



# Νευρωνικά δίκτυα

*Ιωάννης Μαδεμλής*

# Perceptron

- Ένα νευρωνικό δίκτυο είναι μία διασυνδεδεμένη συλλογή από πανομοιότυπα θεμελιώδη υπολογιστικά στοιχεία, τα οποία καλούνται **νευρώνες**.
- Δύο νευρώνες μπορούν να συνδέονται μεταξύ τους μέσω μίας **σύναψης**.
  - Ο νευρώνας στην αρχή της σύναψης (**προσυναπτικός**) δίνει την έξοδό του ως είσοδο στον νευρώνα του τέλους της σύναψης (**μετασυναπτικός**).
  - Σε κάθε σύναψη ανατίθεται ένα **συναπτικό βάρος**, ως αριθμητική παράμετρος.
  - Κάθε νευρώνας έχει  $N+1$  παραμέτρους:  $N$  είναι το πλήθος των συνάψεων όπου αυτός λειτουργεί ως μετασυναπτικός νευρώνας.

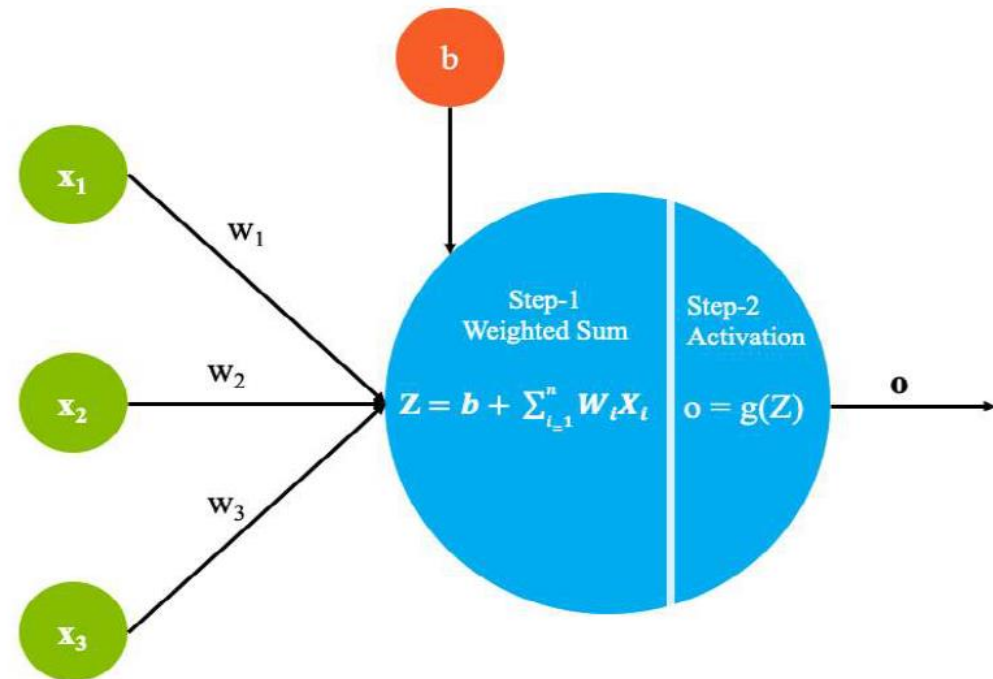
# Perceptron

- Η επιπρόσθετη αριθμητική παράμετρος κάθε νευρώνα καλείται **πόλωση**  $b$  (bias).
  - Κατά σύμβαση, θεωρούμε πως πρόκειται για το βάρος μίας ειδικής σύναψης με είσοδο πάντοτε 1.
- Η βασική γραμμική πράξη την οποία εκτελεί κάθε νευρώνας είναι ένα εσωτερικό γινόμενο:
  - $z = \mathbf{w}^T \mathbf{x}$ , όπου  $\mathbf{w}, \mathbf{x} \in \mathbb{R}^{N+1}$  και  $w_0 = b, x_0 = 1$ .
  - *Εναλλακτική σύμβαση:*  $z = \mathbf{w}^T \mathbf{x} + b$ , όπου  $\mathbf{w}, \mathbf{x} \in \mathbb{R}^N$ .
- Άρα  $\mathbf{w}$  είναι το διάνυσμα των παραμέτρων και  $\mathbf{x}$  το διάνυσμα των εισόδων του νευρώνα, αντιστοίχως.
- Η γραμμική έξοδος  $z$  του νευρώνα μεταβιβάζεται ως όρισμα σε μία **συνάρτηση ενεργοποίησης**  $g$ , η οποία ενδέχεται να είναι μη γραμμική.
  - Έτσι προκύπτει η τελική **ενεργοποίηση**  $a$  του νευρώνα.

