


נוירו-חילוםים

שקופית 3:



(*) התכנית הנה בא שקובעת מה יהיה הפלט.

(*) מה היבון של תוכנית שרתק ה-CPU (קבוצה בנימון)?

~~שקופית 3: שניו תתק כפי כורה -~~

שקופית 4:

(*) מה ההבדל בין מה שהמוח עושה לבין מה שתוכנית עושה?

כשעשים טעות בתוכנת ~~שקופית 4~~ ניתן למצוא בקומפילציה אולם כשהמוח מתקט ~~שקופית 4~~ התוכנית

אינה "שפירה", fault tolerant, האלמנט של המוח שמעבד שינה מהאלמנט של

תוכנית שמחשבת כיוון שהמוח יכול לעמוד מוגזמות.

בזמנא- הנכנסת סובגט לכמה רק אם הוא כבר שישם שכל

(*) שים מנצמחה עם מנצול על הפת שים סובגט רורה לריכס המנצמחה

מנצמחה את הסובגט נעשה סריקה אל פני הסובגט ולא התכנה שלו האם

שישם ואם כן הפת נפתחה.

תוכנית תמיד תפוצ את הסריקה הנע אולם מוח יכול לעבד הכלה ולתאר

מה פלגים כבר עומד ואינו מבצע את הסריקה הנע.

שקופית 5:

(*) המוח עובד לפי מיליארדים של אלמנטים (גם, ניוונים, בינאמיה וכו'...)

(*) אנו נסתב על עזבים - כמה זמן אוקח לעזב: 10^{-3} עזבים

מתשבים עובדים בסדר זרנ יותר מהיר: 10^{-9} (ז'פים)

(*) אולם המוח עובד יותר ביציאות

שקופית 6:

(*) המוח יותר טוב מבחינת חושים, הכשלות, fault tolerant

שקופית 7:

(*) בנה מנצמחה מקבילת עכסיכולוגיה קונטריבית - תכונות של המוח

חילוםים ניוונים מקבילת ניוופסיכולוגיה

סקופ 8:

(*) במהו אין רק נירונים אלא גם קשרים ביניהם (בצדק 10^{16} קשרים)
 ← טמור ימנה קיבולת יננה טביות צדוה יותר מחסב: אם מסתבים א
 הקשרים. השאלה - מה יוסב א הקשרים?

סקופ 10:

(*) ינו אהיות שהקשרים אינם משמעותיים
 (*) אם נסתכל א סרטן אין א הרבה עצבים והם מבצעים פאזוז - נאן: מציאת אור, מציאת בית וכו' וכן ינו אהיות א צריק ס-כך הרבה עצבים.

סקופ 11:

משנות ה-50, עצבים יש תאים נפרדים (א יחטי) בנוסף אלו יש Spikes (מחטי)
 א יש אדם א אין (0 או 1) - שולח א - Spike א א שולח אמת.
 אxon א עצב מקבא dendries א עצבים אחרים.

הם ביצא הפסטה - dendries שהם וקטור א אינפורמציה א ישנם משקלים
 שמקצים אור ודמא מבצא קומבינציה אינארית: $\sum_{i=1}^n w_i x_i$ אס יוצאים Spikes
 אם זה עובר אשמו סף.

סקופ 12:

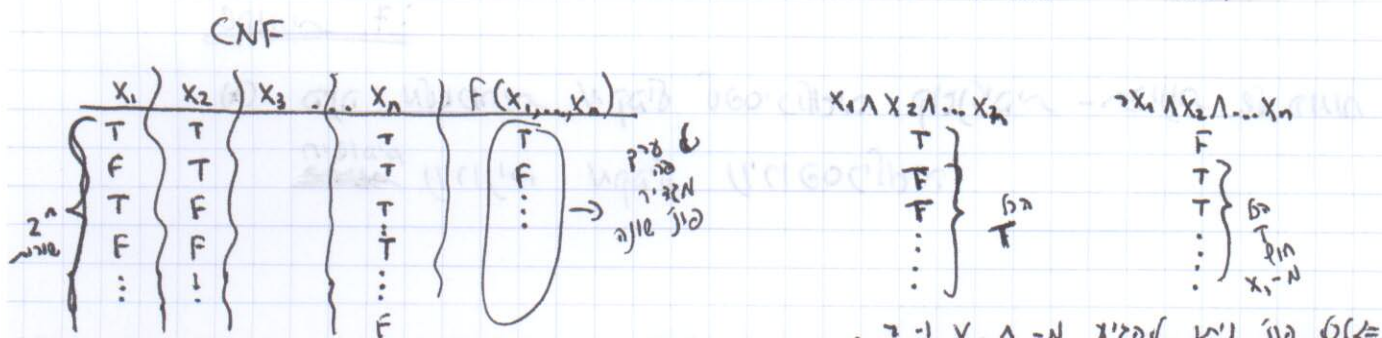
בצבם זה מגזיר פונקציה בוליאנית אבא השאלה היא אזה פונ' בוליאנית?
 אם משנים את ה-w אזי נקבא פונ' בוליאנית אחרת (זם אר הול' נימן
 דמג)

(*) נשים א שהאמנט א כמן אינו מופיע במוב

סקופ 13:

נימן מהצב ר פונ' בוליאנית, כיוון שנין אהצים בעורה נורמטיבית
 המקום המשקלים הם שצדים - and, or, not.

and - איחוב של א שצדים: 1 : סף: 1.5
 NOT - שצדים: -1 : סף: 0.5



שקופית 20:

לרשת נייטרונים יש כוח אולם כיצד ניתן להשתמש בה?

אנו רוצים רשת פשוטה שיהיה קלה לתפעול, כלומר רשת בעלת חוקים נמוכים

(כלים) יוניפורמים לקביעת המשקלים

שקופית 21:

(*) רשת עם נייטרון אחד: האם ניתן לייצג כל פונקציה בוליאנית? נייטרון אחד?

(*) השאלות שמעניינות: מה הכוח של נייטרון אחד?

האם יש שיטה אוטומטית למצוא פונקציה בוליאנית?

כוח (מה ניתן להפיק) | שיטת עיבוד (אלגוריתם)

?

כל פונקציה בוליאנית

3-level NNs


?

?

נייטרון אחד

→ נענה היום.
(perceptron)

שקופית 22:



שיטה אנטיסימטרית למציאת המשקלים: \vec{w}, θ

(אם בוליאנית) $\mathcal{F} = \mathcal{F}^+ \cup \mathcal{F}^-$

עם $\vec{x} \in \mathcal{F}^+$ (בוליאנית חיובית) } עם $\vec{x} \in \mathcal{F}^-$ (בוליאנית שלילית)

$(\sum_{i=1}^n w_i x_i = \vec{w} \cdot \vec{x} > \theta)$ } $\vec{w} \cdot \vec{x} < \theta$

עומד - אם נכון הנחזיר אחרת נתקן את בוליאנית.

היתכנות - כאשר ניקח את כל הבוליאניות ולא נצטרך לבצע חישובי אקס


שקופית 29:

בהיכ: $\theta = 0$ (נבין את ה-x במינז אחד יותר גדול). (למעשה הוא 1)

$\sum w_i x_i > \theta \Leftrightarrow \sum_{i=1}^n w_i x_i - \theta > 0 \Leftrightarrow \sum_{i=1}^{n-1} w_i x_i > 0$

$\vec{x} = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \rightarrow \vec{\hat{x}} = \begin{pmatrix} x_1 \\ \vdots \\ x_n \\ 1 \end{pmatrix}$

$\sum_{i=1}^n w_i x_i + w_{n+1} x_{n+1} > 0$
 $\downarrow \quad \downarrow$
 $\quad \quad -\theta \cdot 1$



	x_1	x_2	And	x_3
\mathcal{F}^+	1	1	1	1
\mathcal{F}^-	1	0	0	1
	0	1	0	1
	0	0	0	1

→ כל שורה הנמצא היא כוח

קיים \vec{v} כך ש:

$$\vec{v} \cdot \vec{x} > 0 \quad x \in \mathcal{F}^+$$

$$\vec{v} \cdot \vec{x} < 0 \quad x \in \mathcal{F}^-$$

צריך למצוא \vec{w} כזה, כיצד?

