

# Τυπολογιστική Νοημοσύνη

Ιωάννης Γ. Τσούλος

Τμήμα Πληροφορικής και τηλεπικοινωνιών  
Πανεπιστήμιο Ιωαννίνων

2024

# Περίληψη

## 1 MLP

- Βασικά στοιχεία

## 2 Μέθοδοι μάθησης

- Gradient Descent
- Η μέθοδος RPROP
- Η μέθοδος ADAM
- Η μέθοδος Simulated Annealing

## 3 Ειδικά θέματα

- Κανονικοποίηση τιμών
- Αρχικοποίηση βαρών
- Folding

# Ορισμός

- ① Είναι τεχνητά νευρωνικά δίκτυα τα οποία διαθέτουν ένα ή περισσότερα ενδιάμεσα επίπεδα επεξεργασίας.
- ② Απαραίτητο στοιχείο τους είναι οι συναρτήσεις ενεργοποίησης
- ③ Μπορούν να χρησιμοποιηθούν για μάθηση συναρτήσεων αλλά και για εύρεση κατηγοριών.
- ④ Επιλύουν προβλήματα που ένα απλό Perceptron δεν μπορεί να λύσει.
- ⑤ Αποτελούν την βάση για τα βαθιά νευρωνικά δίκτυα.

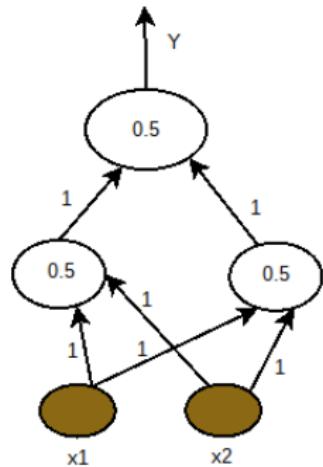
# Το πρόβλημα XOR

- ① Τα δίκτυα PERCEPTRON και ADALINE δεν είναι σε θέση να μάθουν πολύπλοκες συναρτήσεις όπως το κλασικό πρόβλημα XOR.
- ② Το πρόβλημα αυτό δίνεται στον επόμενο πίνακα.

A	B	γ
0	0	0
0	1	1
1	0	1
1	1	0

# Επίλυση του XOR με MLP

Μια ενδεικτική υλοποίηση με χρήση MLP



Για τα δίκτυα MLP έχει αναπτυχθεί και αποδειχθεί η θεωρία της παγκόσμιας προσέγγισης:

- ① Ένα δίκτυο δύο στρωμάτων (είσοδος - επεξεργασία - έξοδος) μπορεί να προσεγγίσει μια οποιαδήποτε συνάρτηση.
- ② Δεν χρειάζεται πάνω από ένα στρώμα επεξεργασίας
- ③ Οι νευρώνες του κρυφού στρώματος έχουν σαν συνάρτηση ενεργοποίησης την σιγμοειδή.
- ④ Ο νευρώνας εξόδου έχει σαν έξοδο την γραμμική συνάρτηση ενεργοποίησης.

# Το MLP σαν συνάρτηση

Ένα νευρωνικό δίκτυο MLP μπορεί να αναπαρασταθεί με πολλούς τρόπους αλλά ο πιο απλός είναι η ακόλουθη εξίσωση:

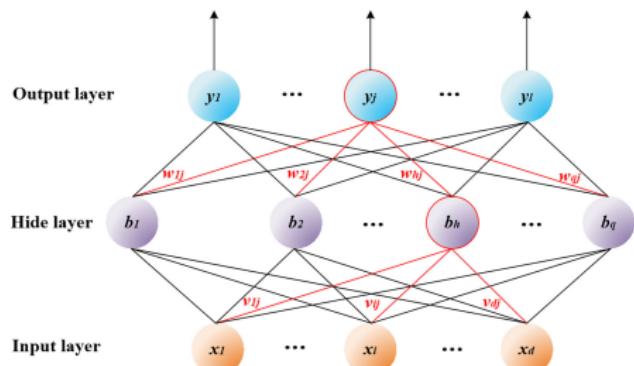
$$N(\vec{x}, \vec{w}) = \sum_{i=1}^H w_{(d+2)i-(d+1)} \sigma \left( \sum_{j=1}^d x_j w_{(d+2)i-(d+1)+j} + w_{(d+2)i} \right) \quad (1)$$

