


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) **$h : X \rightarrow Y$**
 - ▶ Κατηγοριοποιεί μήλο («παράδειγμα») ως άνοστο ή νόστιμο με βάση χαρακτηριστικά.
 - ▶ Για $|Y| = 2$, υπόθεση **$h \subseteq X$** (σύνολο νόστιμων μήλων).
- ▶ **Στόχος**: δεδομένων ορθά **κατηγοριοποιημένων** παραδειγμάτων, υπολογισμός υπόθεσης **$h : X \rightarrow Y$** που κατηγοριοποιεί ορθά **όλα(;) τα παραδείγματα στο X**.
 - ▶ Δοκιμάζοντας **λίγα** μήλα, μαθαίνουμε να αποφεύγουμε **όλα** τα άνοστα!
 - ▶ Στατιστική (λίγα παραδείγματα) και υπολογιστική (ταχύτητα) **αποδοτικότητα**.




Μάθηση από Δεδομένα Εκπαίδευσης (Batch Learning)

- ▶ **Σύμπαν** (domain) **X**: σύνολο παραδειγμάτων για κατηγοριοποίηση.
- ▶ **Κατηγορίες** (labels) **Y** (εστιάζουμε σε $|Y| = 2$).
- ▶ **Υπόθεση** (hypothesis, concept, classifier) $h : X \rightarrow Y$
- ▶ Είσοδος **δεδομένα εκπαίδευσης**: $S = \{ (x_1, y_1), \dots, (x_m, y_m) \} \in (X \times Y)^m$
- ▶ Έξοδος: **υπόθεση** $h : X \rightarrow Y$ (ορθή στο μεγαλύτερο μέρος του X)
- ▶ **Στόχος**: αν υπάρχει ορθή $f : X \rightarrow Y$, μαθαίνουμε f ή άλλη υπόθεση $h \approx f$.



Μάθηση από Δεδομένα Εκπαίδευσης

- ▶ Είσοδος **δεδομένα εκπαίδευσης**:
 $S = \{(x_1, y_1), \dots, (x_m, y_m)\}$



- ▶ **Στόχος**: αν υπάρχει ορθή $f : X \rightarrow Y$, μαθαίνουμε f ή άλλη υπόθεση $h \approx f$.
 - ▶ Κατανομή D στο X ως μέτρο **«σοβαρότητας» λάθους** κατηγοριοποίησης $h(x) \neq f(x)$.
 - ▶ **Σφάλμα** $L_{D,f}(h) = \text{Prob}_{x \sim D}[f(x) \neq h(x)]$ αποτελεί **μέτρο απόκλισης** υπόθεσης h από f .
 - ▶ Υπολογισμός υπόθεσης $h : X \rightarrow Y$ με αρκετά **μικρό σφάλμα** $L_{D,f}(h)$.
 - ▶ Δεδομένα εκπαίδευσης $S = \{(x_i, f(x_i))\}_{i=1, \dots, m}$, με κάθε $x_i \sim D$, ώστε να **αντανακλούν** κατανομή D (ανεξάρτητα δείγματα) και **κατηγοριοποίηση** f .
 - ▶ **Άγνωστική** περίπτωση: δεδομένα $S = \{(x_i, y_i)\}$ από κατανομή D στο $X \times Y$, σφάλμα $L_D(h) = \text{Prob}_{(x,y) \sim D}[y \neq h(x)]$, και προσεγγίζουμε $f = \operatorname{argmin}_h \{L_D(h)\}$