$$x \in \mathcal{F}^- \Leftrightarrow -x \in \mathcal{F}^+$$

$$\mathcal{F} = \mathcal{F}^+ \cup \mathcal{F}^-$$

$$\sum w_i x_i < 0 \Leftrightarrow \sum w_i (-x_i) > 0$$

בהיבט: ניתן למצוא את הוקטורים

$$\vec{x} \in \mathcal{F}^+ \text{ אם } \vec{w} \cdot \vec{x} > 0$$


$$w \cdot \frac{\vec{x}}{\|\vec{x}\|} > 0 \quad \text{נמצא } \vec{w} \text{ כך ש: } \|\vec{x}\|=1 \quad \vec{x} \in \mathcal{F}^+$$

(*) אנו רוצים למצוא את הוקטורים שיכנסו בזמן סופי לפיתרון

להמסכת אומר שקיים כזה. (סקופית 26)

$$0 \neq \vec{w} \cdot \vec{x} \text{ מניין שהזווית זווית } 90^\circ$$

$$\vec{w} + \vec{x}$$



אלה יכילו את הוקטור שה- w החדש מקבלת לבחור

אחרת ולכן יש שוק לקצו בדיוק זה שמציעים $v = w$ (באומר w שזה באמת ניתן


לפיתרון נכון).

צו: שאם מצאים שהתכנסות הנ"ל ($w=v$)

סקופית 30:

נוסיף שקיים v^* כזה שהוא רחוק מ- \mathcal{F} (המינימום של \mathcal{F})

$$v^* \cdot x > \epsilon > 0 \quad \text{אם } x \in \mathcal{F}$$



באומר, הוקטורים לא צריכים רק את סופי של

פלאנים.

סקופית 35:

$$\frac{v^* \cdot w}{\|w\|} \leq 1 \rightarrow$$

אם v^* מניין ≤ 1 כזה: $\cos \leq 1$

$$\|v^*\|=1$$

הצרה:
ניתן לבחור $w = w$

נראה מה קורה עם w ומה קורה עם x ומה קורה עם $w+x$ ומה קורה עם $w-x$

$$\textcircled{I} \vec{w}_{n+1} = \vec{w}_n + x$$

אחר מומה קטן של פלאנים.

$$\textcircled{I} v^* \cdot w_{n+1} = v^* \cdot w_n + v^* \cdot x > v^* \cdot w_n + \epsilon$$

$$\textcircled{II} \|w_n\|^2 = (w_{n+1}) \cdot (w_{n+1}) = (w_n + x) \cdot (w_n + x)$$

$$\Rightarrow v^* \cdot w_n \geq n \epsilon \quad (\rightarrow \text{Fix: } \text{אם } v^* \text{ קטן של } \mathcal{F} \text{ אז } v^* \cdot x > \epsilon)$$

$$= w_n \cdot w_n + 2w_n \cdot x + x \cdot x$$

נוירו-חישוביים

(*) ערכת את הנוירון זה עבור את המסקים (והסל)

שקופת 31:

X_1	X_2	X_3	And
0	0	1	0
0	1	1	0
1	0	1	0
1	1	1	1

(*) ביצאת עבור AND :

⊗ תוספת ההרכבה אינה

משפחה עם התוצאה

תשובה רגילה →

⊗ באלגוריתם perceptron נעזרים לקבלת זכר x_i אם מספר התוצאה לא נעזרת תוצאה רגילה שלם את המסק.

one in a time : אם משלים כל פעם w אחד
Batch : אם משלים עבור כל w

(*) ביצאת נוספת :

כל משנה את התוצאה

	X_1	X_2	X_3	And
(1)	0	0	1	0
(2)	1	0	1	0
(3)	0	1	1	0
(4)	1	1	1	0
(5)	0	0	1	1
(6)	1	0	1	1
(7)	0	1	1	0
(8)	1	1	1	0
(9)	0	0	1	0
(10)	1	0	1	1
(11)	0	1	1	1
(12)	1	1	1	0

⇒ $w_1 X_1 + w_2 X_2 + w_3 X_3 = 0$
 $w_i = 0$ כזה
 $\vec{w} = w + X \Rightarrow w^{new} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} + \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} \Rightarrow w_i = 1$

⇒ $w_1^{new} X_1 + w_2^{new} X_2 + w_3^{new} X_3 =$
 (5) $0 \cdot 0 + 0 \cdot 0 + 0 \cdot 1 = 0 \rightarrow$ לא נכון
 $w^{new} = w - X = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} - \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}$
 (6) $1 \cdot 1 + 1 \cdot 0 + 0 \cdot 1 = 1 \rightarrow$ לא נכון
 $\vec{w} = w - X = \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix} - \begin{pmatrix} 1 \\ 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 0 \\ 1 \\ -1 \end{pmatrix}$
 (7) $0 \cdot 0 + 1 \cdot 1 + (-1) \cdot 1 = 0$
 (8) $0 \cdot 1 + 1 \cdot 1 + (-1) \cdot 1 = 0 \rightarrow$ לא נכון
 $\vec{w} = w + X = \begin{pmatrix} 0 \\ 1 \\ -1 \end{pmatrix} + \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix}$

ביקור:
 $\vec{w}^{new} = \vec{w}^{old} + X$
 $\vec{w}^{new} = \vec{w}^{old} - X$


ומשנים עד שהם נותן תוצאה נכונה ולכן הם המסקים
 אם יש מהו שניתן להפרידה ליניארית האלמנטים מתכנס.

בחירת משקל
 משפחה רי
 הנוירון להיות
 not, or, and



(*) ביצאת :

נניח שאנו רוצים עסקות מצרפה רמנות (האם סבתא בתמונה)



השלמה: כמה features - higher features - כרוך לדיק למצוא את ה- w_i ?

שאלה:

קמור



לא קמור



קמור



לא קמור





כוכבים זראות האם הבורה קמורה

קמורה

- " -

ניקה מה זאפים ונקבוק האם הם קטרים או לא.



$\sum w_i x_i \leq 0$ $\sum w_i x_i > 0$ $\sum w_i x_i < 0$ $\sum w_i x_i > 0$ \Rightarrow ב זאפים קטרים ו-2 לא

↓

$\sum_L w_i x_i + \sum_M w_i x_i + \sum_R w_i x_i \leq 0$

$LHS^1 + RHS^1 < c$

$LHS^2 + RHS^2 > c$

$LHS^3 + RHS^3 < c$

$LHS^4 + RHS^4 > c$

$LHS^1 = LHS^2$

$RHS^1 = RHS^4$

$RHS^2 = RHS^3$

$LHS^3 = LHS^4$

\Rightarrow


יש סתירה ואכן לא ניתן לפתור

כאומר, אין מפרק perceptron שפותר את הבעיה.

נקבוק קמירות.


להיות קמור = 3 נקודות באותה שורה ומיוד בתוך הזוו.

נבנה מכונה הבורה הבאה:



אם רק עבור הקואסינציה הזאת נקטס 0 אחת 1.

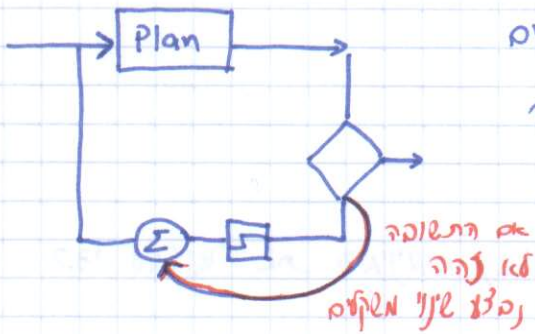
נשים סנסור כזה על 3 נקודות:



מחפשים דוגמא נצדית + כאומר, שני נקודות בתוך הזוו ונקודה אחרת

לא בתוך הזוו.

יש מכשיר שאנו רוצים לעצור מה הוא עושה




אנו עוקחים את ה-input וכווננים
האם המכשיר שלנו מוציא את אותה
התוצאה כמו ה-plan
אם לא אז חוזרים ומשנים
את ערכי ה-w

Adaline

אלמנטים נוסף.