όπου

- ①  $H$  είναι ο συνολικός αριθμός μονάδων επεξεργασίας του νευρωνικού δικτύου
- ②  $d$  είναι η διάσταση του προβλήματος εισόδου.
- ③  $\vec{w}$  είναι τα βάρη του TNΔ.
- ④ Η πόλωση κάθε μονάδας επεξεργασίας:  $w_{(d+2)i}$ .
- ⑤ Αν  $d=3$  και έχουμε 2 κόμβους επεξεργασίας τότε συνολικά θα υπάρχουν  $(d+2)H = 10$  συνολικά παράμετροι στο TNΔ

- ① Χρησιμοποιούνται τόσες έξοδοι όσες και το πλήθος των κατηγοριών του προβλήματος (πχ στο wine 3)
- ② Το αποτέλεσμα του TNΔ θεωρείται εκείνη η έξοδος με την μεγαλύτερη τιμή εξόδου
- ③ Απαιτείται μεγαλύτερος αριθμός βαρών και πιο αργοί χρόνοι εκπαίδευσης

# ΤΝΔ πολλών εξόδων



# Κατώφλια στην μάθηση κατηγοριών

- ➊ Για τις περιπτώσεις που θέλουμε το παραπάνω δίκτυο να κάνει πρόβλεψη κατηγορίας μπορούν να χρησιμοποιηθούν κατώφλια στις τιμές.
- ➋ Για παράδειμα έστω ο ακόλουθος ενδεικτικός πίνακας:

$y(x)$	$N(x)$	CLASS
1	2.4	1
0	0.4	0
0	1.3	1
1	0.8	1

- ➌ Στην στήλη  $y(x)$  είναι η πραγματική έξοδος και στην στήλη  $N(x)$  η έξοδος του ΤΝΔ.
- ➍ Με την χρήση κατωφλιών (κοντινότερη κατηγορία) παράγεται η στήλη CLASS όπου βλέπουμε πως το ΤΝΔ "μαντεύει" σωστά τις 3 από τις 4 πραγματικές εξόδους.

# Μέσο τετραγωνικό σφάλμα σε μάθηση συναρτήσεων

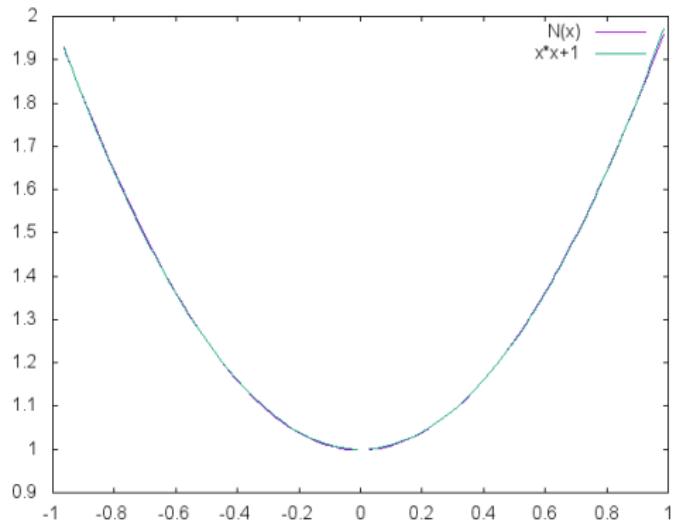
- ① Έστω  $x = (x_1, x_2, \dots, x_M)$  τα πρότυπα εισόδου
- ② Έστω  $y = (y_1, y_2, \dots, y_M)$  οι πραγματικές έξοδοι
- ③ Το σφάλμα ορίζεται

$$E = \frac{1}{M} \sum_{i=1}^M (N(x_i) - y_i)^2$$

- ④ Μπορεί να χρησιμοποιηθεί άμεσα σε μεθόδους βελτιστοποίησης

# Παράδειγμα μάθησης συνάρτησης

Στο σχήμα παρατίθεται η μάθησης της συνάρτησης  $x^2 + 1$  την οποία το δίκτυο Adaline δεν κατόρθωσε να μάθει.