«Μάλλον Σχεδόν Σωστή» (PAC) μάθηση

- ▶ «**Σχεδόν**» σωστό: αδύνατον $L_{D,f}(h) = 0$ (στη χειρότερη περίπτωση).
 - ▶ Π.χ., $X = \{x_1, x_2\}$ με πιθανότητες $(1 - 1/m^2, 1/m^2)$, οπότε δεν μαθαίνουμε $f(x_2)$.
 - ▶ Απαιτούμε $L_{D,f}(h) \leq \varepsilon$, για αρκετά μικρό λάθος $\varepsilon \in (0, 1)$
- ▶ «**Μάλλον**» σωστό: αδύνατον $L_{D,f}(h) \leq \varepsilon$ με σιγουριά (πιθανότητα = 1).
 - ▶ Σύνολο δεδομένων εκπαίδευσης S αποτελείται από ανεξάρτητα δείγματα: μικρή, αλλά θετική, πιθανότητα να έχουμε δει λίγα διαφορετικά στοιχεία του X .
 - ▶ Απαιτούμε $\text{Prob}_S[L_{D,f}(h) > \varepsilon] \leq \delta$, για κάποιο αρκετά μικρό $\delta \in (0, 1)$
- ▶ «**Μάλλον σχεδόν σωστή**» (Probably Approximately Correct – **PAC**) μάθηση.
 - ▶ Για κάθε κατανομή D και κάθε $f : X \rightarrow Y$ (άγνωστα), για κάθε $\varepsilon, \delta \in (0, 1)$ (είσοδος)
 - ▶ Αλγόριθμος «ζητάει» $m(\varepsilon, \delta)$ ανεξάρτητα δείγματα $(x, f(x))$ από D , και παράγει υπόθεση $h : X \rightarrow Y$ με $\text{Prob}_S[L_{D,f}(h) \leq \varepsilon] \geq 1 - \delta$ (κλάση υποθέσεων;)
 - ▶ **Αγνωστική** περίπτωση: υπόθεση $h : X \rightarrow Y$ με $\text{Prob}_S[L_D(h) \leq \varepsilon + \min_f L_D(f)] \geq 1 - \delta$



Προκαθορισμένη Κλάση Υποθέσεων

- ▶ Δεν υπάρχει «καθολικός» αλγόριθμος, ανεξάρτητος από κλάση υποθέσεων H .
- ▶ Για κάθε αλγόριθμο A , domain X και $\#$ δειγμάτων $m \leq |X|/2$, υπάρχει f ώστε με πιθανότητα $> \delta$ (στην επιλογή m τυχαίων δειγμάτων $(x, f(x))$), $L_{D,f}(h_A) > \epsilon$.
- ▶ Ανάγκη για επιπλέον πληροφορία, με **προκαθορισμένη κλάση** υποθέσεων H .
- ▶ «**Μάλλον σχεδόν σωστή**» (Probably Approximately Correct – **PAC**) μάθηση.
 - ▶ Κλάση υποθέσεων H μαθαίνεται κατά PAC, αν για κάθε $\epsilon, \delta \in (0, 1)$, υπάρχει $m_H(\epsilon, \delta)$ και αλγόριθμος A
 - ▶ τ.ω. για κάθε κατανομή D στο X και κάθε υπόθεση $f : X \rightarrow Y$, με $f \in H$,
 - ▶ ο αλγόριθμος A με είσοδο $m_H(\epsilon, \delta)$ ανεξάρτητα δείγματα $(x, f(x))$ από D , υπολογίζει υπόθεση $h \in H$ με $\text{Prob}_S[L_{D,f}(h) \leq \epsilon] \geq 1 - \delta$ (αγνωστική περίπτωση;)
 - ▶ Συνάρτηση $m_H(\epsilon, \delta)$: **δειγματική πολυπλοκότητα** της κλάσης H .
- ▶ Ελαχιστοποίηση εμπειρικού σφάλματος (Empirical Risk Minimization – **ERM**):

$$\text{ERM}_H(S) = \arg \min_{h \in H} \{(x_i, y_i) \in S : h(x_i) \neq y_i\}$$





Πεπερασμένες και Άπειρες Κλάσεις Υποθέσεων

- ▶ Κάθε **πεπερασμένη** κλάση H , μαθαίνεται από **ERM** με $m \geq \log(|H|/\delta)/\varepsilon$ δείγματα.
 - ▶ $h \in H$ είναι «κακή» αν $h(x_i) = f(x_i)$ για κάθε $(x_i, f(x_i)) \in S$ και $L_{D,f}(h) > \varepsilon$:
«κακή» h έχει **μεγάλο πραγματικό σφάλμα** και **μηδενικό εμπειρικό σφάλμα**.
$$\text{Prob}_{S \sim D^m}[h \text{ “bad”}] < (1 - \varepsilon)^m$$



$$\text{Prob}_{S \sim D^m}[\exists h \in H : h \text{ “bad”}] < |H|(1 - \varepsilon)^m \leq \delta$$
- ▶ **Άπειρη** κλάση H : #δειγμάτων ορίζεται από **VC-διάσταση** (Vapnik–Chervonenkis)
 - ▶ $\text{VC}(H) = \text{μέγιστου μεγέθους σύνολο δειγμάτων } C \text{ που μπορεί να κατηγοριοποιηθεί από υποθέσεις στην } H \text{ με όλους } 2^{|C|} \text{ διαφορετικούς τρόπους.}$
 - ▶ Για κάθε κατηγοριοποίηση C , υπάρχει **πλήρως συμβατή υπόθεση** στην H .
 - ▶ $\text{VC}(H) = k$, αν (i) **υπάρχει** $C \subseteq X$, $|C| = k$, που κατηγοριοποιείται από H με 2^k τρόπους, και (ii) **κάθε** $C' \subseteq X$, $|C'| = k+1$, κατηγοριοποιείται από H με $< 2^{k+1}$ τρόπους.
 - ▶ $H \subseteq 2^X$ ως σύστημα συνόλων. **H θρυμματίζει** σύνολο C αν $|\{h \cap C : h \in H\}| = 2^{|C|}$
 - ▶ $\text{VC}(H) = \sup\{ |C| : H \text{ θρυμματίζει } C \}$

