **κατηγορία**  $z_t = h_t(x_t)$
  - ▶ Πληροφορούμαστε (ορθή) **κατηγορία**  $y_t$  παραδείγματος  $x_t$
  - ▶ Αν  $z_t \neq y_t$ , έχουμε **λάθος** (κόστος 1), διαφορετικά **σωστό** (κόστος 0)
- ▶ **Στόχος: πεπερασμένο** κόστος (για **άπειρη** ακολουθία παραδειγμάτων)!
  - ▶ «Μικρό» σύμπαν αποτελεί **τετριμμένη** περίπτωση (απομνημόνευση).
  - ▶ Χωρίς γνωστή «δομή», μπορεί **μη εφικτό** για «μεγάλο» (ή **άπειρο**) σύμπαν.



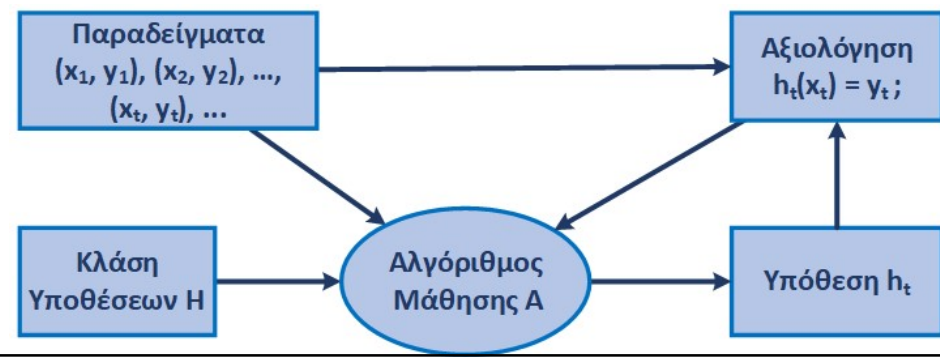
## Άμεση Μάθηση (Online Learning)

- ▶ Κάθε χρονική στιγμή  $t = 1, 2, \dots$  (επ' άπειρον):
  - ▶ Επιλέγουμε υπόθεση  $h_t : X \rightarrow Y$  και εμφανίζεται παράδειγμα  $(x_t, y_t) \in (X \times Y)$
  - ▶ Αν  $h_t(x_t) \neq y_t$ , έχουμε λάθος (κόστος 1), διαφορετικά σωστό (κόστος 0)
- ▶ **Στόχος: πεπερασμένο** κόστος (για **άπειρη** ακολουθία παραδειγμάτων)!
  - ▶ Χωρίς γνωστή «δομή», μπορεί **μη εφικτό** για «μεγάλο» (ή **άπειρο**) σύμπαν.
- ▶ **Κλάση υποθέσεων** (hypothesis class)  $H \subseteq 2^X$  (ή γενικά  $H \subseteq Y^X$ ) και υπάρχει απόλυτα **συνεπής** υπόθεση  $f \in H$  ώστε  $y_t = f(x_t)$ , για κάθε  $x_t \in X$ .
  - ▶ «Ορθή» κατηγοριοποίηση  $f$  για  $X$ : **πραγματοποιήσιμη** (realizable) περίπτωση.
  - ▶ Απαιτούνται **υποθέσεις** για κλάση  $H$  ή/και για μέγεθος περιγραφής  $f$ .



