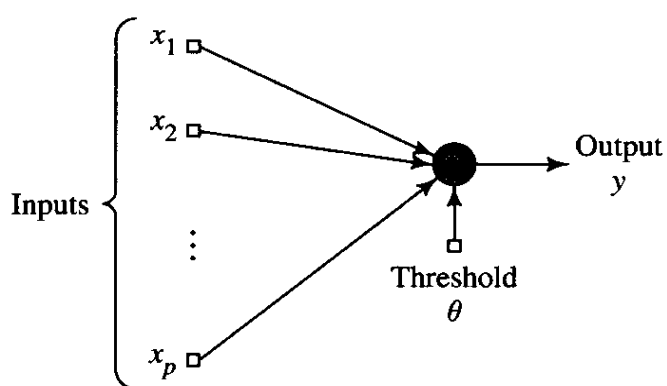


3. Ο ΑΛΓΟΡΙΘΜΟΣ ΤΟΥ PERCEPTRON

3.1 ΕΙΣΑΓΩΓΗ:

Το Perceptron είναι η απλούστερη μορφή Νευρωνικού δικτύου, το οποίο χρησιμοποιείται για την ταξινόμηση ενός ειδικού τύπου προτύπων, που είναι γραμμικά διαχωριζόμενα.

- Ένα τέτοιο δίκτυο φαίνεται στο σχήμα:




Σχήμα 1: Perceptron ενός επιπέδου

- Κανόνας εκπαίδευσης: Ο κανόνας του Rosenblatt.

- Μοντέλο νευρώνα: Το μοντέλο Mc Culloch - Pitts

Αποτελείται από ένα γραμμικό συνδυαστή ακολουθούμενο από ένα στοιχείο κατωφλίου και παράγει έξοδο με τιμή ± 1 .

- Θεωρούμε το signal - flow graph του perceptron.



- Η έξοδος του Γ.Σ. θα είναι:
$$v = \sum_{i=1}^p w_i x_i - \theta \quad (1)$$

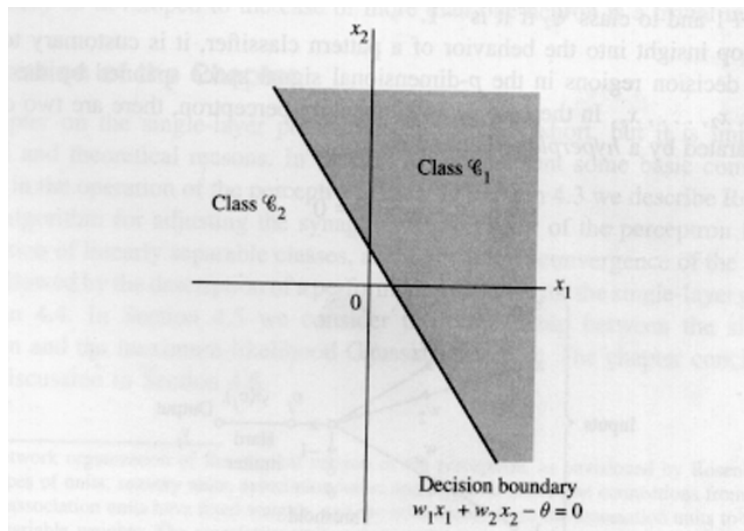
- Σκοπός του perceptron είναι να ταξινομήσει ένα σύνολο εισόδων x_1, x_2, \dots, x_p σε μία από τις κλάσεις I_1 και I_2 .

- Ο κανόνας απόφασης θα είναι: ανάθεσε το σημείο που αναπαριστούν x_1, x_2, \dots, x_p τα στην I_1 , αν $y = +1$ και στην I_2 αν $y = -1$.

- Οι περιοχές απόφασης διαχωρίζονται από το υπερεπίπεδο που ορίζεται από τη σχέση:

$$v = \sum_{i=1}^p w_i x_i - \theta = 0 \quad (2) \quad \Leftrightarrow \quad w_1 x_1 + w_2 x_2 - \theta = 0$$

Στο σχήμα 3 φαίνεται η γραμμική διαχωρισιμότητα για ένα δισδιάστατο πρόβλημα ταξινόμησης, με δύο κλάσεις



Σχήμα 3

Για την προσαρμογή του w χρησιμοποιούμε ένα error - correction rule.