- ① Έστω  $x = (x_1, x_2, \dots, x_M)$  τα πρότυπα εισόδου
- ② Έστω  $y = (y_1, y_2, \dots, y_M)$  οι πραγματικές έξοδοι
- ③ Το σφάλμα ορίζεται

$$E = \frac{1}{M} \sum_{i=1}^M (C(N(x_i)) \neq y_i)$$

- ④ Η συνάρτηση  $C(X)$  βρίσκει και επιστρέφει την κοντινότερη κατηγορία στην οποία είναι η τιμή  $X$ .

# Σφάλμα κατηγοριοποίησης σε imbalanced data

- ① Είναι δεδομένα στα οποία τα πρότυπα που ανήκουν σε κάποιες κατηγορίες είναι πολύ λιγότερα από τον μέσο όρο.
- ② Σε αυτήν την περίπτωση το TNΔ τείνει να μάθει μόνο τα δεδομένα που ανήκουν στην κατηγορία με τα περισσότερα πρότυπα.
- ③ Μια καλύτερη μέθοδος υπολογισμού
  - ① Έστω οι κατηγορίες  $C = (c_1, c_2, \dots, c_K)$
  - ② Υπολογίζουμε το σφάλμα κατηγοριοποίησης μεμονωμένο για κάθε κατηγορία  $E(c_i)$
  - ③ Το σφάλμα ορίζεται ως

$$E = \frac{1}{K} \sum_{i=1}^K E(c_i)$$

# Παράγωγοι της σιγμοειδούς

- ① Οι περισσότερες μέθοδοι εκπαίδευσης χρησιμοποιούν παράγωγο του σφάλματος
- ② Εμπλέκεται και η παράγωγος της συνάρτησης ενεργοποίησης.
- ③ Συνήθως η συνάρτηση ενεργοποίησης είναι η σιγμοειδής
- ④  $\sigma(x) = \frac{1}{1+\exp(-x)}$ ,  $\sigma'(x) = \sigma(x) \times (1 - \sigma(x))$
- ⑤ Τι πολογίζονται εύκολα, χωρίς πολλές πράξεις

# Ο αλγόριθμος Back Propagation (gradient descent)

Το μέσο τετραγωνικό σφάλμα ορίζεται ως:

$$E(N(\vec{x}, \vec{w})) = \sum (N(\vec{x}_i, \vec{w}) - y_i)^2 \quad (2)$$

Στην μέθοδο αυτή ισχύουν τα ακόλουθα:

- ① Κινούμαστε αντίθετα από ότι λέει η παράγωγος της εξίσωσης 2. Αν η παράγωγος είναι θετική τότε μειώνεται το αντίστοιχο βάρος αλλιώς αυξάνεται.
- ② Ο συντελεστής μάθησης είναι θετικός αριθμός και μικρότερος του 1.
- ③ Τα βάρη ενημερώνονται από τον κανόνα

$$w = w - n \frac{\partial E}{\partial w} \quad (3)$$

- ① Ο αλγόριθμος Back Propagation ουσιαστικά είναι ο αλγόριθμος Gradient Descent
- ② Έχει πολύ αργή σύγκλιση
- ③ Απαιτείται παραγώγιση (σε δίκτυα πολλών επιπέδων είναι δύσκολο).
- ④ Εξαρτάται άμεσα από την επιλογή του  $n$
- ⑤ Η τιμή του  $n$  μπορεί να υπολογιστεί και με γραμμική αναζήτηση
- ⑥ Υπάρχει online τρόπος μάθησης (ένα - ένα τα πρότυπα) και offline.
- ⑦ Τα βάρη ενημερώνονται διαρκώς είτε μέχρι να υπάρξει σύγκλιση είτε μέχρι να φτάσουμε σε μέγιστο αριθμό επαναλήψεων.