# Perceptron

- Ο μεμονωμένος νευρώνας της ανωτέρω μορφής καλείται **perceptron**.
- Στο απλό perceptron υπάρχει μόνο ένας τέτοιος νευρώνας.
- Το διάνυσμα εισόδου  $\mathbf{x}$  του απλού perceptron είναι διάνυσμα χαρακτηριστικών/πρότυπο και όχι έξοδοι άλλων νευρώνων.

Νευρωνικά δίκτυα



# Perceptron

- Η επιλογή της συνάρτησης ενεργοποίησης είναι κρίσιμη, αφού σχετίζεται με την εργασία την οποία ζητούμε να εκτελέσει ο νευρώνας.
- Οι είσοδοι  $x$  είναι τα εκάστοτε δεδομένα τα οποία ζητούμε από τον νευρώνα να αναλύσει.
- Οι παράμετροι  $w$  μαθαίνονται κατά τη διάρκεια μίας προκαταρκτικής φάσης εκπαίδευσης σε ένα σύνολο εκπαίδευσης.
- Στην περίπτωση των ταξινομητών, οι παράμετροι ενός εκπαιδευμένου νευρώνα κωδικοποιούν γνώση περιοχών απόφασης.

# Perceptron

- Το απλό perceptron μπορεί να εκπαιδευτεί με έναν ειδικό αλγόριθμο σε κάποιο σύνολο εκπαίδευσης ως **δυναμικός ταξινομητής**.
  - Κατά τη λήξη της εκπαίδευσής του, το διάνυσμα βαρών του  $w$  και η πόλωσή του  $b$  κωδικοποιούν από κοινού τη γνώση ενός **υπερεπιπέδου απόφασης**.
  - Το  $w$  ορίζει τον προσανατολισμό αυτού του υπερπιπέδου στον διανυσματικό χώρο των προτύπων εισόδου, ενώ το  $b$  ορίζει την απόστασή του από την αρχή των αξόνων.
  - Ο αλγόριθμος εκπαίδευσης εντοπίζει τις κατάλληλες τιμές παραμέτρων  $w$  και  $b$  ώστε το εν λόγω υπερπίπεδο να διαχωρίζει βέλτιστα τις δύο κλάσεις.
    - Μετά τη λήξη της εκπαίδευσης, οι παράμετροι παγώνουν και ο ταξινομητής μπορεί να χρησιμοποιηθεί πλέον για την ταξινόμηση νέων προτύπων ελέγχου.
- Κατάλληλο μόνο για **γραμμικά διαχωρίσιμες κλάσεις**.

## Δίκτυα εμπρόσθιας τροφοδότησης

- Ένας μεμονωμένος νευρώνας δεν είναι ικανός να επιλύσει περίπλοκα προβλήματα.
- Έτσι προέκυψαν τα νευρωνικά δίκτυα, ως γράφοι αλληλεπιδρώντων και διασυνδεδεμένων νευρώνων οι οποίοι ενώνονται με συνάψεις.
- Ο συνηθέστερος τύπος νευρωνικού δικτύου είναι τα δίκτυα **εμπρόσθιας τροφοδότησης** (feed-forward).

Νευρωνικά δίκτυα

# Δίκτυα εμπρόσθιας τροφοδότησης

- Στα δίκτυα εμπρόσθιας τροφοδότησης οι νευρώνες είναι οργανωμένοι σε αριθμημένα επιμέρους **επίπεδα** (layers).
- Συνάψεις υπάρχουν μόνο μεταξύ διαφορετικών επιπέδων, όπου ο προσυναπτικός νευρώνας τοποθετείται πάντοτε σε επίπεδο το οποίο προηγείται του μετασυναπτικού.