3.2 ΤΟ ΘΕΩΡΗΜΑ ΣΥΓΚΛΙΣΗΣ ΤΟΥ PERCEPTRON.

- Θεωρούμε ότι το κατώφλι $\theta(n)$ σαν ένα συναπτικό βάρος, που είναι συνδεδεμένο σε μια σταθερή είσοδο -1 . Αρα, το $(p + 1) \times 1$ διάνυσμα εισόδου είναι:

$$\mathbf{x}(n) = [-1, x_1(n), x_2(n), \dots, x_p(n)]^T \quad (3)$$

και αντίστοιχα ορίζουμε το $(p + 1) \times 1$ διάνυσμα βαρών:


$$\mathbf{w}(n) = [\theta(n), w_1(n), w_2(n), \dots, w_p(n)]^T \quad (4)$$

- Η έξοδος του γραμμικού συνδυαστή είναι: $u(n) = \mathbf{w}^T(n) \mathbf{x}(n)$ (5)

- Αν οι κλάσεις I_1 και I_2 είναι γραμμικά διαχωριζόμενες, τότε υπάρχει ένα διάνυσμα βαρών:

$$\text{και} \quad \left. \begin{array}{l} \mathbf{w}^T \mathbf{x} \geq 0 \quad \forall \mathbf{x} \in I_1 \\ \mathbf{w}^T \mathbf{x} < 0 \quad \forall \mathbf{x} \in I_2 \end{array} \right\} \quad (6)$$

- Το πρόβλημα για το απλό Perceptron είναι να βρούμε το διάνυσμα βαρών w , το οποίο ικανοποιεί τις ανισότητες (6)



Σχήμα 4: Ισοδύναμο signal - flow graph του Perceptron.

- Αλγόριθμος προσαρμογής των βαρών.

1) Αν το n - στό μέλος του εκπαιδευτικού διανύσματος $\mathbf{x}(n)$, ταξινομείται σωστά από το διάνυσμα βαρών στην η -στή επανάληψη του αλγορίθμου, δεν γίνεται καμία διόρθωση στο $\mathbf{w}(n)$, δηλ.

$$\mathbf{w}(n+1) = \mathbf{w}(n) \text{ αν } \mathbf{w}^T(n) \mathbf{x}(n) \geq 0 \text{ και } \mathbf{x}(n) \in I_1$$

$$\text{και } \mathbf{w}(n+1) = \mathbf{w}(n) \text{ αν } \mathbf{w}^T(n) \mathbf{x}(n) < 0 \text{ και } \mathbf{x}(n) \in I_2 \quad (7)$$

2) Διαφορετικά, το διάνυσμα βαρών του Perceptron, ενημερώνεται σύμφωνα με τον κανόνα:

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \eta(n) \mathbf{x}(n) \text{ αν } \mathbf{w}^T(n) \mathbf{x}(n) \geq 0 \text{ και } \mathbf{x}(n) \in I_2$$

$$\text{και } \mathbf{w}(n+1) = \mathbf{w}(n) + \eta(n) \mathbf{x}(n) \text{ αν } \mathbf{w}^T(n) \mathbf{x}(n) < 0 \text{ και } \mathbf{x}(n) \in I_1 \quad (8)$$

- όπου η παράμετρος ρυθμού - μάθησης $\eta(n)$ ελέγχει τις ρυθμίσεις, που εφαρμόζονται στο διάνυσμα βαρών στην επανάληψη η .

- Αν $\eta(n) = \eta - ct > 0$, τότε έχουμε ένα κανόνα σταθερά αυξανόμενης προσαρμογής (fixed increment adaptation rule) για το Perceptron.

Σύγκλιση:

1) $\eta = 1$, ο fixed increment adaption rule συγκλίνει:

Απόδειξη:

Για $\mathbf{w}(0) = 0$, υποθέτουμε ότι $\mathbf{w}^T(n) \mathbf{x}(n) < 0$, για $\eta = 1, 2, \dots$ και το διάνυσμα $\mathbf{x}(n) \in X_1$ (το υποσύνολο των $\mathbf{x}_1(n), \mathbf{x}_2(n), \dots \in I_1$).