## Άμεση Μάθηση με Φράγμα Λαθών

- ▶ **Κλάση υποθέσεων  $H$**  μαθαίνεται με  **$M$  λάθη**, αν υπάρχει αλγόριθμος με  $\leq M$  λάθη για κάθε ακολουθία παραδειγμάτων **κατηγοριοποιημένων** από κάποια  $f \in H$ .
  - ▶ Επιθυμητή **πολυωνυμική** (π.χ., στο  $\log_2|H|$ ) υπολογιστική πολυπλοκότητα!
- ▶ **Παράδειγμα:** εκμάθηση **λογικών διαζεύξεων** σε  $\leq n$  μεταβλητές.
  - ▶ Σύμπαν  $X = \{0, 1\}^n$ , κλάση  $H_{\text{disj-}n}$  περιέχει **όλες λογικές διαζεύξεις**  $\leq n$  μεταβλητών. Π.χ.,  $h_{\{1,3,7\}}(x) = x_1 \vee x_3 \vee x_7$ . 
$$h_S(x) = \bigvee_{i \in S} x_i, \quad \forall S \subseteq \{1, \dots, n\}$$
  - ▶ Αρχικά  $S = \{1, \dots, n\}$  και υπόθεση  $h_S$ . Αμετάβλητη:  $h_S(x) \geq f(x)$ .
  - ▶ Για κάθε **λάθος**  $h_S(x) = 1$  και  $f(x) = 0$ , αφαιρούμε από  $S$  κάθε θέση  $i$  όπου  $x_i = 1$ .
  - ▶ Σε κάθε λάθος,  $|S|$  **μικραίνει τουλάχιστον κατά 1**: συνολικά  $\leq n$  λάθη.
  - ▶ Κλάση **λογικών διαζεύξεων**  $H_{\text{disj-}n}$  μαθαίνεται **με  $n$  λάθη** (βέλτιστο στη χειρ. περ.).
- ▶ **Συντηρητικός** αλγόριθμος: ενημερώνει κατάσταση του **μόνο όταν κάνει λάθος**.
- ▶ **Perceptron** μαθαίνει υπερεπίπεδο διαχωρισμού με  $O(1/\gamma^2)$  λάθη ( $\gamma$  περιθώριο).



## Αλγόριθμος Υποδιπλασιασμού (Halving Algorithm)

- ▶ Υποδιπλασιασμός για **πεπερασμένη** κλάση υποθέσεων  $H$ :
  - ▶ Αρχικά  $S_0 = H$ . Διατηρούμε **σύνολο  $S_t$  συνεπών** υποθέσεων μέχρι δείγμα  $t$ .
  - ▶ Για  $t = 1, 2, \dots$ , κλάση  $z_t$  δείγματος  $x_t$  με **πλειοψηφία** σε **συνεπείς** υποθέσεις  $h \in S_{t-1}$
  - ▶  $S_t = \{ h \in S_{t-1} \mid h(x_t) = y_t \}$  (υποθέσεις συνεπείς για  $t$  πρώτα παραδείγματα).
  - ▶ Συνολικά  $\leq \log_2(|H|)$  λάθη: αν έχουμε **λάθος**,  $|S_t| \leq |S_{t-1}| / 2$ , λόγω πλειοψηφίας.
  - ▶ Αν έχουμε **prior  $p_h$**  = πιθανότητα υπόθεση  $h$  να είναι απολύτως ορθή.
  - ▶ Πλειοψηφία με βάση πιθανότητες  $p_h$ . **Λάθη  $\leq$  εντροπία** αντίστοιχης κατανομής.
- ▶ Χρονική **πολυπλοκότητα  $O(|H|)$**  – **εκθετικός** σε μέγεθος περιγραφής  $h \in H$ !
  - ▶ Αποδοτικές υλοποιήσεις: π.χ., αλγόριθμος **ελλειψοειδούς** μαθαίνει **υπερεπίπεδο** διαχωρισμού σε  $n$ -πλέγμα διάστασης  $d$  με  **$O(d^2 \log(n))$**  λάθη, αντί  **$O(d \log(n))$**  λαθών.
- ▶ Αν κλάση  $H$  **δεν** περιέχει **απολύτως ορθή** υπόθεση για  $X$ :  
**αγνωστική** (agnostic) περίπτωση.