- Παραδείγματα:

- Μπορεί να υπάρχει σύναψη από νευρώνα του 2<sup>ου</sup> επιπέδου σε νευρώνα του 3<sup>ου</sup> επιπέδου.
- Μπορεί να υπάρχει σύναψη από νευρώνα του 2<sup>ου</sup> επιπέδου σε νευρώνα του 5<sup>ου</sup> επιπέδου.
- **Δεν** μπορεί να υπάρχει σύναψη από νευρώνα του 3<sup>ου</sup> επιπέδου σε νευρώνα του 2<sup>ου</sup> επιπέδου.
- **Δεν** μπορεί να υπάρχει σύναψη από νευρώνα του 3<sup>ου</sup> επιπέδου σε νευρώνα επίσης του 3<sup>ου</sup> επιπέδου.

Νευρωνικά δίκτυα



# Δίκτυα εμπρόσθιας τροφοδότησης

- Η είσοδος  $x$  των νευρώνων του πρώτου επιπέδου είναι ένα πρότυπο από το σύνολο δεδομένων μας.
  - **Επίπεδο εισόδου.**
- Η είσοδος  $x$  των νευρώνων του  $i$ -οστού επιπέδου ( $i > 1$ ) είναι συνήθως ένα σύνολο εξόδων κάποιου/κάποιων νευρώνων προηγούμενων επιπέδων ( $[1, i-1]$ ).
  - **Κρυμμένα επίπεδα.**
- Ως τελική έξοδο του δικτύου θεωρούμε το τελικό διάνυσμα ενεργοποίησης του τελευταίου επιπέδου.
  - **Επίπεδο εξόδου.**
  - Αυτή είναι η απάντηση στο ερώτημά μας σχετικά με το πρότυπο εισόδου.
    - Π.χ., ετικέτα κλάσης στην περίπτωση της ταξινόμησης.


# Πολυεπίπεδο Perceptron

- Το πρώτο δημοφιλές δίκτυο εμπρόσθιας τροφοδότησης ήταν ιστορικά το **Πολυεπίπεδο Perceptron** (Multilayer Perceptron, **MLP**).
  - Εμφανίστηκε σε ώριμη μορφή περί το 1986.
- Οι νευρώνες του είναι τύπου perceptron και η τοπολογία του έχει την ιδιαιτερότητα πως κάθε επίπεδο είναι **πλήρως συνδεδεμένο**.
  - Υπάρχει μία ξεχωριστή σύναψη μεταξύ **κάθε** νευρώνα του  $i$ -οστού επιπέδου και **κάθε** νευρώνα του  $(i+1)$ -οστού επιπέδου.
  - Στην αρχική/πρωτότυπη έκδοση του MLP δεν υπήρχαν συνάψεις μεταξύ μη διαδοχικών επιπέδων.
    - Τέτοιες **συνάψεις συντόμευσης** (skip connections) έγιναν δημοφιλείς μόλις το 2015.

MLP

# Πολυεπίπεδο Perceptron

- Οι ενεργοποιήσεις των νευρώνων του  $i$ -οστού επιπέδου λειτουργούν ως χαρακτηριστικά εισόδου των νευρώνων του  $(i+1)$ -οστού επιπέδου.
  - Κάθε νευρώνας του  $(i+1)$ -οστού επιπέδου δέχεται την ίδια είσοδο: ένα διάνυσμα  $\mathbf{x}$  διάστασης ίσης με το πλήθος των νευρώνων του  $i$ -οστού επιπέδου.



MLP

# Συμβολισμοί MLP

## Ορισμοί:

- $L$ : συνολικό πλήθος επιπέδων (αρίθμηση επιπέδων: 1, 2, ...,  $L$ ).
- $W_l$ : πίνακας βαρών όλων των συνάψεων με μετασυναπτικό νευρώνα στο  $l$ -οστό επίπεδο.
- $w_{jk}^l$ : το τρέχον βάρος της σύναψης από τον  $k$ -οστό νευρώνα (στο  $(l-1)$ -οστό επίπεδο) προς τον  $j$ -οστό νευρώνα (στο  $l$ -οστό επίπεδο).
- $w_{j0}^l$ : η τρέχουσα πόλωση του  $j$ -οστού νευρώνα του  $l$ -οστού επιπέδου (σύμβαση των πολώσεων ως ειδικών συνάψεων).
- $\mathbf{b}^l$ : το διάνυσμα των τρεχόντων πολώσεων των νευρώνων του  $l$ -οστού επιπέδου (μία συνιστώσα  $w_{j0}^l$  ανά νευρώνα).
- $a_j^l$ : η τρέχουσα ενεργοποίηση/τιμή εξόδου του  $j$ -οστού νευρώνα του  $l$ -οστού επιπέδου.
- $z_j^l$ : η τρέχουσα γραμμική έξοδος του  $j$ -οστού νευρώνα του  $l$ -οστού επιπέδου, πριν τον μετασχηματισμό της από τη συνάρτηση ενεργοποίησης.