Αρα, το perceptron ταξινομεί λάθος τα $\mathbf{x}(1), \mathbf{x}(2), \dots$, και (6β) παραβιάζεται. Τότε για $\eta(n) = 1$, έχουμε:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \mathbf{x}(n) \text{ για } \mathbf{x}(n) \in I_1 \quad (9)$$

Επειδή $\mathbf{w}(0) = 0$, μπορούμε να λύσουμε επαναληπτικά την εξίσωση, άρα:

$$\mathbf{w}(n+1) = \mathbf{x}(1) + \mathbf{x}(2) + \dots + \mathbf{x}(n) \quad (10)$$

Επειδή οι κλάσεις I_1 και I_2 έχουν υποτεθεί γραμμικά διαχωριζόμενες υπάρχει μια λύση \mathbf{w}_0 για την οποία $\mathbf{w}_0^T \mathbf{x}(n) > 0$ για το διάνυσμα $\mathbf{x}(1), \dots, \mathbf{x}(n) \in X_1$.

- Για μια fixed λύση \mathbf{w}_0 , μπορούμε να υπολογίζουμε ένα θετικό αριθμό α από τη σχέση:

$$\alpha = \min_{\mathbf{x}(n) \in X_1} \mathbf{w}_0^T \mathbf{x}(n) \quad (11)$$

Αρα, από την (10), \Rightarrow πολ/τας επί \mathbf{w}_0^T , παίρνουμε:

$$\mathbf{w}_0^T \mathbf{w}(n+1) = \mathbf{w}_0^T \mathbf{x}(1) + \mathbf{w}_0^T \mathbf{x}(2) + \dots + \mathbf{w}_0^T \mathbf{x}(n) \quad (12)$$

(11)

$$(12) \Rightarrow \mathbf{w}_0^T \mathbf{w}(n+1) \geq n\alpha, \quad n = 1, 2, \dots, p \quad (13)$$

Από την ανισότητα Cauchy - Schwartz έχουμε:

$$\|\mathbf{w}_0\|^2 \|\mathbf{w}(n+1)\|^2 \geq [\mathbf{w}_0^T \mathbf{w}(n+1)]^2 \quad (14)$$

(14)

$$(13) \Rightarrow [\mathbf{w}_0^T \mathbf{w}(n+1)]^2 \geq n^2 \alpha^2 \Rightarrow \|\mathbf{w}_0\|^2 \|\mathbf{w}(n+1)\|^2 \geq n^2 \alpha^2$$

$$\Rightarrow \|\mathbf{w}(n+1)\|^2 \geq \frac{n^2 \alpha^2}{\|\mathbf{w}_0\|^2} \quad (15)$$

Στη συνέχεια, ακολουθούμε μια άλλη τεχνική. Ξαναγράφουμε την (9) στη μορφή:

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \mathbf{x}(k), \text{ για } k = 1, \dots, n \text{ και } \mathbf{x}(k) \in X_1 \quad (16)$$

$$\Rightarrow \|\mathbf{w}(k+1)\|^2 = \|\mathbf{w}(k)\|^2 + \|\mathbf{x}(k)\|^2 + 2\mathbf{w}^T(k) \mathbf{x}(k) \quad (17)$$

Αλλά, έχουμε υποθέσει ότι το perceptron ταξινομεί λάθος ένα διάνυσμα εισόδου $\mathbf{x}(k) \in X_1$, άρα $\mathbf{w}^T(k) \mathbf{x}(k) < 0$

$$(17) \Rightarrow \|\mathbf{w}(k+1)\|^2 \leq \|\mathbf{w}(k)\|^2 + \|\mathbf{x}(k)\|^2$$

$$\text{ή} \quad \Leftrightarrow \|\mathbf{w}(k+1)\|^2 - \|\mathbf{w}(k)\|^2 \leq \|\mathbf{x}(k)\|^2, \quad k = 1, \dots, n \quad (18)$$

- Προσθέτοντας τις ανισότητες για $k = 1, \dots, n$ και επειδή $\mathbf{w}(0) = 0$, έχουμε:

$$\|\mathbf{w}(n+1)\|^2 \leq \sum_{i=1}^p \|\mathbf{x}(k)\|^2 \leq n\beta \quad (19)$$

όπου β είναι μια θετική σταθερά που ορίζεται από:

$$\beta = \max_{\mathbf{x}(k) \in X_1} \|\mathbf{x}(k)\|^2 \quad (20)$$

- Η ανισότητα (19) ορίζει ότι η τετραγωνική νόρμα του $\mathbf{w}(k+1)$ αυξάνεται γραμμικά με τον αριθμό των επαναλήψεων (n).