## Επιλέγοντας Συμβουλή Ειδικού

- ▶ Έχουμε  $|H|$  ειδικούς, έναν για κάθε  $h \in H$ , που προβλέπουν αν βρέξει ή όχι.
- ▶ Κάθε πρωί  $t = 1, 2, \dots, T$ , βλέπουμε **χαρακτηριστικά** καιρού  $x_t$  και **επιλέγουμε**  $h_t$
- ▶ Αν  $h_t(x_t) = y_t$ , έχουμε κόστος **0**, αλλιώς κόστος **1**.
- ▶ **Στόχος**: κόστος συγκρίσιμο με κόστος **καλύτερου ειδικού** (εκ των υστέρων).
 
$$\text{regret}(T) = \sum_{t=1}^T (h_t(x_t) \neq y_t) - \min_{h \in H} \sum_{t=1}^T (h(x_t) \neq y_t)$$
  - ▶ Αν τέλειος ειδικός, **πλειοψηφία αλάνθαστων** μέχρι στιγμής εγγυάται  **$\leq \log_2 |H|$  λάθη**
  - ▶ Αν **όχι**, φάσεις με **πλειοψηφία αλάνθαστων** με επανεκκίνηση όταν όλοι  $\geq 1$  λάθος.
  - ▶ Αν  $L = \#$ λαθών καλύτερου ειδικού, έχουμε  **$\leq L+1$  φάσεις**, και  **$\leq \log_2 |H|$  λάθη/φάση**.
  - ▶ Συνολικός **#λαθών  $\leq \log_2 |H| (L + 1)$** .
  - ▶ «Ξεχνάμε» εντελώς προηγούμενες φάσεις: περιθώριο **σημαντικής βελτίωσης!**

## Πλειοψηφία με Βάρη Εμπιστοσύνης (WMA)

- ▶ **Λάθος δεν αποκλείει** κάποιον ειδικό  $h$ , αλλά **μειώνει βάρος** εμπιστοσύνης  $w(h)$ .
  - ▶ Αρχικά  $\mathbf{w}_1(\mathbf{h}) = \mathbf{1}$  για κάθε  $h \in H$ . Σε κάθε βήμα  $t = 1, 2, \dots, T$ :
  - ▶ Για παρατήρηση  $x_t$ , υιοθετούμε **πρόταση  $\mathbf{z}_t$**  που συγκεντρώνει **βεβαρημένη πλειοψηφία**.
 
$$\sum_{h \in H: h(x_t) = z_t} w_t(h) \geq W_t(H)/2$$
  - ▶ Για κάθε  $h \in H$  με  $h(x_t) \neq y_t$ ,  $\mathbf{w}_{t+1}(\mathbf{h}) = \mathbf{w}_t(\mathbf{h})/2$  ( γενικότερα  $\mathbf{w}_{t+1}(\mathbf{h}) = (1 - \epsilon)\mathbf{w}_t(\mathbf{h})$  ).
- ▶  $L = \#$ λαθών καλύτερου ειδικού,  $M = \#$ λαθών αλγόριθμου,  $W =$  συνολικό βάρος.
  - ▶ Αρχικά  $W_1 = |H|$ , **μειώνεται κατά 25%** σε κάθε λάθος:  $W_{t+1} \leq 3 W_t / 4$ 

$$(1/2)^L \leq |H|(3/4)^M$$

$$-L \leq \log(|H|) - M \log(4/3)$$
  - ▶ Βάρος καλύτερου ειδικού  $\leq$  συνολικό βάρος
 
$$M \leq 2.41(L + \log(|H|))$$
  - ▶  $\#$ λαθών  $\leq \mathbf{2.41(L + \log_2|H|)}$ , αντί του  $\log_2|H| (L + 1)$  για πλειοψηφία με φάσεις.
  - ▶  $\mathbf{2.5 \log_2|H|}$  λάθη αρχικά, και μετά  $\mathbf{2.5}$  λάθη αλγόριθμου για **κάθε αναπόφευκτο** λάθος!
  - ▶ Όχι ικανοποιητικό για «δύσκολες» προβλέψεις με «μεγάλο»  $L$ . Μπορούμε καλύτερα;

## Αναλογικότητα με Βάρη Εμπιστοσύνης (RWMA)

- ▶ Αντίστοιχα, αλλά χρησιμοποιούμε τα **βάρη** ως **πιθανότητες!**
  - ▶ Αρχικά  $\mathbf{w}_1(\mathbf{h}) = \mathbf{1}$  για κάθε  $h \in H$ . Σε κάθε βήμα  $t = 1, 2, \dots, T$ :
  - ▶ Για παρατήρηση  $x_t$ , υιοθετούμε **πρόταση**  $\mathbf{z}_t$  με **πιθανότητα ανάλογη βάρους** υποστήριξης.
 