# Γραμμική αναζήτηση

## ① Η εξίσωση

$$x(\lambda) = x_1 + \lambda(x_2 - x_1)$$

δίνει την εξίσωση ευθείας που διέρχεται από τα σημεία  $x_1, x_2$

- ① Αν μια ευθεία διέρχεται από το  $x_1$  και είναι παράλληλη σε ένα διάνυσμα  $s$  έχει την μορφή

$$x(\lambda) = x_1 + \lambda s$$

- ② Η διαδικασία

$$\min_{\lambda} f(x + \lambda s)$$

ονομάζεται **γραμμική αναζήτηση**.

# Γενική μορφή γραμμικής αναζήτησης

- ① Δίνεται ένα σημείο  $x^{(k)}$
- ② Υπολογίζεται μια φθίνουσα κατεύθυνση  $s^{(k)}$
- ③ Ελαχιστοποιείται ως προς  $\lambda$  ( $\lambda > 0$ ) η συνάρτηση

$$\phi(\lambda) = f\left(x^{(k)} + \lambda s^{(k)}\right)$$

και εντοπίζεται η βέλτιστη τιμή  $\lambda^{(k)}$

- ④ Τίθεται  $x^{(k+1)} = x^{(k)} + \lambda^{(k)} s^{(k)}$

Στο σημείο 3 γίνεται η λεγόμενη **γραμμική αναζήτηση**.

# Τεχνικές γραμμικής αναζήτησης

- ① Γραμμική αναζήτηση χρυσής τομής.
- ② Γραμμική αναζήτηση Fibonacci.
- ③ Γραμμική αναζήτηση Armijo.

# Η γραμμική αναζήτηση χρυσής τομής

- Επιλέγονται σημεία  $x_1, x_2$  που να ισαπέχουν από τα άκρα του διαστήματος  $[a, b]$ .
- Τα βήματα έχουν ως ακολούθως
  - ①  $\phi = \frac{\sqrt{5}-1}{2}$
  - ② Για  $i = 1, 2, 3, \dots$  επαναλαμβάνουμε
    - ①  $x_1 = a + (1 - \phi)(b - a)$
    - ②  $x_2 = a + \phi(b - a)$
    - ③ Αν  $f(x_1) < f(x_2)$  τότε  $b = x_2$
    - ④ Άλλιώς  $a = x_1$
    - ⑤ Τέλος - Αν
  - ③ Τέλος - Για

Παράδειγμα για την  $f(x) = x(x-3)^*(x-3) + 2$

a	$x_1$	$f(x_1)$	$f(x_2)$	$x_2$	b
2.0000	2.7639	2.1540	2.1803	3.2361	4.0000
2.0000	2.4721	2.6888	2.1540	2.7639	3.2361
2.4721	2.7639	2.1540	2.0091	2.9443	3.2361
2.7639	2.9443	2.0091	2.0095	3.0557	3.2361
2.8754	2.9443	2.0091	2.0005	2.9868	3.0557
2.9443					3.0557

- Μετά από 6 επαναλήψεις έχει εντοπιστεί ένα διάστημα  $[2.9443, 3.0557]$

# Τερματισμός της μεθόδου Gradient Descent

- Μέγιστος αριθμός επαναλήψεων.
- $\|x_{k+1} - x_k\| \leq e$
- $|f(x_{k+1}) - f(x_k)| \leq e$
- $\frac{\|x_{k+1} - x_k\|}{\|x_k\|} \leq e$  (δεν δουλεύει αν  $x_k \simeq 0$ )

# Momentum Gradient Descent

- Για τον υπολογισμό του νέου σημείου λαμβάνεται υπόψιν και το ιστορικό των μεταβολών
- Εισάγεται μια ακόμα παράμετρος με το όνομα momentum (παράμετρος  $m$ )
- Η ενημέρωση γίνεται σύμφωνα με τον τύπο:

$$x_{k+1} = x_k - h \nabla f(x_k) - m(x_k - x_{k-1})$$

- Οι μεταβολές είναι πιο ομαλές, αλλά απαιτείται η χρήση δύο παραμέτρων.