Αυτό όμως, έρχεται σε αντίθεση με το αποτέλεσμα της (15), για ικανοποιητικά μεγάλες τιμές του n . Στην πραγματικότητα, το n δεν μπορεί να είναι μεγαλύτερο από κάποια τιμή n_{\max} , για την οποία οι σχέσεις (15) και (19) ικανοποιούνται σαν ανισότητα.

Αρα, το n_{\max} , θα είναι η λύση της εξίσωσης:

$$\frac{n_{\max}^2 \alpha^2}{\|\mathbf{w}_o\|^2} = n_{\max} \beta \Rightarrow n_{\max} = \frac{\beta \|\mathbf{w}_o\|^2}{\alpha^2} \quad (21)$$

- Εχουμε λοιπόν, αποδείξει ότι, για $\eta(n) = 1 \forall n$ και $\mathbf{w}(0) = 0$, δοθέντος ότι υπάρχει μια λύση \mathbf{w}_o , ο κανόνας για την προσαρμογή των βαρών του perceptron, πρέπει να τελειώσει το πολύ σε n_{\max} επαναλήψεις.

- Από τις (11), (20) και (21) είναι προφανές ότι δεν υπάρχει μια μοναδική λύση για \mathbf{w}_o ή n_{\max} .

Ορισμός του fixed - increment convergence theorem, για το perceptron ενός επιπέδου (Rosenblatt, 1962):

Εστω ότι τα υποσύνολα X_1 και X_2 , του εκπαιδευτικού συνόλου X , είναι γραμμικά διαχωριζόμενα και έστω ότι οι είσοδοι που παρουσιάζονται στο απλό perceptron προέρχονται από αυτά τα δύο υποσύνολα. Τότε, το perceptron συγκλίνει μετά από μερικές επαναλήψεις n_o , με την έννοια ότι:

$$\mathbf{w}(n_o) = \mathbf{w}(n_o + 1) = \mathbf{w}(n_o + 2) = \dots$$

είναι ένα διάνυσμα λύσης για $n_o \leq n_{\max}$

- Θεωρούμε στη συνέχεια τη διαδικασία απόλυτης διάρθρωσης λάθους για την προσαρμογή ενός απλού perceptron, για το οποίο το $\eta(n)$ είναι μεταβλητό.

- Εστω ότι $\eta(n)$ είναι ο μικρότερος ακέραιος για τον οποίο:

$$\eta(n) \mathbf{x}^T(n) \mathbf{x}(n) > |\mathbf{w}^T(n) \mathbf{x}(n)|$$

- Σε αυτή τη διαδικασία, βρίσκουμε ότι αν το εσωτερικό γινόμενο $\mathbf{w}^T(n) \mathbf{x}(n)$ στην n -στή επανάληψη έχει λάθος πρόσημο, τότε το $\mathbf{w}^T(n+1) \mathbf{x}(n)$ στην επανάληψη $n + 1$ θα είχε το σωστό πρόσημο.

- Αυτό σημαίνει ότι αν το $\mathbf{w}^T(n) \mathbf{x}(n)$ έχει λάθος πρόσημο, πρέπει να τροποποιήσουμε την εκπαιδευτική ακολουθία στη $n + 1$ επανάληψη θέτοντας $\mathbf{x}(n+1) = \mathbf{x}(n)$.

- Με άλλα λόγια, κάθε πρότυπο παρουσιάζεται επαναληπτικά στο perceptron, μέχρι να ταξινομηθεί σωστά.

- Σημειώνουμε επίσης ότι η χρήση της αρχικής τιμής $\mathbf{w}(0) \neq 0$, σπανίως έχει σαν αποτέλεσμα την αύξηση ή ελάττωση του αριθμού των επαναλήψεων που απαιτούνται για σύγκλιση, εξαρτώμενο από το πως το $\mathbf{w}(0)$ συνδέεται προς τη λύση \mathbf{w}_* .