אם עוקחים פונקציות סינאיות שהיא פונקציה של פונקציות סינאיות ונסתכל בחלק
של נירון:



נבדוק את הרשימה:

$$\langle \vec{x}^{(1)} d^{(1)} \rangle \leftarrow \text{התשובה הרלויה}$$

$$\langle \vec{x}^{(2)} d^{(2)} \rangle$$

⋮

$$\langle \vec{x}^{(m)} d^{(m)} \rangle$$

יש לנו את ה- \vec{w} המתחמתי ונראה כמה קומבינציות סינאיות נותנות
את התוצאה הרלויה.

$$E(\vec{w}) = \sum_{j=1}^n (\sum_i w_i x_i^{(j)} - d^{(j)})^2 \leftarrow \text{הטעות}$$

רוצים לעצור את המינימום (ע"י גזירה)

⊗ מכיון שזה הביולוגי אזי צוהי פרהמורה ואכן יש מינימום אחד

x_1	x_2	x_3	AND
0	0	1	-1
1	0	1	-1
0	1	1	-1
1	1	1	1

$$E(w) = (w_1 \cdot 0 + w_2 \cdot 0 + w_3 \cdot 1 - (-1))^2 + (w_1 \cdot 1 + w_2 \cdot 0 + w_3 \cdot 1 - (-1))^2 + (w_1 \cdot 0 + w_2 \cdot 1 + w_3 \cdot 1 - (-1))^2 + (w_1 \cdot 1 + w_2 \cdot 1 + w_3 \cdot 1 - 1)^2 =$$

נצטרך גם חלק בנפרד:

$$\frac{\partial E}{\partial w_i} = 2(w_1 \cdot 0 + w_2 \cdot 0 + w_3 \cdot 1 + 1) + 2(\dots) + 2(\dots) + 2(\dots)$$

$$\frac{\partial E}{\partial w_1} = \sum_{j=1}^n 2 \left(\sum_{i=1}^n w_i x_i^{(j)} - d^{(j)} \right) x_1$$

$$\frac{\partial E}{\partial w_2} = \sum_{j=1}^n 2 \left(\sum_{i=1}^n w_i x_i^{(j)} - d^{(j)} \right) x_2$$

⋮

כדי למצוא את המינימום נשווה הנגזרות ל-0 ונקבל ח שוויונות n -ה (משוואות)


$$\frac{\partial E}{\partial w_1} = 0 \quad \dots \quad \frac{\partial E}{\partial w_n} = 0$$

ניתן לרשום את זה כק: $M\vec{w} = \vec{q}$

$\vec{w} = M^{-1}\vec{q}$ + קשה למצוא את M^{-1} (עולה הרבה פעולה לחשב)

אך ניתן לפתור בעזרת הפוק מטרייה?

שיטת LMS



נחזים ב- w אקראי ונבדוק את התוצאות (משק)

ונאם בניולן של הירידה, נאמר, נשנה את ה- w :

בקצת ונבדוק שנית.

$$\vec{w}^{new} = \vec{w}^{old} - \alpha \nabla_w E(\vec{w})$$

← זרנוצ'ני

$\alpha =$ גודל הצעד

6/6/08

נירו - חישוביים

שביח יוסף ארבל

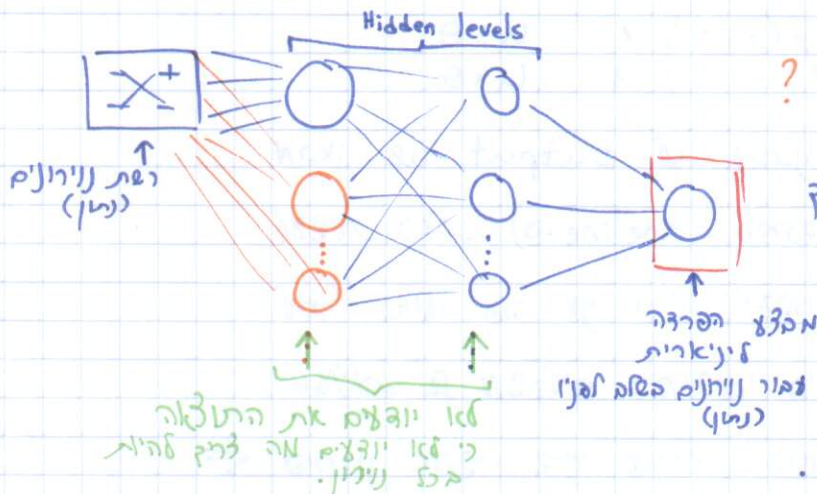
(*) עבור XOR ה-Adeline היתה התכנסות עצומה perceptron ~~מזה~~ כדי אינסוף.

(*) התנגדו לבדק:

- התכנסות

Test set vs. Training set-

נשים אם - התכנסו על צברים אשר ניתנים להפרדה ליניארית ואילו מחפשים אלה אשר מסתבכים על רשת של נייטרונים (ולו נייטרון אחד)


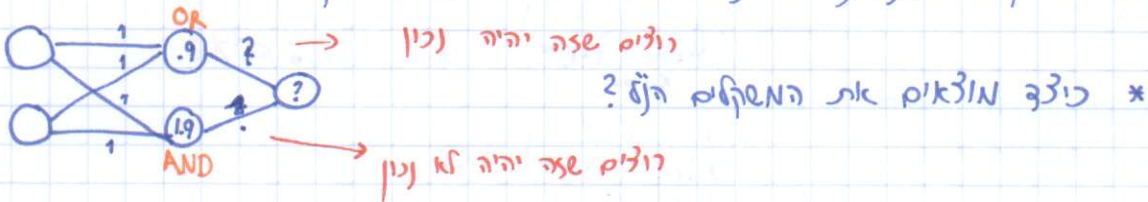


* מה אם יש לנו כמה?

* בעזרת ניתן להסתכל על כך כביצוע טרנספורמציה על הנתונים.

זהו בעצם feed forward.

השאלה - איך ייתן לנו תוצאה של רשת? נשים אם שבטוח אנו יודעים את התוצאה הארכיטקטורה נתונה ואנו מחפשים את המסקנים.



בעזרת ניתן לתרגם:

נשים אם שב- perceptron לא ניתן לבצע הכללה לכמה רמות אך ה- Adeline ק.

נמצא אלגוריתם אשר ייתן לנו את המסקנים:

$\langle \vec{x}, \vec{y} \rangle \leftarrow$ אסוף ביטוי

יש לנו Training Set

⊕ כיוון שיש להיות שניה אסוף

קטנה (t/p)

אם יש משהו


$Error(\vec{y}) = \frac{1}{2} \sum_{k \in \text{training examples}} (t_k - y_k)^2$

$t_k = \text{training Example}$

$y_k = \text{Net Output } (\vec{x}_k)$

- ג- Adeline היה פשוט כי היה נורוון אהב אתן משקל אחר.
 כאן ישנם משהו נורוונים ומשקל כאן לא ברור מהיכן משיעה הטעלת.
 ⇐ נמצא את המשקל של E, נאמור, נמצא נעזרת עשאי כש ה-w
 ולקחת את הוקטורים ומצוא את הכיוון ולעברת עם-פיו.

$$\nabla_{\text{משקלים}} E() \rightarrow \left(\frac{\partial E}{\partial w}, \dots \right)$$



- את נסתכל על:


$$\text{Output } J = f\left(\sum x_i v_{ij}\right)$$

$$f(u) = \begin{cases} 1 & u \geq \theta \\ -1 & u < \theta \end{cases}$$

← לא ניתנת לעצירה

מכאן שה-output לא ניתנת לעצירה ולכן אנו לא יכולים
 לעשות זאת (ג- Adeline הסתכלו על "השק מהסכום" היצאו ואחר בקנה
 מספר ואילו פה אנו יכולים לעשות זאת רק בסוף ← לא נוכל למצוא
 טעליות של משקלים בהישובי ביניים).