VC-Διάσταση: Παραδείγματα

- ▶ $VC(H) = k$: (I) **υπάρχει** $C \subseteq X$, $|C| = k$, που κατηγοριοποιείται από H με 2^k τρόπους,
 (II) **κάθε** $C' \subseteq X$, $|C'| = k+1$, κατηγοριοποιείται από H με $< 2^{k+1}$ τρόπους.
- ▶ Συναρτήσεις κατωφλίου στο R έχουν **VC-διάσταση 1**.




- ▶ Διαστήματα στο R έχουν **VC-διάσταση 2**.



VC-Διάσταση: Παραδείγματα

- ▶ $VC(H) = k$: (I) υπάρχει $C \subseteq X$, $|C| = k$, που κατηγοριοποιείται από H με 2^k τρόπους,
 (II) κάθε $C' \subseteq X$, $|C'| = k+1$, κατηγοριοποιείται από H με $< 2^{k+1}$ τρόπους.
 - ▶ Παραλληλόγραμμα στο R έχουν **VC-διάσταση 4**.



- ▶ Γραμμικοί διαχωριστές στο R^d έχουν **VC-διάσταση $d+1$** .




Θεμελιώδες Θεώρημα Στατιστικής Μάθησης

- ▶ Κλάση H **μαθαίνεται** αν και μόνο αν έχει **πεπερασμένη** VC-διάσταση $VC(H) = d$.
- ▶ Αλγόριθμος ERM, **δειγματική πολυπλοκότητα** για **πραγματοποιήσιμη** και **αγνωστική** περίπτωση:

$$m_H(\varepsilon, \delta) \leq \beta \frac{d \ln(1/\varepsilon) + \ln(1/\delta)}{\varepsilon}$$

$$m_H(\varepsilon, \delta) \leq \beta' \frac{d + \ln(1/\delta)}{\varepsilon^2}$$
- ▶ **Μάθηση με ομοιόμορφη σύγκλιση:**
 - ▶ Σύνολο S δειγμάτων **ε -αντιπροσωπευτικό** για H : για κάθε $h \in H$, $|L_S(h) - L_D(h)| \leq \varepsilon$
 - ▶ Αν σύνολο εκπαίδευσης S είναι **$(\varepsilon/2)$ -αντιπροσωπευτικό** για H , **ERM** υπολογίζει υπόθεση $h_{ERM} \in H$ με $L_D(h_{ERM}) \leq \min_h L_D(h) + \varepsilon$
 - ▶ Κλάση H έχει **ιδιότητα ομοιόμορφης σύγκλισης**: για κάθε κατανομή D , και $\varepsilon, \delta \in (0, 1)$, σύνολο $m_{H,UC}(\varepsilon, \delta)$ τυχαίων δειγμάτων ε -αντιπροσωπευτικό με πιθανότητα $\geq 1 - \delta$.
 - ▶ Κλάση H έχει **ιδιότητα ομοιόμορφης σύγκλισης** ανν έχει **πεπερασμένη** $VC(H) = d$.
 - ▶ Δειγματική πολυπλοκότητα: $m_H^{UC}(\varepsilon, \delta) \leq \beta'' \frac{d + \ln(1/\delta)}{\varepsilon^2}$



Ανομοιομόρφη Μάθηση – Κριτήριο Occam

- ▶ Κλάση H μαθαίνεται **ανομοιόμορφα** αν για κάθε υπόθεση $f \in H$, δειγματική πολυπλοκότητα $m_H(\varepsilon, \delta, f)$ εξασφαλίζει ότι $L_D(h) \leq L_D(f) + \varepsilon$.
 - ▶ Κλάση υποθέσεων H μαθαίνεται ανομοιόμορφα ανν H αριθμήσιμη **ένωση** κλάσεων με πεπερασμένη VC-διάσταση.
- ▶ **Κριτήριο Occam**
 - ▶ **Συντομότερες** εξηγήσεις (βλ. υποθέσεις) είναι **προτιμότερες** (μεταξύ εξηγήσεων παρόμοιας ακρίβειας).
 - ▶ Συντομότερες υποθέσεις έχουν **μικρότερη** δειγματική πολυπλοκότητα.
 - ▶ Υποθέσεις με περιγραφή **μήκους** d , δειγματική πολυπλοκότητα **$(d \ln(1/\varepsilon) + \ln(1/\delta))/\varepsilon$**
 - ▶ Προφανώς μπορεί να **μην** υπάρχει σύντομη υπόθεση με ικανοποιητικό σφάλμα.