# Συμβολισμοί MLP

## Ορισμοί:

- $z^l$ : το διάνυσμα των τρεχουσών γραμμικών εξόδων όλων των νευρώνων του  $l$ -οστού επιπέδου (μία συνιστώσα ανά νευρώνα).
- $a^l$ : το διάνυσμα ενεργοποιήσεων/τελικών εξόδων όλων των νευρώνων του  $l$ -οστού επιπέδου (μία συνιστώσα ανά νευρώνα).
  - Λειτουργεί ως διάνυσμα εισόδου σε κάθε νευρώνα του επόμενου  $(l+1)$ -οστού επιπέδου.
- Η διαδοχική διάδοση της πληροφορίας διαμέσου όλων των επιπέδων κατά τη φορά από το επίπεδο εισόδου προς το επίπεδο εξόδου καλείται **ευθύ πέρασμα** (forward pass).
  - Αυτή είναι η κανονική λειτουργία ενός ήδη εκπαιδευμένου MLP.
  - **Μαθημένη** συνάρτηση απεικόνισης εισόδου σε έξοδο.

# Σχεδιαστικές επιλογές


- Αναθέτουμε συνήθως την ίδια συνάρτηση ενεργοποίησης σε όλους τους νευρώνες του ίδιου επιπέδου.
- Πρόκειται για δική μας σχεδιαστική επιλογή, όταν επιλέγουμε την τοπολογία του δικτύου **πριν από την εκπαίδευσή του**.
  - Παρομοίως, δική μας επιλογή είναι το πλήθος των επιπέδων και το πλήθος των νευρώνων στο κάθε επίπεδο.
- Εξαιρέσεις αποτελούν τα επίπεδα εισόδου και εξόδου.
  - Οι νευρώνες εισόδου είναι τόσοι όση η διαστατικότητα των προτύπων μας.
  - Το πλήθος των νευρώνων εξόδου και η συνάρτηση ενεργοποίησης του επιπέδου εξόδου εξαρτώνται από το πρόβλημα το οποίο θέλουμε να επιλύει το δίκτυο.
    - Π.χ., για ταξινόμηση  $K$  κλάσεων, έχουμε να επιλέξουμε μεταξύ συγκεκριμένων επιλογών.

MLP

# Συναρτήσεις ενεργοποίησης

- **Βηματική συνάρτηση.**

- Αν η είσοδος στη συνάρτηση – άρα η γραμμική έξοδος του νευρώνα – είναι μεγαλύτερη από ένα κατώφλι, τότε ο νευρώνας **πυροδοτεί** (δίνει ως τελική έξοδο την τιμή 1).




- Διαφορετικά ο νευρώνας **απενεργοποιείται** στο τρέχον ευθύ πέρασμα (δίνει ως τελική έξοδο την τιμή 0).
- Ασυνεχής και μη διαφορίσιμη συνάρτηση χωρίς καμία βιολογική πιστότητα στα φυσικά νευρωνικά δίκτυα (π.χ., τον εγκέφαλο).

# Συναρτήσεις ενεργοποίησης

- Γραμμική συνάρτηση.

- Η τελική έξοδος/ενεργοποίηση του νευρώνα είναι ευθέως ανάλογη της εισόδου του, ή ίση μαζί της.



Πηγή: Διαφάνειες MM, 2021.

- Χρήσιμη στο επίπεδο εξόδου, όταν στόχος μας είναι το δίκτυο να μάθει ένα πρόβλημα παλινδρόμησης.

- Διαφορίσιμη, συνεχής και δεν θέτει κανέναν περιορισμό στο πεδίο τιμών του νευρώνα.

- Η αποκλειστική χρήση της στα κρυμμένα επίπεδα ενός MLP **περιορίζει δραστικά** την ικανότητα του δικτύου να μάθει πολύπλοκα μοτίβα και να εξαγει χρήσιμη γνώση από το σύνολο εκπαίδευσης.

- Η γραμμικότητά της υποβιβάζει όλο το δίκτυο σε μία απλή σύνθεση γραμμικών πράξεων.


MLP



# Συναρτήσεις ενεργοποίησης

- Λογιστική σιγμοειδής συνάρτηση.