⇐ פיתרון אפשרי שינוי פונקציית הסף שבנוי של ניתנת לעצירה



$$f(x) = \frac{1}{1+e^{-x}}$$

לצד:

$$\lim_{x \rightarrow \infty} \left(\frac{1}{1+e^{-x}} \right) = 1$$

בעצם:

$$\lim_{x \rightarrow -\infty} \left(\frac{1}{1+e^{-x}} \right) = 0$$

Approximate for $\epsilon \rightarrow$
Binary


for bipolar

$$\leftarrow g(x) = 2f(x) - 1 = \frac{2}{1+e^{-x}} - 1 = \frac{2-1-e^{-x}}{1+e^{-x}} = \frac{1-e^{-x}}{1+e^{-x}}$$

$$\lim_{x \rightarrow \infty} \left(\frac{2}{1+e^{-x}} - 1 \right) = 1$$

$$\lim_{x \rightarrow -\infty} (g(x)) = -1$$

Bipolar Sigmoid
arctanh
(hyperbolic tangens)



$$h(x) = \text{arctan } x$$

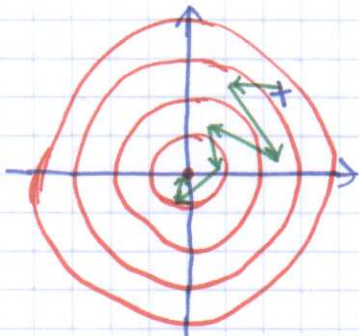
* מכיון שאנו דוקמים נעזרת נצטרך לקחת נעזרת של הפונק, עבור f(x) ניקח:

$$f'(x) = \frac{1}{(1+e^{-x})^2} (e^{-x}) = \frac{e^{-x}}{(1+e^{-x})^2} = \left(\frac{1}{1+e^{-x}} \right) \left(\frac{e^{-x}}{1+e^{-x}} \right) = f(x)(1-f(x))$$

אלגוריתם Back Propagation

$$E_{\text{error}}(\vec{w}) = \frac{1}{2} \sum_{\text{dimension}} (t_k^d - y_k^d)^2$$

Adeline - כיצד? *



Adeline

* - המיקום שהיינו

← - כיצד תקין

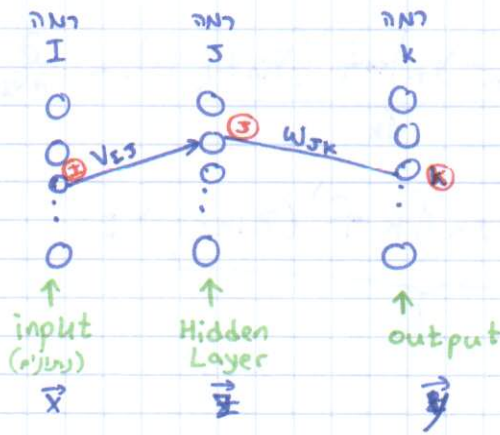
• - נקודה רלוויה

התקין התפלג - batch

Back Propagation - כיצד "אנו צבר" רק את המיקון נכנס *

One at a time

\vec{z} - המצב של הניורונים באמצע.



$$y_k = f\left(\sum \omega_{jk} z_j\right)$$

↑ הפונקציה
↑ מה נכנס
↑ y-f

$$z_j = f\left(\sum v_{ij} x_i\right)$$


↑ מה נכנס
↑ x-f

* הן-ן נוסיף ניוון שמתוכם 1 והמקום שלו הוא פונקציה של הן-ן ושל הן-ן. למחר, כותב הפונקציה נמצא הן-ן.

$$E = \frac{1}{2} \sum_k (t_k - y_k)^2$$

→ אנו מנסים להמיר

$$\frac{\partial E}{\partial \omega_{jk}} = \left[\sum_k (t_k - f(y_{ink})) \right] \cdot \frac{\partial}{\partial \omega_{jk}} (t_k - f(y_{ink}))$$



$$= f'(y_{ink}) \frac{\partial}{\partial \omega_{jk}} y_{ink}$$

↑ הפונקציה
↑ מה נכנס
↑ y-f

$$= f'(y_{ink}) z_j$$

$$E = \frac{1}{2} \sum_k (t_k - f(y_{ink}))^2$$

אנו מנסים להמיר את המיקום של הן-ן ושל הן-ן. למחר, כותב הפונקציה נמצא הן-ן.

$$\frac{\partial E}{\partial \omega_{jk}} = [t_k - f(y_{ink})] \cdot f'(y_{ink}) \frac{\partial}{\partial \omega_{jk}} y_{ink}$$

$$= [t_k - f(y_{ink})] \cdot f'(y_{ink}) \cdot z_j$$

↑ הפונקציה
↑ מה נכנס
↑ y-f

$$= \delta_k z_j$$

* בעולם האלגוריתם הן-ן צומח
Adeline - כיצד? *

$$\frac{\partial E}{\partial V_{Ij}} = \left(\frac{1}{2} \left(\sum_k (t_k - y_k)^2 \right) \right)$$

$$E = \frac{1}{2}$$

$$= \sum_k (t_k - y_k) \frac{\partial}{\partial V_{Ij}} (t_k - f(y_{ink}))$$

$$= \sum_k (t_k - y_k) \cdot -f'(y_{ink}) \cdot \frac{\partial}{\partial V_{Ij}} y_{ink}$$

$$= \sum_k (t_k - y_k) \cdot f'(y_{ink}) \cdot \frac{\partial}{\partial V_{Ij}} \sum_j z_j \omega_{jk}$$

z_j נכנסת כי הארזות ω_{jk} \rightarrow V_{Ij}

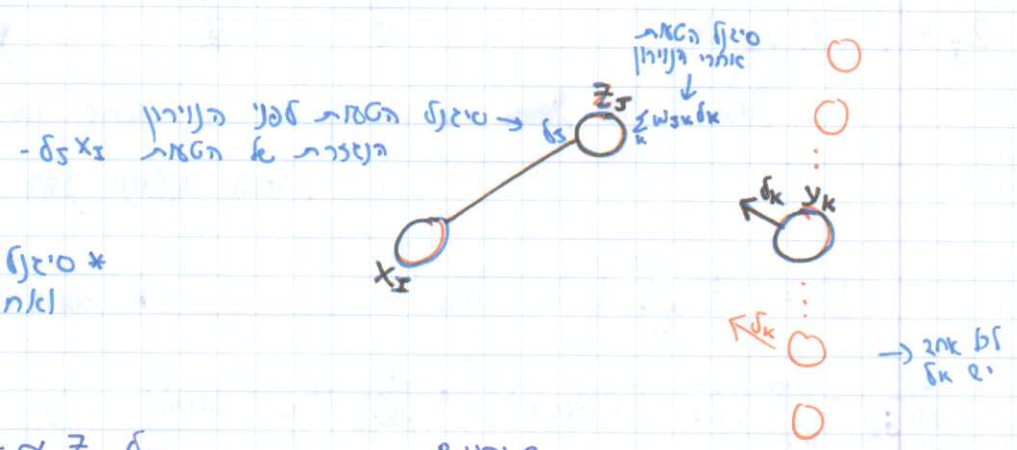
$$= \sum_k (t_k - y_k) \cdot f'(y_{ink}) \cdot \omega_{jk} \frac{\partial}{\partial V_{Ij}} z_j$$

$$= \sum_k \underbrace{(t_k - y_k)}_{\delta_k} \cdot f'(y_{ink}) \cdot \omega_{jk} \frac{\partial}{\partial V_{Ij}} f(z_{inj}) \quad f(z_{inj}) = \sum_j \omega_{ij} X_j$$

$$= \sum_k \omega_{jk} \delta_k f'(z_{inj}) X_j$$

δ_j

$$= \delta_j X_j$$



* סימן ה-AVG לפני הנירן אחר הנירן.

$$w_{jk}^{new} = w_{jk}^{old} + \alpha z_j \delta_k$$

$$V_{Ij}^{new} = V_{Ij}^{old} + \alpha X_j \delta_j$$

תיקון :

בגזם אחרי שמתקנים את משל מתקנים את V_{Ij} האדואריותם :

רבים בהתחלה קצתה (אחר שנותנים מקום התחלתי) Output. מוצאים את לשורת השגיאה ומחברים שגיאה אחרת אל מרכזים אחרים התחלתיים ואזר חלוקה.

(*) \rightarrow batch סוכמים את δ \rightarrow δ_k

One at a time \rightarrow צריך לשים את המשלים בה של V_{Ij} קודם

יש w_{jk} .