$$\frac{\sum_{h \in H: h(x_t) = z_t} w_t(h)}{W_t(H)}$$
  - ▶ Για κάθε  $h \in H$  με  $h(x_t) \neq y_t$ ,  $\mathbf{w}_{t+1}(\mathbf{h}) = (1 - \varepsilon)\mathbf{w}_t(\mathbf{h})$ .
- ▶  $L = \#$ λαθών καλύτερου ειδικού,  $M =$  **αναμενόμενο #λαθών** αλγόριθμου,  $F_t =$  **πιθανότητα λάθους** σε βήμα  $t$ , και  $M = F_1 + F_2 + \dots + F_t + \dots$ 
  - ▶  $W_{t+1} = W_t[\text{σωστό}] + (1 - \varepsilon)W_t[\text{λάθος}]$ 

$$(1 - \varepsilon)^L \leq |H| \prod_t (1 - \varepsilon F_t)$$
  - ▶ Αφαιρούμε  $\varepsilon F_t$  από συνολικό βάρος  $W_t$  σε κάθε βήμα:  $\mathbf{W}_{t+1} = \mathbf{W}_t(1 - \varepsilon F_t)$ 

$$-L \ln(1 - \varepsilon) \leq \log(|H|) - \varepsilon \sum_t F_t$$
  - ▶  $\#$ λαθών  $\leq (1 + \varepsilon/2)L + \log_2 |H|/\varepsilon, \forall \varepsilon > 0.$ 

$$-L \ln(1 - \varepsilon) \leq \log(|H|) - \varepsilon M$$
  - ▶ **Regret** =  $\#$ λαθών – βέλτιστος  $\#$ λαθών
 
$$M \approx (1 + \varepsilon/2)L + \log(|H|)/\varepsilon$$
  - ▶  $\text{Regret} / L \rightarrow 0$ , καθώς  $L$  (ή  $T$ ) μεγαλώνει.
 
$$\varepsilon = \sqrt{\log(|H|)/L} \Rightarrow M \leq L + 2\sqrt{L \log(|H|)}$$
  - ▶ **No-regret** αλγόριθμοι: πρακτικά **βέλτιστος** μέσος  $\#$ λαθών, καθώς  $T$  μεγαλώνει!



## Γενικεύσεις – Εφαρμογές

- ▶ Γενικεύσεις – Παραλλαγές:
  - ▶ Πλαίσιο **πολλαπλασιαστικής ενημέρωσης βαρών** (multiplicative weight updates).
  - ▶ Fictitious play, winnow (αυξομείωση βαρών), Hedge όπου  $w_{t+1}(h) = w_t(h)\exp(-\eta \text{cost})$ , AdaBoost για συνδυασμό ταξινομητών, ...
  - ▶ **Bandits**: επιλογή μόνο ενός  $h_t$ , για κάθε  $t$ , και μαθαίνουμε μόνο για  $h_t(x_t) = y_t$
  - ▶ **Εκθετικά μεγάλο  $|H|$** : μείωση διάστασης, πλαίσιο **Follow the (Regularized) Leader**.
- ▶ Εφαρμογές:
  - ▶ Μηχανική μάθηση (γραμμικός διαχωρισμός, boosting, ...).
  - ▶ **Θεωρία παιγνίων**: 2-person 0-sum games, coarse correlated equilibrium
  - ▶ **Εξελικτική** θεωρία παιγνίων: replicator dynamics.
  - ▶ **Βελτιστοποίηση**: stochastic gradient descent, άμεση κυρτή βελτιστοποίηση
  - ▶ Προσεγγιστική επίλυση packing / covering γραμμικών προγραμμάτων.
  - ▶ Άμεσοι και προσεγγιστικοί αλγόριθμοι, αλγοριθμικός σχεδιασμός μηχανισμών
  - ▶ (Arora, Hazan, Kale, ToC 2012, <https://theoryofcomputing.org/articles/v008a006/v008a006.pdf> )