- ① Στην μέθοδο αυτή το βήμα είναι μεταβλητό στην ενημέρωση των βαρών.
- ② Επίσης για την ενημέρωση των βαρών χρησιμοποίει τα πρόσημα των παραγώγων και όχι τις ίδιες τις παραγώγους.
- ③ Η ενημέρωση γίνεται

$$w^{(k+1)} = w^{(k)} - n^{(k)} \times \text{sign}\left(\frac{\partial E}{\partial w^{(k)}}\right)$$

# Το βήμα στον RPROP

- Το βήμα δίνεται από τον τύπο

$$n^{(k)} = \begin{cases} \min(n^{(k-1)} \times a, n_{\max}) & , \frac{\partial E^{(k)}}{\partial w^{(k)}} \times \frac{\partial E^{(k-1)}}{\partial w^{(k-1)}} > 0 \\ \max(n^{(k-1)} \times b, n_{\min}) & , \frac{\partial E^{(k)}}{\partial w^{(k)}} \times \frac{\partial E^{(k-1)}}{\partial w^{(k-1)}} < 0 \\ n^{(k-1)} & , \text{otherwise} \end{cases}$$

- Όπου  $a > 1 > b$
- Το βήμα περιορίζεται μεταξύ των τιμών  $n_{\min}$  και  $n_{\max}$  για να μην γίνει πολύ μεγάλο ή πολύ μικρό.
- Σε περίπτωση που η παράγωγος γίνει 0, τότε βρισκόμαστε σε τοπικό ελάχιστο της συνάρτησης σφάλματος και επομένως το βήμα δεν αλλάζει.

# Η μέθοδος ADAM

- Χρησιμοποιείται από το 2015 ευρύτατα στα βαθιά νευρωνικά δίκτυα.
- Δεν απαιτεί την χρήση δευτέρων παραγώγων.
- Είναι χρήσιμη σε περιπτώσεις που η παράγωγος έχει θόρυβο στον υπολογισμό της ή και υπάρχουν προβλήματα αριθμητικής ακρίβειας.
- Χρησιμοποιεί διανύσματα momentum και όχι απλώς έναν αριθμό.
- Παίρνει μέρος στον υπολογισμό τόσο η παράγωγος όσο και το τετράγωνό της.

## Ο αλγόριθμος της μεθόδου ADAM (παράμετροι)

- Παράμετρος  $\alpha$ , μέγεθος βήματος, συνήθως 0.001
- Παράμετροι  $\beta_1$ ,  $\beta_2$ , είναι οι παράγοντες momentum με συνήθεις τιμές 0.9 και 0.999

# Ο αλγόριθμος ADAM (βήματα)

- ① Θέσει  $m_0 = 0$ , πρώτο διάνυσμα momentum
- ② Θέσει  $u_0 = 0$ , δεύτερο διάνυσμα momentum
- ③ Θέσει  $k = 0$ , αριθμός επαναλήψεων
- ④ Έστω ένα νέο δείγμα από την συνάρτηση  $x_0$
- ⑤ Μέχρι τερματισμό κάνε

- ①  $g_k = \nabla f(x_k)$
- ②  $m_{k+1} = \beta_1 m_k + (1 - \beta_1) g_k$
- ③  $u_{k+1} = \beta_2 u_k + (1 - \beta_2) g_k^2$
- ④  $\hat{m}_{k+1} = \frac{1}{1-\beta_1^{k+1}} m_{k+1}$ , παίρνει δυνάμεις για τα  $\beta_1, \beta_2$  ώστε να μειώνεται η επίδρασή τους όσο περνάνε οι επαναλήψεις.
- ⑤  $\hat{u}_{k+1} = \frac{1}{1-\beta_2^{k+1}} u_{k+1}$
- ⑥  $x_{k+1} = x_k - \alpha \frac{\hat{m}_{k+1}}{(\sqrt{\hat{u}_{k+1}} + \epsilon)}$
- ⑦  $k = k + 1$