3.3 ΑΝΑΚΕΦΑΛΑΙΩΣΗ

- Στον πίνακα 1, παρουσιάζεται η ανακεφαλαίωση του αλγόριθμου σύγκλισης του perceptron (Lippman, 1987).

- Το σύμβολο $\text{sgn}(\cdot)$, που χρησιμοποιείται στο βήμα 3 του πίνακα, για τον υπολογισμό της πραγματικής απόκρισης του perceptron, παριστάνει την συνάρτηση προσίμου:

$$\text{sgn}(v) = \begin{cases} +1 & \text{αν } v > 0 \\ -1 & \text{αν } v < 0 \end{cases} \quad (22)$$

ΠΙΝΑΚΑΣ 1: Αλγόριθμος Σύγκλισης του Perceptron

Μεταβλητές και Παράμετροι

$\mathbf{x}(n)$ = $(p + 1) \times 1$ input vector

$$[-1, x_1(n), x_2(n), \dots, x_p(n)]^T$$

$\mathbf{w}(n)$ = $(p + 1) \times 1$ weight vector

$$[\theta(n), \mathbf{w}_1(n), \mathbf{w}_2(n), \dots, \mathbf{w}_p(n)]^T$$

- $\theta(n)$ = threshold (κατώφλι)
- $y(n)$ = actual response (πραγματική έξοδος)
- $d(n)$ = desired response (επιθυμητή έξοδος)
- η = learning - rate parameter, θετική σταθερά < 1

Step 1: Αρχικοποίηση

Θέσε $w(0) = 0$. Κατόπιν κάνε τους υπολογισμούς για $\eta = 1, 2, \dots$

Step 2: Ενεργοποίηση

Στο χρόνο n , ενεργοποίησε το perceptron εφαρμόζοντας το συνεχές διάνυσμα εισόδου $x(n)$ και το $d(n)$.

Step 3: Υπολογισμός πραγματικής Απόκρισης

Υπολόγισε την πραγματική απόκριση του perceptron:

$$y(n) = \text{sgn} [w^T(n) x(n)]$$

Step 4: Προσαρμογή διανύσματος βαρών

Προσάρμοσε τα βάρη του perceptron:

$$w(n+1) = w(n) + \eta [d(n) - y(n)] x(n) \text{ (E.C.L. rule)}$$

όπου:

$$d(n) = \begin{cases} +1, & \text{αν } x(n) \text{ ανήκει στην κλάση } I_1 \\ -1 & , \text{αν } x(n) \text{ ανήκει στην κλάση } I_2 \end{cases}$$

Step 5: Αύξησε το χρόνο η κατά μια μονάδα και πήγαινε στο βήμα 2.

Παρατήρηση: Για το n ισχύει: $0 < \eta \leq 1$. Για να δώσουμε τιμές μέσα σε αυτό το διάστημα, πρέπει να θυμόμαστε δύο απαιτήσεις (Lippman), που είναι conflict (συγκρουόμενες):

- Να παίρνουμε μέσες τιμές των περασμένων εισόδων για να επιτύχουμε ευσταθείς εκτιμήσεις των βαρών, που απαιτεί μικρό η .
- Γρήγορη προσαρμογή σε σχέση με τις πραγματικές αλλαγές στις υποκείμενες κατανομές της διαδικασίας που είναι υπεύθυνη για τη δημιουργία του διανύσματος εισόδου x , απαντεί μια μεγάλη τιμή για το η .

3.4 ΜΕΤΡΟ ΑΠΟΔΟΣΗΣ

Είναι προφανές μέτρο απόδοσης θα μπορούσε να είναι η μέση πιθανότητα του λάθους ταξινόμησης, που ορίζεται σαν η μέση πιθανότητα του perceptron να πάρει απόφαση υπέρ μιας κλάσης, όταν το διάνυσμα εισόδου ανήκει σε άλλη κλάση.

- Δυστυχώς, ένα τέτοιο μέτρο απόδοσης, δεν οδηγεί από μόνο του στην αναλυτική παραγωγή του αλγόριθμου.