- Συμπιέζει τις εισόδους της στο πραγματικό διάστημα (0, 1).



Πηγή: Διαφάνειες MM, 2021.

- Είναι διαφορίσιμη, συνεχής, μη γραμμική και θέτει αυστηρό περιορισμό στο πεδίο τιμών του νευρώνα.


- Συνιστά μία συνεχώς διαφορίσιμη προσέγγιση της βηματικής συνάρτησης και έχει νευροβιολογική βάση.

- Παλαιότερα, ήταν η συνηθέστερη συνάρτηση ενεργοποίησης στα κρυμμένα επίπεδα.

# Συναρτήσεις ενεργοποίησης

- Συνάρτηση υπερβολικής εφαπτομένης ( $\tanh$ ).

- Παρόμοια με τη λογιστική σιγμοειδή, αλλά είναι συμμετρική πέριξ του μηδενός και συμπιέζει τις εισόδους της στο  $(-1, 1)$ .




Πηγή: Διαφάνειες MM, 2021.

- Είναι επίσης διαφορίσιμη, συνεχής, μη γραμμική και θέτει αυστηρό περιορισμό στο πεδίο τιμών του νευρώνα.
- Η χρήση της σε ένα επίπεδο δίνει τη δυνατότητα συνιστωσών με διαφορετικά πρόσημα στο ίδιο διάνυσμα εισόδου του επόμενου επιπέδου, κατά το ευθύ πέρασμα.

- Με τα διαφορετικά πρόσημα συλλαμβάνεται περισσότερη πληροφορία (π.χ., εύκολη διάκριση μεταξύ αρνητικών και θετικών συσχετίσεων).

# Συναρτήσεις ενεργοποίησης

- **Rectified Linear Unit (ReLU)**. Η συνηθέστερη σήμερα.
  - Συνδυασμός της βηματικής και της γραμμικής, ώστε να αποφευχθούν ορισμένα προβλήματα των σιγμοειδών, με ταυτόχρονη διατήρηση της ισχυρής μη γραμμικότητάς τους.



- Όσοι νευρώνες έχουν αρνητική γραμμική έξοδο κατά το ευθύ πέρασμα απενεργοποιούνται.
  - Εξοικονόμηση υπολογισμών λόγω μηδενικής ενεργοποίησης.
  - Αποφυγή υπερεκπαίδευσης κατά την εκπαίδευση.
- Στο ημιδιάστημα  $(0, +\infty)$  η ReLU είναι παντού συνεχώς διαφορίσιμη με σταθερή παράγωγο ίση με 1.

Πηγή: Διαφάνειες MM, 2021.

- Αντιθέτως, οι σιγμοειδείς παρουσιάζουν ισχυρό **κορεσμό** όσο περισσότερο απομακρυνόμαστε από το 0 στο πεδίο ορισμού τους.
  - Η παράγωγός τους τείνει στο 0 και αυτό προξενεί προβλήματα στην εκπαίδευση.

MLP

# Συναρτήσεις ενεργοποίησης

- **Softmax:**  $\sigma(\mathbf{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$ ,  $\sigma : \mathbb{R}^K \rightarrow (0,1)^K$ .

- Οι συνηθισμένες συναρτήσεις ενεργοποίησης είναι βαθμωτές συναρτήσεις μίας ανεξάρτητης μεταβλητής.
  - Υπολογίζονται ξεχωριστά ανά νευρώνα στο τρέχον επίπεδο.
- Αντιθέτως, η softmax είναι  $K$ -διάστατη διανυσματική συνάρτηση  $K$  ανεξάρτητων μεταβλητών, όπου  $K$  το πλήθος των νευρώνων του εν λόγω  $l$ -οστού επιπέδου.
  - Η τελική ενεργοποίηση κάθε νευρώνα του  $l$ -οστού επιπέδου εξαρτάται από τις γραμμικές εξόδους όλων των νευρώνων του ίδιου επιπέδου.
- Η softmax δέχεται ως είσοδο ένα  $K$ -διάστατο διάνυσμα γραμμικών εξόδων και το κανονικοποιεί σε μία έγκυρη **διακριτή κατανομή πιθανοτήτων**, ορισμένη επί ενός δειγματικού χώρου  $K$  απλών ενδεχομένων.