- ⑥ Τέλος - Μέχρι

- AdaGrad
- AdaDelta
- AdaMax
- AMSGrad
- RMSProp
- NADam

## Περιγραφή της μεθόδου

- Αναπτύχθηκε το 1983 από τον Kirkpatrick κυρίως για συνδυαστικά προβλήματα.
- Μιμείται την φυσική διαδικασία της Ανόπτυσης.
- Στην ανόπτυση ζεσταίνεται ένα μέταλλο σε υψηλή θερμοκρασία και εν συνεχείᾳ μειώνεται η θερμοκρασία μέχρι να φτάσει στο 0.
- Στην άνοδο τα μόρια του μετάλλου κινούνται γρήγορα (αναζήτηση λύσεων) αλλά στην συνέχεια όσο αυτό ψύχεται μειώνεται η ταχύτητά τους.
- Ο τρόπος που πέφτει η θερμοκρασία ονομάζεται cooling schedule
- Στα νευρωνικά δίκτυα απαιτείται συνδυασμός της μεθόδου αυτής και υπάρχουσων τεχνικών τοπικής αναζήτησης.

# Ενδεικτικός αλγόριθμος

## ① Θέτουμε $k = 0$ , $T_0 > 0$

- ① Έστω  $x_0$  το αρχικό σημείο.
- ② Έστω  $N_{eps} > 0$  ένας θετικός ακέραιος.
- ③ Έστω  $e > 0$ , ένας μικρός θετικός δεκαδικός αριθμός.
- ④ Για  $i = 1, \dots, N_{eps}$  επανέλαβε

- ① Έστω  $y$  ένα νέο δείγμα.
- ② Αν  $f(y) \leq f(x_k)$   $x_{k+1} = y$
- ③ Διαφορετικά  $x_{k+1} = y$  με πιθανότητα
 
$$\min \left\{ 1, \exp \left( -\frac{f(y) - f(x_k)}{\tau_k} \right) \right\}$$

## ⑤ Τέλος Για

- ⑥ Ενημέρωση θερμοκρασίας  $T_k$  σύμφωνα με τον μηχανισμό ψύξης.
- ⑦  $k = k + 1$
- ⑧ Αν  $T_k \leq e$  τερματισμός
- ⑨ Άλλιώς μετάβαση στο βήμα 5.

# Τεχνικές μείωσης Θερμοκρασίας

- Θεωρούμε πως ξεκινάμε πάντα από μια μεγάλη θερμοκρασία  $T_0$ 
  - $k$  ειναι η επανάληψη του αλγορίθμου.
  - Εκθετική μείωση:

$$T_k = T_0 a^k, \quad 0.8 \leq a \leq 0.9$$

- Logarithmical multiplicative cooling:

$$T_k = \frac{T_0}{1 + a \log(1 + k)}$$

- Linear multiplicative cooling:

$$T_k = \frac{T_0}{1 + ak}$$

- Quadratic multiplicative cooling:

$$T_k = \frac{T_0}{1 + ak^2}$$

# Ορισμοί

- ① Στις περισσότερες περιπτώσεις τα δεδομένα υποβάλλονται σε κανονικοποίηση πριν την παρουσίαση στο ΤΝΔ
- ② Έχει σαν αποτέλεσμα και μικρότερες τιμές στις παραγώγους.
- ③ Μέθοδοι κανονικοποίησης:
  - ① Ελαχίστου - μεγίστου
  - ② z-score
  - ③ Δεκαδική κλιμάκωση (διαίρεση με δυνάμεις του 10)
- ④ Δεν είναι δίκαιος τρόπος, καθώς πρέπει να γνωρίζουμε εκ των προτέρων πληροφορία τόσο από το σύνολο εκπαίδευσης όσο και από το σύνολο ελέγχου.
- ⑤ Η κανονικοποίηση της εξόδου στο διάστημα  $[0,1]$  είναι πιο δίκαιη και βοηθάει περισσότερο.