- Ο Shynk (1990) πρότεινε τη χρήση μιας συνάρτησης απόδοσης, η οποία προσαρμόζεται στη λειτουργία του perceptron, όπως φαίνεται από την:

$$J = -E [\mathbf{e}(n) \mathbf{v}(n)] \quad (26)$$

όπου $\mathbf{e}(n) = \mathbf{d}(n) - \mathbf{y}(n)$ -, το σήμα λάθους

$\mathbf{v}(n) = \eta$ έξοδος του γραμμικού συνδυαστή

- Η στιγμιαία εκτίμηση της συνάρτησης απόδοσης, είναι χρονικά μεταβαλλόμενη συνάρτηση:

$$\hat{\mathbf{J}}(n) = - \mathbf{e}(n) \mathbf{v}(n) = - [\mathbf{d}(n) - \mathbf{y}(n)] \mathbf{v}(n) \quad (27)$$

- Το στιγμιαίο gradient vector ορίζεται σαν:

$$\nabla_{\mathbf{w}} \hat{\mathbf{J}}(n) = \frac{\partial \hat{\mathbf{J}}(n)}{\partial \mathbf{w}(n)} \quad (28)$$

- Αρα, επειδή το $\mathbf{d}(n)$ είναι ανεξάρτητο του $\mathbf{w}(n)$ και το γεγονός ότι η πραγματική έξοδος $\mathbf{y}(n)$ έχει μια σταθερή τιμή ± 1 , από τις (27) και (22) \Rightarrow

$$\nabla_{\mathbf{w}} \hat{\mathbf{J}}(n) = - [\mathbf{d}(n) - \mathbf{y}(n)] \frac{\partial \mathbf{v}(n)}{\partial \mathbf{w}(n)} \quad (29)$$

$$\text{Από την (5): } \mathbf{v}(n) = \mathbf{w}^T(n) \mathbf{x}(n) \Rightarrow \frac{\partial \mathbf{v}(n)}{\partial \mathbf{w}(n)} = \mathbf{x}(n) \quad (30)$$

Εξ ορισμού είναι:

$$\mathbf{v} = \mathbf{w}^T \mathbf{x} = \sum_{i=1}^p w_i x_i \Rightarrow \frac{\partial \mathbf{v}}{\partial \mathbf{w}} = \begin{bmatrix} \partial \mathbf{v} / \partial w_1 \\ \partial \mathbf{v} / \partial w_2 \\ \vdots \\ \partial \mathbf{v} / \partial w_p \end{bmatrix}$$

$$\text{αλλά } \frac{\partial \upsilon}{\partial w_i} = x_i \quad \text{για } i = 1, 2, \dots, p$$

$$\text{άρα: } \frac{\partial \upsilon}{\partial \mathbf{w}} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix} = \mathbf{x}$$

Αντικαθιστώντας την (30) στην (29) έχουμε το αποτέλεσμα:

$$\nabla_{\mathbf{w}} \hat{\mathbf{J}}(\mathbf{n}) = - [\mathbf{d}(\mathbf{n}) - \mathbf{y}(\mathbf{n})] \mathbf{x}(\mathbf{n}) \quad (31)$$

Άρα, σύμφωνα με το E.C.L. rule, μπορούμε να εκφράσουμε την αλλαγή, που εφαρμόζεται στο διάνυσμα βαρών σαν:

$$\Delta \mathbf{w}(\mathbf{n}) = -\eta \nabla_{\mathbf{w}} \hat{\mathbf{J}}(\mathbf{n}) = -\eta [\mathbf{d}(\mathbf{n}) - \mathbf{y}(\mathbf{n})] \mathbf{x}(\mathbf{n}) \quad (32)$$

όπου η είναι η learning - rate parameter.

- Αυτό είναι ακριβώς η διόρθωση που έγινε στο διάνυσμα βαρών, καθώς προχωρούμε από την επανάληψη n στην $n + 1$, όπως περιγράφεται από την εξίσωση (25).

Αποδείξαμε λοιπόν ότι η στιγμιαία εκτίμηση της συνάρτησης απόδοσης $\hat{\mathbf{J}}(\mathbf{n})$, όπως ορίζεται από την (27), είναι πράγματι το σωστό μέτρο απόδοσης για ένα perceptron ενός επιπέδου.