האלמנטים

- Apply \vec{x} to input unit
- Calculate for 1st hidden level

$$\begin{aligned} (x_1, \dots, x_n) \\ (x_i \in \{1\}) \end{aligned}$$

$$net_j = \sum_{i=1}^n w_{ji} x_i$$

- Calculate output for 1st hidden level

$$O_j = f_j (net_j)$$

- Calculate for 2nd hidden level

$$net_j^{(2)} = \sum_{i=1}^{1^{st} \text{ level}} w_{ji}^{(2)} O_i$$

- Calculate output for 2nd level


$$O_j' = f_j' (net_j^{(2)})$$

נהגו
שקפו
לה
move
forward

המשקל
המשקל

δ_j is $\begin{cases} (O_j - t_j) f'(y_j) = \text{for Output} \\ (\sum_k \delta_k w_{kj}) f'(net_j) \end{cases}$

קבלו זה
נתם
Back E'
processed
one at a time



אנו רוצים להימנע ממ'ינימום מקומי

ולכן משתמשים ב-Bipolar Representation

אם נימצא בזמן של הפונקציה הסימטרית ייקרה הרבה זמן

אם נבחר את הפונקציה הסימטרית של פסגה נימנע מה'ינימום מקומי'.

one at a time יש יתרון של batch כי יש בו בעל.

השאלה - כמה דוגמאות צריך?

- מתי צריך לעצור?

ישנם הרבה פרמטרים חופשיים בהמשך (משקלים) ולכן נדרש יותר דוגמאות

of needed examples אנו מחפשים את ה-

אם נרצה שהטעות תהא e (למשל 10%) אסי (Hasler) גודלים שלטו את

$$\frac{e}{2} \text{ TS}$$

→ לדוגמה: יש 80 משקלים ורוצים 10% טעות (אסי שלטו את הרשת 95 נכונה)

$$\frac{\# \text{ of needed examples}}{\# \text{ of free parameters}} = e$$

800 דוגמאות 0.1

Hasler
מא שזרין
שלטו
ויסבוקו

$$\# \text{ of needed examples} = e * \# \text{ of free parameters}$$

BACK - PROPAGATION (One-at-a-Time)

Apply \vec{x} to input units $x = (x_1, \dots, x_n)$ \rightarrow Net input
 (Note: $x_n \equiv 1$?) \rightarrow Output מ'פני k

Calculate for 1st hidden level \rightarrow Output מ'פני k

$$net_j = \sum_{i=1}^n w_{ji} x_i$$

Calculate Output for 1st hidden level

$$O_j = f_j(net_j)$$

(note: f can depend on j !)

Calculate for 2nd hidden level

$$net_{j'} = \sum_{j=1}^n w_{j'j} O_j$$

Calculate Output for 2nd level

$$O_{j'} = f_{j'}(net_{j'})$$

etc for more levels

input מ'פני k \rightarrow output k

Calculate Output $O_k = f_k(net_k)$ \rightarrow Output מ'פני k

Calculate Error for Output

$$\delta_k = -(t_k - O_k) f'_k(net_k)$$

Outputs \rightarrow Last \rightarrow Output מ'פני k

Calculate Error for Hidden Level

$$\delta_{j'} = f'_{j'}(net_{j'}) \sum_k \delta_k w_{k j'}$$

Calculate Error for previous Hidden Level



$$\delta_j = f'_j(net_j) \sum_{j'} \delta_{j'} w_{j j'}$$

Change Weights: $w_{kj}(new) = w_{kj}(old) + \eta \delta_k O_j$
 $w_{jj'}(new) = w_{jj'}(old) + \eta \delta_{j'} O_j$


Use $E = \sum_k \sum_j (t_k - O_k)^2$ to decide when to stop

13/6/08

נירן - חישוביים



- * נירן הקלט והפלט
- ~~להקים~~
- * ה'נירן' ה'Hidden Layers'
- יכולים להיות קטנים/שונים/
- זבזבים.



- * אין משתנים בפונ' אשר מאפשרת חיבור
- לכן אין זה חייבים להשתמש בקלט בוליאני
- הפלט יהיה אם $x > 1$ או $x < -1$.

$$F: \{x \mid -1 < x < 1\}^m \rightarrow \{y \mid -1 < y < 1\}^n$$

כל Boolean functions: אפשרות אס' Continuous functions

משפט של Cybenko

ניתן להכליל קירוב 'אניברסלי' של כל פונ' רציפה (לדג כפי קירוב מסויים) ונתונים ϵ וכל נתונים היא תמיד 'אניברסלי' ל ϵ .

(*) מטעם של נירן

$$f(x) = \text{Sigmoid}(x) = \frac{1}{1+e^{-x}}$$

$$f'(x) = f(x)(1-f(x))$$

$$\Rightarrow f(x) = f(\text{net}_x)$$

אם ניתן להשתמש ב-פ.פ.?

- * ארכיטקטורה - איך להרכיב את הקלט והפלט?

כמה רמות של שכבות פתוחות (פזל)?

הם כמה פתוחות כמה נירונים יהיו?

מאצה פונ' יתקבל שימוש

- * קלט סימולי - אם יש יותר מ'ני' משתנים אולי יותר קל?

הפ' קל יותר שזה יהיה טוב אם לא נתונים רבים ולכן הקלט

הסימולי צריך 'שכבות' את כל העלם

* פרמטר אימוץ - כמה קטן/גדול אפשר לשנות את המצבן אימוץ

מיוון שאנו רוצים למצוא במצבן סביב אבי נרצה שיהיה

adaptivity

* משקלים הנתונים - הכי טבעי לאפשר את זה יותר נוחים סימטריים

ואם יש יותר הנתונים סימטריים הוא ישמור לנו

פיתרון נכון - מספרים הנבחרים (השאלה-זכרון/קטנים?)

הוא בסוף מסומן - קטן אבל לא נרצה להיות בסוגר
שכן מצבן האימוץ יהיה ארוך. (נרצה במרכז).

* מומנטום - אם נשנה משקל מסוים באותו כיוון \leftarrow אנו יכולים להטות אותו ונרצה
(\Rightarrow ^{אם צריך} לשנות בצורה וזמן נפתרם על התפרסם בין המשקלים, אם זה באותו כיוון
מצד אחד השני (הוספה של α).

* מינימום מקומי - האלגוריתם הוא ירצה במרכזי אלק וישנה

מלבד (מינימום מקומי) \leftarrow צריך לעצור: הוספת נעם. ^{המספרות עליה} \leftarrow ^{המנין המקומי}


* Adeline לא היתה בליה כפי כי הפסג הוא פירוקה = מינימום אחר

* בזמנאם ארבע ניוונים וסגורה נסגרת לפונקציה XOR

XOR

$\eta = 5$

558 Sweeps



\rightarrow אינדיקטור לא כל כך טוב

$f(\text{net}_k - \theta)$


$\frac{1}{1 + e^{-\sum_{i=1}^n x_i w_i - \theta}}$

סדר ממשם בסידור הקלט הוא $\sum_{i=1}^n w_i x_i$
ואנו רוצים למצוא את נוסף במקום $\frac{1}{1 + e^{-\sum_{i=1}^n x_i w_i - \theta}}$

Local Min

$\eta = .25$

10,587 Sweeps




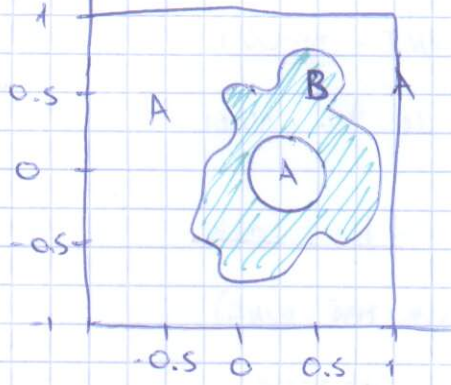
\rightarrow אינדיקטור כל כך טוב

במקרה 1 מתוך 200 ניסיונות נתקלים מינימום מקומי

אמנת הרזיסור: *

ישו קטע ממחצה ב $(n-1-n-1)$
 וזו קטע שניתן נרצה לבצע האם הוא
 A או B.

מסובק מכוון יש A בתוך B ו-A מחוץ.