Συναρτήσεις Σφάλματος – Υπολογιστική Πολυπλοκότητα


- ▶ Συνάρτηση σφάλματος $c: H \times (X \times Y) \rightarrow R_{\geq 0}$ αποτιμά **σφάλμα h σε δείγμα (x, y)** .
Σφάλμα με βάση συνάρτηση c : $L_D(h) = \text{Exp}_{(x,y) \sim D}[c(h, (x, y))]$
 - ▶ 0-1 σφάλμα: $c(h, (x, y)) = 0$, αν $h(x) = y$, και 1, αν $h(x) \neq y$.
 - ▶ Απόλυτη τιμή: $c(h, (x, y)) = |h(x) - y|$
 - ▶ Τετραγωνικό σφάλμα (γραμμική παλινδρόμηση): $c(h, (x, y)) = (h(x) - y)^2$
 - ▶ Hinge σφάλμα (SVM): $c(h, (x, y)) = \max\{1 - y \cdot h(x), 0\}$
 - ▶ Εκθετικό σφάλμα (λογιστική παλινδρόμηση): $c(h, (x, y)) = \ln(1 + e^{-y \cdot h(x)})$
- ▶ ERM μπορεί **υπολογιστικά δύσκολο** πρόβλημα (π.χ., μη-κυρτές συναρτήσεις σφάλματος, σύνθετες κλάσεις υποθέσεων).
 - ▶ Υιοθετούμε (απλές) **κυρτές κλάσεις υποθέσεων** (π.χ., υπερεπίπεδα) και **κυρτές συναρτήσεις σφάλματος** και βελτιστοποιούμε με **(stochastic) gradient descent**.
 - ▶ **Συνολικό σφάλμα:** (σφάλμα περιορισμού σε απλή κλάση H) + (σφάλμα βελτιστοποίησης) + (σφάλμα αντιπροσωπευτικότητας δεδομένων)

Υπολογιστική Πολυπλοκότητα

- ▶ ERM μπορεί **υπολογιστικά δύσκολο** πρόβλημα (π.χ., μη-κυρτές συναρτήσεις σφάλματος, σύνθετες κλάσεις υποθέσεων).
 - ▶ Υιοθετούμε (απλές) **κυρτές κλάσεις υποθέσεων** (π.χ., υπερεπίπεδα) και **κυρτές συναρτήσεις σφάλματος** και βελτιστοποιούμε με **(stochastic) gradient descent**.
 - ▶ **Υλοποίηση** (online projected / stochastic) gradient descent ως **άμεση μάθηση**: τρέχουσα υπόθεση (π.χ., υπερεπίπεδο) ενημερώνεται μετά από **κάθε δείγμα** με χρήση **(sub)gradient σφάλματος** υπόθεσης για δείγμα.
 - ▶ **Perceptron** και **SVM** προκύπτουν ως **ειδικές περιπτώσεις** γενικού πλαισίου.
 - ▶ **Άμεση μάθηση** H με $\#λαθών \leq M$ συνεπάγεται **PAC-μάθηση** με δειγματική πολυπλοκότητα $O((M+\ln(1/\delta))/\varepsilon)$.
 - ▶ (Υπολογιστικά «γρήγοροι») **προσεγγιστικοί αλγόριθμοι** για προβλήματα μάθησης: εκπαίδευση δέντρων απόφασης και τυχαίων δασών, νευρωνικά δίκτυα, GANs();