# Συναρτήσεις ενεργοποίησης

- Η softmax χρησιμοποιείται συνήθως στο επίπεδο εξόδου όσων MLP λειτουργούν ως ταξινομητές  $K$  κλάσεων.
  - $K$  νευρώνες εξόδου.
  - **One-hot** κωδικοποίηση των κλάσεων: ιδανικά, αν το πρότυπο εισόδου ανήκει στην  $i$ -οστή κλάση (όπου  $1 \leq i \leq K$ ), πρέπει κατά το τέλος του ευθέος περάσματος ο  $i$ -οστός νευρώνας εξόδου να έχει ενεργοποίηση 1 και οι υπόλοιποι νευρώνες εξόδου να είναι απενεργοποιημένοι.
    - Ισοδυναμεί με μία **κρουστική** διακριτή κατανομή  $K$  ενδεχομένων.
  - Στην πράξη, η έξοδος της τελικής softmax ενός ήδη εκπαιδευμένου MLP ταξινόμησης για νέα δείγματα ελέγχου έχει συνήθως μεγαλύτερη εντροπία απ' ότι η ιδανική κρουστική κατανομή.
    - Επιλέγουμε ετικέτα κλάσης με βάση απλώς το ποιος νευρώνας εξόδου έχει τη μεγαλύτερη ενεργοποίηση, μεταξύ όλων των νευρώνων εξόδου.

# Εκπαίδευση MLP

- Ένα MLP το οποίο έχει ήδη εκπαιδευτεί για κάποια εργασία (π.χ., ταξινόμηση), έχει συγκεκριμένες τιμές συναπτικών βαρών.
  - Αυτές οι συγκεκριμένες τιμές παραμέτρων κωδικοποιούν συγκεκριμένη γνώση εξηγμένη από το σύνολο εκπαίδευσης (π.χ., περιοχές απόφασης).
- Ο βασικός αλγόριθμος εκπαίδευσης του MLP είναι η **κάθοδος κλίσης** (gradient descent).
  - Εκκινούμε με τυχαία αρχικοποιημένες τιμές παραμέτρων.
    - Συνήθως πραγματικοί αριθμοί περίξ του μηδενός, αλλά όχι 0.
  - Επαναληπτικά: εκθέτουμε το δίκτυο σε ένα από τα πρότυπα του συνόλου εκπαίδευσης, εκτελούμε το αντίστοιχο ευθύ πέρασμα και υπολογίζουμε το κόστος για την τρέχουσα κάθε φορά επανάληψη.
    - Στην επόμενη επανάληψη δειγματοληπτούμε τυχαία άλλο πρότυπο εκπαίδευσης.

# Εκπαίδευση MLP

- Χρησιμοποιούμε συνάρτηση κόστους κατάλληλη για το προς επίλυση πρόβλημα.
- Συνήθως, για πρότυπο εισόδου  $\mathbf{x}$  γνωστής ετικέτας (από το σύνολο εκπαίδευσης), η συνάρτηση κόστους αποδίδει στην έξοδο του δικτύου μία βαθμωτή τιμή.
  - Η τιμή κόστους είναι ανάλογη της απόκλισης της εξόδου του δικτύου για είσοδο  $\mathbf{x}$  από την ιδανική έξοδο (την ετικέτα του  $\mathbf{x}$ ).
- Όμως η έξοδος του δικτύου είναι συνάρτηση όχι μόνο του  $\mathbf{x}$ , αλλά και του ολικού διανύσματος παραμέτρων του δικτύου  $\mathbf{w}$ .
- Βασικός στόχος της εκπαίδευσης είναι η εύρεση του κατάλληλου  $\mathbf{w}$  το οποίο **ελαχιστοποιεί** το μέσο κόστος επί όλου του συνόλου εκπαίδευσης.

# Κάθοδος κλίσης


- Συνήθης περίπτωση: συνεχείς βαθμωτές συναρτήσεις κόστους  $n$  μεταβλητών οι οποίες **δεν** είναι κυρτές. Τι κάνουμε;
  - Στη δική μας περίπτωση πρόκειται για τη συνάρτηση κόστους και το  $n$  είναι το ολικό πλήθος παραμέτρων του δικτύου.
- Ελαχιστοποιούνται με την **επαναληπτική** μέθοδο της **καθόδου κλίσης**.
- Εκκινούμε από τυχαίο σημείο του πεδίου ορισμού τους.
- Σε κάθε επανάληψη, υπολογίζουμε την **τοπική κλίση** της υπερεπιφάνειας του κόστους στο  $n$ -διάστατο πεδίο ορισμού της.
  - Άρα η ελαχιστοποίηση του κόστους εκτελείται στον χώρο των παραμέτρων.