שום הקטע הוא שני נייורונים
 שקיבלו שם עם שם משלים
 בין 1 -1 -1
 ב רמת נסתרת:

* עם נייורון ברמה אחת קטור
 עם נייורון ברמה הבאה.

ימה נסתרת ראשונה - 8 נייורונים
 ימה נסתרת שנייה - 4 נייורונים
 פלט - נייורון אחד

* היו ניסיונות עם רמה אחת נסתרת שהצליחו.

learning rate = 0.1


$f(x) = \text{Sigmoid}$

data = 500 נתונים
 Balance קטגורי
 (A-N 250 B-N 250)

התבצע קריב יוניסורטי.

* בסכנה הנסתרת השנייה לא התקבלו קיום ישים כמו בסכנה הנסתרת
 הראשונה אלא מתחילים לראות defining Areas ב-1 מסבלות.
 * בסכנה האחרונה (פלט) התקבל זיכרון.

ביצע: נתונים אחרים ורזיסור לבצע Compression שלהם, כיצד?



מחברים את סוג הנחת

ס נייורון קטור עם נייורון בסכנה
 הידועה לו.

(נרצה עם אחרים A-3 באופן 7x9
 המיוצג יצום בנאח)

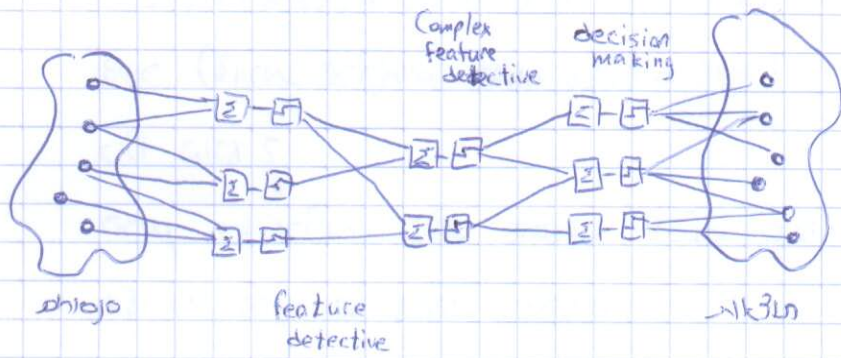
63 נייורונים
 שמיימים את
 מוקטור של
 כל אחד.

רמת נסתרת
 1 עם M קטור N-63
 רמת נסתרת
 2 עם 63 נייורונים
 (שליכה למה)
 סדורת קטור

מכוון שנרצה שימוש עם 1-1 שי
 ישנו טעם שכן Sigmoid בין 1 ו-1
 וזמן לקחו tolerance של 0.1-0.2.

בזמן הרמה הזו הוא מתפרסם של האינפורמציה

נירו - ח'שוק"ם



Early Notion (*) of an Intelligent System Built from trainable Perceptron


ארכיטקטורה קדם

(*) ירידה בקרפאונט:
$$w_{ij}^{new} = w_{ij}^{old} + \alpha \frac{\text{Error}}{\partial w_{ij}}$$

→ מנסה על הישגיו שהיה ומנסה באותו כיוון
$$+ \beta (w_{ij}^{old} - w_{ij}^{old-1})$$
 עם המונטום: (מוסיף עוד 25%)

יקח המון איטרציות.

(הערה: לא בקיבוק נכון כי לא מבלעים) עבור אתר




איננו מנסים על הפונקציה אלא על פני הטבלה (שיטה אפרימיליטרי)

וכי אנו יכולים ל"התקד" במניחים מקומות

ולכן:
$$\vec{w}^{new} = \vec{w}^{old} - \alpha \text{grad}(\text{Error}(\vec{w})) + \beta (\nabla \vec{w})$$

 (הבלעדים גדולים יותר)
 חלקים כי חלקים אלו
 חלקים כיוון
 חלקים כיוון




מה קרה אם נהיה בחלק הימני?
 זה אומר שלד משנה מה עיסים - אנו חוזים

עצמת המנו. - אם הבלעדים יותר גדולים נלך ממנו יותר אהר.

אם בתוך החלק ישנו מניחים מקומות נרצה שהפסיכי שניהם לטוב יהיה נמוק.

נצטר בחורים מה? נורונים מסביר (סתם ניתן מסתור כמה קטנה) (*)

ולבדוק את הפיזיקים ואם לא מספק טקס לטוביהם טוב נורונים לטוב שמשלים סדרת פיזיקס מסתרת.



(*) שאלה: כמה טוב יהיה המעוות? 10x כמה זמן יקח?

* ש'מח - B.P.

ניסו לכתוב Zip Code שנתה יבני, הם עקרו 70 פיזיקים כושר הם אחר

64 נורונים בעלים:
$$\sum_{i=1}^8 x_i^2 + \sum_{i=1}^8 x_i^2 + \dots + \sum_{i=1}^8 x_i^2$$
 (אם נניחו היצע 25 קטנים $\sum_{i=1}^8 x_i^2$)


Weight Sharing - הנצילן

המשקלים המאטים לעניוין את הפעולה מסוים לעניוין את כאלו פעולה ידוע אלו
 זכור (למרות שהקטטים ~~מאטים~~ מאטורים שונים)
 כיצד בוצע?

בזמן האיטרציות בוצע update לכלם ואם אינו נחה מבצעים ~~מבצעים~~ ^{סבוכים} על העליון.
 נאמר, פונג של פחות משקלים.

הארכיטקטורה שלם הנוכחית (ה features) הם עוקים, מבחיר משקלים
 ← נסכן אם המשקלים קטן יותר
 בעלים הארכיטקטורה של הנוכחית בונה ארכיטקטורה בסים (מבוצע קודם)

תוצאות: 163,000 בלתיאור של סמור (מיטק ט- training ו- test)
 23 epochs → לקח 3 ימים (ביאנו עוקה עם בקור)

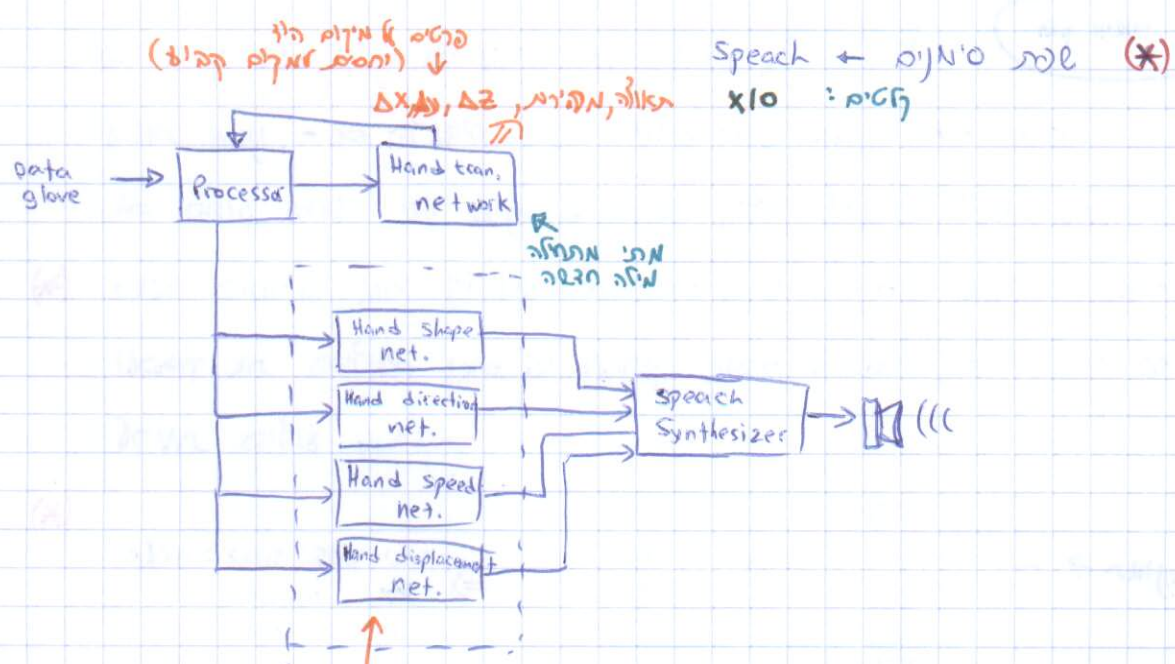


training: 2.5×10^{-3}
 test set: 1.8×10^{-2}

ב- training היה 0.14% misclassification
 ב- test 5% misclassification → הצמחה של 95%.