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 **Μ 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** (γ 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 ≥ 1 λάθος.
- ▶ Αν $L = \#\lambda\alpha\theta\omega\nu$ καλύτερου ειδικού, έχουμε $\leq L+1$ φάσεις, και $\leq \log_2 |H|$ λάθη/φάση.
- ▶ Συνολικός $\#\lambda\alpha\theta\omega\nu \leq \log_2 |H| (L + 1)$.
- ▶ «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 $w_1(h) = 1$ για κάθε $h \in H$. Σε κάθε βήμα $t = 1, 2, \dots, T$:
 - ▶ Για παρατήρηση x_t , υιοθετούμε **πρόταση 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 $h(x_t) \neq y_t$, $w_{t+1}(h) = w_t(h)/2$ (γενικότερα $w_{t+1}(h) = (1 - \varepsilon)w_t(h)$).
- ▶ $L = \#\text{λαθών καλύτερου ειδικού}$, $M = \#\text{λαθών αλγόριθμου}$, $W = \text{συνολικό βάρος}$.
 - ▶ Αρχικά $W_1 = |H|$, **μειώνεται κατά 25%** σε κάθε λάθος: $W_{t+1} \leq 3 W_t / 4$
$$(1/2)^L \leq |H|(3/4)^M$$
 - ▶ Βάρος καλύτερου ειδικού \leq συνολικό βάρος $-L \leq \log(|H|) - M \log(4/3)$
 - ▶ **#λαθών $\leq 2.41(L + \log_2|H|)$** , αντί του **$\log_2|H| (L + 1)$** για πλειοψηφία με φάσεις.
 - ▶ **2.5 $\log_2|H|$** λάθη αρχικά, και μετά **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 $w_1(h) = 1$ για κάθε $h \in H$. Σε κάθε βήμα $t = 1, 2, \dots, T$:
 - ▶ Για παρατήρηση x_t , υιοθετούμε **πρόταση** z_t $\frac{\sum_{h \in H: h(x_t) = z_t} w_t(h)}{W_t(H)}$ με **πιθανότητα ανάλογη βάρους** υποστήριξης.
 - ▶ Για κάθε $h \in H$ με $h(x_t) \neq y_t$, $w_{t+1}(h) = (1 - \varepsilon)w_t(h)$.
- ▶ $L = \#\text{λαθών καλύτερου ειδικού}$, $M = \text{αναμενόμενο } \#\text{λαθών αλγόριθμου}$,
 $F_t = \text{πιθανότητα λάθους σε βήμα } t$, 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 εF_t από συνολικό βάρος W_t σε κάθε βήμα: $W_{t+1} = W_t(1 - \varepsilon F_t)$ $-L \ln(1 - \varepsilon) \leq \log(|H|) - \varepsilon \sum_t F_t$
 - ▶ $\#\text{λαθών} \leq (1 + \varepsilon/2)L + \log_2 |H| / \varepsilon$, $\forall \varepsilon > 0$. $-L \ln(1 - \varepsilon) \leq \log(|H|) - \varepsilon M$
 - ▶ $\text{Regret} = \#\text{λαθών} - \text{βέλτιστος } \#\text{λαθών}$ $M \approx (1 + \varepsilon/2)L + \log(|H|) / \varepsilon$
 - ▶ $\text{Regret} / L \rightarrow 0$, 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 $\#\text{λαθών}$, 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 $|\mathcal{H}|$** : 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, αλγορίθμικός σχεδιασμός μηχανισμών
 - ▶ (Arora, Hazan, Kale, ToC 2012, <https://theoryofcomputing.org/articles/v008a006/v008a006.pdf>)

Συμπεράσματα

- ▶ Βασικές αρχές (υπολογιστικής) **Θεωρίας μάθησης.**
 - ▶ **Μοντέλο άμεσης μάθησης** με φράγμα στο #λαθών.
 - ▶ **Αλγόριθμοι πλειοψηφίας** (δυαδική αναζήτηση!), έννοια regret, **no-regret** αλγόριθμοι
 - ▶ **Σημαντικές εφαρμογές** σε κυρτή βελτιστοποίηση, υπολογισμό ισορροπιών σε παίγνια, άμεσους και προσεγγιστικούς αλγόριθμους, αλγορίθμικό σχεδιασμό μηχανισμών.
 - ▶ **«Μάλλον σχεδόν σωστή»** (PAC) μάθηση.
 - ▶ **VC-διάσταση**, ελαχιστοποίηση εμπειρικού σφάλματος (**ERM**), ομοιόμορφη σύγκλιση και ανομοιόμορφη μάθηση, υπολογιστική πολυπλοκότητα.
 - ▶ **Στενή σχέση** μεταξύ των δύο μοντέλων και με **άμεση (και κυρτή)** βελτιστοποίηση
 - ▶ Γνωστοί αλγόριθμοι / παραδείγματα (επιβλεπόμενης) μηχανικής μάθησης **εμπίπτουν(;) στο θεωρητικό** πλαίσιο με στόχο βαθύτερη **κατανόηση**.
 - ▶ Κατανόηση θεωρητικού πλαισίου **μπορεί(;) να οδηγήσει σε νέα παραδείγματα** ή/και **νέους αλγόριθμους** μηχανικής μάθησης.