# Κάθοδος κλίσης


- *Γιατί;* Το διάνυσμα κλίσης σε κάθε σημείο δηλώνει τη διεύθυνση της *τοπικά μέγιστης ανόδου* της υπερεπιφάνειας.
- Άρα ακολουθούμε μία πορεία επί του πεδίου ορισμού **αντίρροπη** προς την κατεύθυνση της εκάστοτε κλίσης.
- Σε κάθε επανάληψη εκτελούμε ένα **μικρό** βήμα με βάση την **τοπική** πληροφορία κλίσης.
- Οδηγούμαστε **σταδιακά** προς ένα κρίσιμο σημείο, με **σχεδόν μηδενική κλίση**.
  - Τότε σταματούμε.

# Κάθοδος κλίσης



Πηγή: Wikipedia.

Πηγή: easyai.tech.



Εκπαίδευση


# Κάθοδος κλίσης

- Στην  $i$ -οστή επανάληψη:  $\mathbf{x}^{i+1} = \mathbf{x}^i - \eta \nabla_x f(\mathbf{x}^i)$ 
  - $\eta$  βαθμωτή υπερπαράμετρος επιλεγμένη από εμάς (**ρυθμός κίνησης**).
  - Η κλίση συνήθως κανονικοποιείται ώστε να έχει  $\mathcal{L}_2$  νόρμα ίση με 1.
  - Ο ρυθμός κίνησης καθορίζει πλήρως τον ρυθμό αλλαγής του τρέχοντος  $\mathbf{x}^i$  σε διαδοχικές επαναλήψεις.
- Η κάθοδος κλίσης είναι εξαιρετικά ευαίσθητη στην επιλογή ρυθμού κίνησης.
- Διαφορετικές αντικειμενικές συναρτήσεις απαιτούν διαφορετικό ρυθμό κίνησης.
- Με το πέρασμα των επαναλήψεων μπορούμε να αλλάζουμε το  $\eta$ , ώστε να επιτύχουμε ταχύτερη σύγκλιση.

# Προβλήματα καθόδου κλίσης

- Προβλήματα:

- Ο αλγόριθμος ενδέχεται να συγκλίνει σε κρίσιμα σημεία τα οποία είναι μη ικανοποιητικά τοπικά ακρότατα ή σαγματικά σημεία.
- Αν η καμπυλότητα της υπερεπιφάνειας του κόστους τοπικά διαφέρει πολύ για διαφορετικές κατευθύνσεις επί του πεδίου ορισμού;



- Η κάθοδος κλίσης παλινδρομεί ως προς μία κατεύθυνση και κινείται πολύ αργά προς το εγγύτερο κρίσιμο σημείο.
- Αργή σύγκλιση!

# Οπισθοδιάδοση σφάλματος

- Σε κάθε επανάληψη της καθόδου κλίσης, χρειαζόμαστε το τρέχον διάνυσμα κλίσης της συνάρτησης κόστους ως προς τις παραμέτρους του δικτύου.
  - Έχει τόσες συνιστώσες (μερικές παραγώγους) όσες οι παράμετροι, δηλαδή τα συναπτικά βάρη και οι πολώσεις.
- Ο αλγόριθμος της **οπισθοδιάδοσης σφάλματος** (error back-propagation) είναι ένας έξυπνος τρόπος υπολογισμού του εν λόγω διανύσματος κλίσης, ξεχωριστά σε κάθε επανάληψη της καθόδου κλίσης.
  - Μας επιτρέπει να ενημερώσουμε τις παραμέτρους στο τέλος της τρέχουσας επανάληψης της εκπαίδευσης, προς μία κατεύθυνση σταδιακής μείωσης του κόστους.