האזניות ^{כדי} להחזיר תשובה - זה הסברה או לא בעיה ולקח 2 אפסיות
 ↑ טעינה

(*) רכיב עוקה 99% הצמחה לריק לעשרת rejection של 12% (נאמר 87% בטוח
 12% לא 1% - לא יואל)

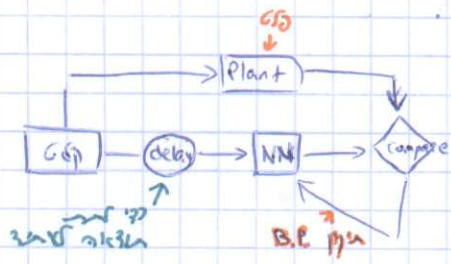


(*) 50 קטטים סה"כ.
 (*) 6 רשת נעמה כמקובל בקרב.
 Hand tran. net. - נעמה - נעמה של הלאו
 ↓
 נעמה של הלאו

תוצאות 99% אלוהם 5% באר אין output (באר של יוצרים את מנתה ומנתה)

מבט כללי על NN (*)

ניתן להשתמש בהם כדי לנתח...



מבט כללי: בסיסה - קלטת הנתונים של היום
 NN תחביר & מודל
 ואם להשוות האם הנתונים היום
 נכון.

Bottleneck N.N. (*)


מתחילים בקלט מרובי ומנסים למצוא את פונ' הפחית ← מסים ציור בקבוק (בסיסה)
 (סדרה עם מס נייטרלי קטן יותר מקלט)

הקלט הינו 2 הסכמה הכסומה 2 (טור חזק) והפלט 2

אם אקרון שלב הונם לא ניתן למצוא את פונ' הפחית אלא כן איננו מנסים 2

קואסיט. א מנה (מאונד) אנו צריכים positive ו-negative data

צריך להיות מייצג (אחרת יש לפתור בעזרתה תהיה גזולה מייצג)

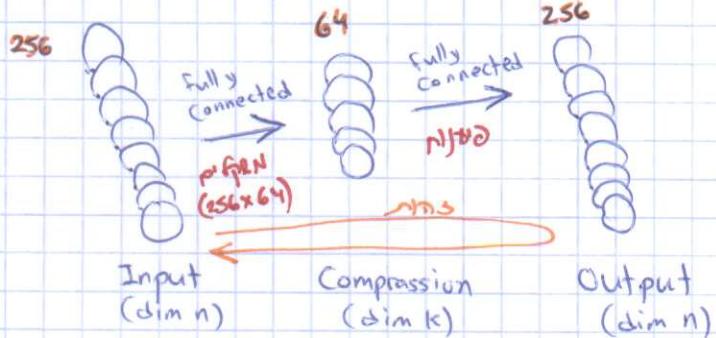


⇒ הסיבה היא שה-negative data
 לא היה מייצג.

צמצום הקלט יורה תמונות, נכון

הקלט הרגיל - אם צומח לפחות תמיד צמצם חיובית אחרת
 צמצום שלילי.

← ה-Bottleneck יורה כיוון של התמונה (למשל קבוצת חוק מהתמונה)



* התמונה של Lena
 קבוצת חוקים באורך 16x16
 * ההצפנה של החוקים הוא ההצפנה של התמונה
 * אלו הם גודל החוק המצומצם
 זרים.

* אלו הם גודל מציאת Compression אופטימלית ← יש כיוון פי 4.



הצורה הפשוטה עם תמונה של Amal צורה, כולל Lena ו-Amal נראה

(מהותית שנייה תמונה של אדם) אם נשים תמונה של Race Car

לא נראה ← פשוט התחבר סוג של תמונה (נוף מציאות סגורה)


נירו - תישובים

2-class labeled training data



המטרה שלנו עם זכרם אחרים - נתן או לא נתן (אמין, ביאטיות - מסל) הסכנה: over trained

כדור, השלטה - מתי נפסק עכצא עמוצ 2 כיוון שטימוצ יתר יכל עכורם שרעור 100% עבור ה- data שמצוין אדם עבור ה- data שרעם עכורן (יכל).



ביאטיות של זכרם דומים

n-fold


- עכורן את הרעם
- עכורן את הרעם טובה



← נכצא ממוצע

היעקו את - הממוצע ה- data
0-10 (10-fold) נכורן 90%
* 1-10% נכורן
* לאיתר אתן נכורן 10% שונים
יתר הממוצע

1-class training



N-class - FMRI specification

כיצא נכצא את הממוצע הרעור שרעם עכור ה- MRI


עם תמונת - עם את אדם מסתם את- MRI שרעור

רעכאות: 90% נכורן עכורן, בין Blank - faces (2-class) (50 classes)
80% עבור 1-class (שימוש ה- wrapper עכורן הרעם)


רעכאות 2 - הרעם 7/11

מה קורה כשם אנחנו?

ישנן כמה יסגים בסיסיים הנראים -







נסתכל על 2 נירותים:




מה יקרה? סינכרוני - יתבצע update לפרטים באג מסמך
אסינכרוני - יתבצע update לפרטים ולחומר מסמך לפרט

לא תהיה התכנסות




התוצאה תהיה יציבה

בשם מסמך לא ישתנה




עבור 2 נירותים ישנם 4 מצבים.

לומר, ישנם 2 מצבים יציבים ו-2 לא יציבים.




אנדר - במקרה של הרבה נירותים אולי יש תהליך שמקבא איתנו לנק' יציבות.

במקרה זה הניירותים היציבים יהיו ביכולתו והמצב ההתחלתי יגיע לסיבובם בצורה "אסינכרונית".




בניגוד למה שהיה אמנם שלא מציגים מנתן מצבים יציבים (מספר מצבים)

מטריות משקלים



כשת יש נירותים נאשר כי נירותן קשיר לכל נירותן

קשרים בין נירותים
 $W_n^{(n)} \leftarrow n \times n$
 $W_n^{(m)} \leftarrow n \times m$



ערך דו-צדדי של נירותים

$W \vec{x}^1 = \vec{x}^1$

$W \vec{x}^2 = \vec{x}^2$

$W \vec{y} = W (\vec{x}^1 + \vec{e}) = W \vec{x}^1 + W \vec{e}$

ביכולת יהיה שמור אב:

$(\vec{e} \rightarrow 0 \Rightarrow W \vec{e} \rightarrow 0)$

* יציב אומר -
אם נתתי מנתן נידאר קו

* כיצד נבנה את המטריצה?

$\vec{s}^1, \dots, \vec{s}^n$

(למשל n וקטורים אורתוגונליים)

$\vec{s}^i \cdot \vec{s}^j = 0 \quad i \neq j$

$\Rightarrow W = \sum_j \vec{s}^j \vec{s}^j{}^T$

outer product:

$n \times 1 \cdot 1 \times n = n \times n$

$W = \begin{pmatrix} w_{11} & \dots & w_{1n} \\ \vdots & \ddots & \vdots \\ w_{n1} & \dots & w_{nn} \end{pmatrix}$
 $w_{ij} = \vec{s}^i \cdot \vec{s}^j$

מטריצה

מה יקרה אם ניקח את W ונכנסו לה?