# Batch normalization

- ① Χρησιμοποιείται στα βαθιά νευρωνικά δίκτυα.
- ② Η έξοδος κάθε επιπέδου κανονικοποιείται πριν την είσοδο στο επόμενο επίπεδο

# Αρχικοποίηση σε χαμηλές τιμές

- ① Είναι ο πιο απλός τρόπος αρχικοποίησης.
- ② Χρησιμοποιείται στην πράξη περισσότερο από όλους.
- ③ Τα βάρη αρχικοποιούνται ομοιόμορφα σε χαμηλό διάστημα τιμών πχ. [-0.1, 0.1]

# Αρχικοποίηση Xavier

- ① Τα βάρη αρχικοποιούνται ομοιόμορφα στο διάστημα  $\left[-\frac{1}{\sqrt{d}}, \frac{1}{\sqrt{d}}\right]$
- ②  $d$  είναι η διάσταση των προτύπων εισόδου.
- ③ Υπάρχει και η κανονικοποιημένη εκδοχή:  $\left[-\frac{\sqrt{6}}{\sqrt{d+m}}, \frac{\sqrt{6}}{\sqrt{d+m}}\right]$ , όπου  $m$  είναι ο αριθμός των κόμβων στο τρέχον επίπεδο.

# Γενίκευση

- ① Σκοπός της μάθησης είναι η εύρεση κρυμμένων συσχετίσεων
- ② Γενίκευση είναι η μάθηση δεδομένων σε άγνωστα πρότυπα, τα οποία δεν έχουν χρησιμοποιηθεί κατά την εκπαίδευση
- ③ Χρήση πολλών νευρώνων: το δίκτυο μαθαίνει πολύπλοκες συναρτήσεις αλλά δεν μπορεί να μάθει σε άγνωστα δεδομένα το ίδιο καλά
- ④ Χρήση λίγων νευρώνων: το δίκτυο μαθαίνει απλές μόνο συναρτήσεις.

- ① Διαίρεση του συνόλου εκπαίδευσης σε εκπαίδευσης και επικύρωσης.
- ② Εκπαιδεύεται το δίκτυο στο μικρότερο πλέον σύνολο εκπαίδευσης
- ③ Η εκπαίδευση διακόπτεται όταν στο σύνολο επικύρωσης ξεκινά να ανεβαίνει στο σφάλμα.
- ④ Χρειάζεται προσεκτική επιλογή του ποσοστού για το σύνολο επικύρωσης
- ⑤ Απαραίτητα προϋπόθεση να έχουμε αρκετά δεδομένα στα χέρια μας.

## N-Fold

- ① Θέτουμε την παράμετρο  $N$
- ② Διαιρούμε το σύνολο των δεδομένων σε  $N$  σύνολο  $S_1, S_s, \dots, S_N$
- ③ Για  $i=1..N$ 
  - ① Δημιουργία συνόλου εκπαίδευσης  $T$  με όλα τα  $S_j$  για  $j$  διαφορετικό του  $i$
  - ② Εκπαίδευση στο σύνολο  $T$  και αποτίμηση του σφάλματος στο  $S_i$  με σφάλμα  $E_i$
- ④ Ο μέσος όρος των σφαλμάτων  $E_i$  είναι και το τελικό σφάλμα.

Στις πιο πολλές περιπτώσεις  $N=10$  αλλά και η τιμή  $N=2$  χρησιμοποιείται αρκετά συχνά.

Η μέθοδος Folding χρησιμοποιείται πάρα πολύ αλλά σε κάποιες περιπτώσεις τα δεδομένα δεν είναι αρκετά για να γίνει η παραπάνω διαδικασία. Σε αυτήν την περίπτωση χρησιμοποιείται η τεχνική leave one out, στην οποία το σύνολο ελέγχου αποτελείται μόνον από ένα πρότυπο.

# Σύνοψη

- Παρουσίαση δικτύων MLP
- Μέθοδοι εκπαίδευσης
- Ειδικά θέματα MLP

# Βιβλιογραφία |

-  Rosenblatt, Frank (1958), The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, Cornell Aeronautical Laboratory, Psychological Review, v65, No. 6, pp. 386–408.
-  Freund, Y. and Schapire, R. E. 1998. Large margin classification using the perceptron algorithm. In Proceedings of the 11th Annual Conference on Computational Learning Theory (COLT' 98). ACM Press.