# Οπισθοδιάδοση σφάλματος

- Εκμεταλλευόμαστε το γεγονός ότι το ευθύ πέρασμα του MLP είναι μία σύνθεση συναρτήσεων.
  - Όσο περισσότερα επίπεδα έχει το δίκτυο, τόσο περισσότερες συναρτήσεις συντίθενται.
    - Κάθε επιμέρους επίπεδο είναι σύνθεση δύο συναρτήσεων:  $g(\mathbf{z})$  και  $\mathbf{z}(\mathbf{x}) = \mathbf{W}^T \mathbf{x} + \mathbf{b}$ .
  - Είσοδος της ολικής σύνθετης συνάρτησης είναι το πρότυπο εισόδου.
  - Έξοδος της ολικής σύνθετης συνάρτησης είναι το διάνυσμα ενεργοποιήσεων εξόδου.
- Οι μερικές παράγωγοι της συνάρτησης κόστους ως προς κάθε παράμετρο του μοντέλου προκύπτουν από επαναλαμβανόμενη παραγωγή σύνθετης συνάρτησης.
  - Κανόνας της αλυσίδας του απειροστικού λογισμού.
    - Η παράγωγος της σύνθεσης δύο συναρτήσεων είναι γινόμενο των παραγώγων τους.
- Η οπισθοδιάδοση σφάλματος είναι ένας υπολογιστικά αποδοτικός τρόπος για να επιτευχθεί αυτό.

# Οπισθοδιάδοση σφάλματος

- Μετά το ευθύ πέρασμα, ακολουθεί ένα **αντίστροφο πέρασμα** (reverse pass) αντίθετης φοράς.
  - Πρώτα υπολογίζονται (απευθείας) οι μερικές παράγωγοι της συνάρτησης κόστους ως προς τις ενεργοποιήσεις εξόδου.
  - Στη συνέχεια ο αλγόριθμος διατρέχει ένα-ένα όλα τα επίπεδα από το τέλος προς την αρχή του δικτύου.
  - Σε κάθε επίπεδο, υπολογίζονται οι παράγωγοι με βάση τον κανόνα της αλυσίδας και τις (ήδη υπολογισμένες) παραγώγους του επόμενου επιπέδου.
- Μετά τη λήξη του αντίστροφου περάσματος, συλλέγονται όλες οι υπολογισμένες μερικές παράγωγοι σε ένα διάνυσμα κλίσης (gradient vector)...
- ...και εφαρμόζεται η εξίσωση ενημέρωσης παραμέτρων της καθόδου κλίσης για την τρέχουσα επανάληψη της εκπαίδευσης.

# Φθορά βαρών

- Η εκπαίδευση ενός μοντέλου μάθησης διαφέρει από την απλή ελαχιστοποίηση μίας συνάρτησης κόστους.
  - Πρέπει να ληφθούν και μέτρα για την αποφυγή της υπερεκπαίδευσης.
- Στα νευρωνικά δίκτυα, ο συνηθέστερος τρόπος είναι η προσθήκη ενός βοηθητικού όρου στη συνάρτηση κόστους  $f$  και η ελαχιστοποίηση του ολικού αθροίσματος.
  - **Φθορά βαρών** (weight decay), ή  $\mathcal{L}_2$ -κανονικοποίηση.
- Άρα ελαχιστοποιείται (με κάθοδο κλίσης) η ολική συνάρτηση κόστους:
  - $L = f + \lambda ||\mathbf{w}||_2^2$ , όπου  $\mathbf{w}$  είναι το διάνυσμα παραμέτρων του δικτύου και  $\lambda$  είναι βαθμωτός συντελεστής-υπερπαραμέτρος.



# Φθορά βαρών

- Η φθορά βαρών τιμωρεί κατά την εκπαίδευση υψηλές απόλυτες τιμές στα συναπτικά βάρη και στις πολώσεις.
  - Για να ελαχιστοποιηθεί η ολική  $L$ , πρέπει να βρεθεί ένα  $\mathbf{w}$  το οποίο και αποδίδει όσο το δυνατόν μικρότερη τιμή στην  $f$  (βασικό κόστος) και έχει μικρό μέτρο ταυτοχρόνως.
- Έτσι περιορίζεται η ευελιξία του δικτύου μέσω της ίδιας της διαδικασίας βελτιστοποίησης.
  - Μικρότερη ευελιξία συνεπάγεται μικρότερη δυνατότητα απομνημόνευσης του θορύβου και των ασήμαντων ιδιαιτεροτήτων του συνόλου εκπαίδευσης.
- Η ισορροπία μεταξύ του βασικού στόχου μάθησης, όπως κωδικοποιείται από τον όρο κόστους  $f$ , και του όρου κανονικοποίησης  $||\mathbf{w}'||_2^2$  ρυθμίζεται από την υπερπαράμετρο  $\lambda$ .

Thank you for your attention!

Q & A

*Contact:* [imademlis@aueb.gr](mailto:imademlis@aueb.gr)