נניח ונכנסו לה ונניח \vec{s}^0 ו- \vec{s}^1 הם 'ש' אורתוגונליים

$\vec{s}^0 \cdot W = \vec{s}^0 \cdot (\vec{s}^0 \vec{s}^0{}^T + \vec{s}^1 \vec{s}^1{}^T + \dots)$

if $\vec{s}^0 \perp \vec{s}^1 \Rightarrow 0$
 (orthogonal)

$\vec{s}^0 \cdot W = \vec{s}^0 \cdot (\vec{s}^0 \vec{s}^0{}^T + \vec{s}^1 \vec{s}^1{}^T + \dots)$
 $= \vec{s}^0 \cdot \vec{s}^0 \cdot \vec{s}^0{}^T \cdot \vec{s}^0 + \vec{s}^0 \cdot \vec{s}^1 \cdot \vec{s}^1{}^T \cdot \vec{s}^0 + \dots$
 $= \|\vec{s}^0\|^2 \vec{s}^0 + 0 + \dots$

with output

$\|\vec{s}^0\|^2 \vec{s}^0$

$w_{ij} = \sum_{k=1}^m \sum_{l=1}^n s_i^{(k)} \cdot s_j^{(l)}$
 $W = (s^{(1)T} \cdot s^{(1)} + s^{(2)T} \cdot s^{(2)} + \dots + s^{(m)T} \cdot s^{(m)})$
 $\vec{s}^0 \cdot W = \|\vec{s}^{(1)}\|^2 \cdot \vec{s}^0 + \|\vec{s}^{(2)}\|^2 \cdot \vec{s}^0 + \dots$
 $= \vec{s}^0 \cdot (\|\vec{s}^{(1)}\|^2 + \|\vec{s}^{(2)}\|^2 + \dots)$
 $= \vec{s}^0$

Grossberg - Hopfield Networks (Auto-Associative)

BAM network
 binary associative memory



n נייטרונים
 עם קשרים - מאוחדים
 (כולם קולומבוסים)

$\vec{s}^i = \begin{Bmatrix} 1 \\ \vdots \\ -1 \end{Bmatrix}^n$
 ↑ state

$W = \begin{pmatrix} w_{11} & \dots & w_{1n} \\ \vdots & \ddots & \vdots \\ w_{n1} & \dots & w_{nn} \end{pmatrix}$ מטריצה קולומבוסית

קולומבוסיות ← איך הוא עובד? סוגי states

לאיזה הרבה תוצאות מוצאם המרצה המטריצה?

$s_i = \text{sign}(\sum_j w_{ij} s_j - \theta_i)$

אם $\theta_i = 0$ אז $w_{ij} = w_{ji}$

הנחה: $w_{ij} = w_{ji}$

נמצא אצבון א-סינכרוני

ניקה t_j ונרצה שהיה ילד

והאלה אזהר w_{ij} ניקח ?

$$\text{sign}(\sum_j w_{ij} t_j) = t_j$$

$i_k \pm$ ↑

רוצים ל"שמור" רק תכנית אחת t_j

$$w_{ij} \ll t_i t_j$$

$$\text{sign}(\sum_j \underbrace{w_{ij}}_{t_i t_j} t_j) = \text{sign}(\sum_j t_i t_j) = \text{sign}(n t_i) = t_i$$


↑ t_i לא גזרי n

$$(t_i t_j)^2 = 1$$

↑
כל אזהר במקום i

$$\text{net}_i = \sum_j w_{ij} t_j = \sum_j t_i t_j^2 - \sum_j t_i t_j^2$$

↑ "ננין" קרום t_i
↑ "ננין" לא קרום t_j



⇒ attraction

← פומר, אני אקרא תשובה על "ננין" אם רחוק התפרים "ננונים"

⊗ בעולם מכיוון שהנו "שומרים" רק גבולות מה אזהר הוא attractor (מניסו חזרים)

⊗ מה אם נרצה ל"שמור" יותר מבעבר אחד ?
(P גבולות)

$$w_{ij} = \sum_{p=1}^P t_i^p t_j^p$$

↑ רוצים רק תכנית אחת

$$t_j^{p_0} = \text{sign}(\sum_i w_{ij} t_i^{p_0})$$

← רוצים סטביליות

$$t_j^{p_0} = \text{sign}(\sum_j (\sum_{p=1}^P t_i^p t_j^p) t_j^{p_0}) = \text{sign}(\sum_j \sum_{p=1}^P t_i^p t_j^p t_j^{p_0}) =$$

↑ רוצים

$$= \text{sign}(\sum_j t_i^{p_0} + \sum_{p \neq p_0} t_i^p t_j^p t_j^{p_0}) = \text{sign}(n t_i^{p_0})$$

↓ $p = p_0$

מקרה שזה אומתנין יחיד שזה t_i (uncorrelated)

⊗ אם הם מנצחם (או קרום נכח) נצא למעט אזהרים חסמם ח

השורה - כמה P? אם אזהרנו נרצה הרבה אזהר לא.

Sign - רוצים מה


→ עלוצר חנון. Crosstalk יהיה קטן.

שאלה

כמה P אזהר למעט, האם יש Convergence ?

⊗ האם יש מקום ל"שמור" ?

⊗ אזהר "תכנס" attractor ?



נירו - תישובים

רשת ניירונים עם סטאטוס:

$$W := \underbrace{\vec{x}_1 \vec{x}_1^T}_{(n \times n)} + \vec{x}_2 \vec{x}_2^T + \dots + \vec{x}_n \vec{x}_n^T$$




מטריצה סימטרית

$$w_{ij} = w_{ji}$$

מטרה שהוקטורים אורמטנלים:

$$\vec{x}_3 W = \underbrace{\vec{x}_3 \vec{x}_1^T}_{\vec{0}} \vec{x}_1 + \underbrace{\vec{x}_3 \vec{x}_2^T}_{\vec{0}} \vec{x}_2 + \underbrace{\vec{x}_3 \vec{x}_3^T}_I \vec{x}_3 + \dots$$

← התוצאה תהא \vec{x}_3 , שומר וזיכה



← לא באמת נכון
כי יש פונקציה אקטיבציה

$$\vec{x} \xrightarrow{W} W\vec{x} \xrightarrow{\Phi} \Phi(W\vec{x}) \xrightarrow{W} W(\Phi(W\vec{x})) \dots$$

אם לא אורמטנליים:

$$W(\vec{y}) = W(\vec{x} + \vec{e}) = W\vec{x} + W\vec{e}$$

$$\Phi(W\vec{x} + W\vec{e}) = \vec{x} + \vec{e} \rightarrow \text{אם היתה אף הטיאה ישנה התכונות של מלטה האיטרטיוו}$$

אם היינו יכולים להזכיר את המצב רק שהם מקבילים את ה- \vec{x} שם נקבלו שר
מכיון שיש לנו פונקציה אקטיבציה (היא תהא לכן תמיד התכונות?)

Hopfield אצן:

אם ניקח שני וקטורים רצופים הסבירה שם יהיו אורמטנלס היקר (מורה (אזל-0))

$$\vec{r}_1 = (1, -1, 1, 1, -1, \dots)$$

$$\vec{r}_2 = (-1, 1, 1, -1, 1, \dots)$$

$$\lim_{n \rightarrow \infty} (\vec{r}_1 \cdot \vec{r}_2) = 0 \leftarrow \text{אם n מספיק גדול}$$

הסבירה שם יסכמו $\frac{1}{2}$
הסבירה שם לא יסכמו $\frac{1}{2}$
חוק אם n מספיק גדול הם יהיו קרובים
אורתוגונליים.

$x_1, x_2, \dots, x_n \leftarrow$ לא תלוי ב-n

$$W := \frac{1}{n} \sum \vec{x}_i \vec{x}_i^T \leftarrow \text{אני לא מנסים ליהיה שווה ל-0 אבל מסוון יש גם אטרקטור}$$

$$\vec{x}_j; W = \frac{1}{n} x_j x_j^T x_j + \underbrace{\sum x_j x_i^T x_i}_{\text{"crosstalk"}}$$

כאשר מסתכלים על יותר מ-1 ניירונים



האם
יש
מאחר
בין?



↑ וזיכה
אם \vec{v}
שנים
attractors

asynchronous update (completely connected, bipolar, Mc.P neurons) → תנאים סגור

סגור נייח אצל
* סגור ההתנסות:
אלו נתון מהתנאים שלנו
של טיפוס למקום יציב

(Symmetric) $w_{ji} = w_{ij}$ (i)
 $w_{ij} = 0$ (ii)

ממדים התחלת כשהו טיפוס מאקום יציב.



הסכמה:
$$\vec{w} = \sum_{\vec{x}} \vec{x}^T \vec{x}$$

$x_{new} := \Phi(\text{net in}) = \Phi(\sum w_{ij} x_j)$

היתכן של הקטור יכול להשתנות אולם מספר
הפסגים שהוא יאמרה הנו סופי ולכן טיפוס מאקום יציב.

הוכחה:

נחשב את כמות 3 תכולות $E(\vec{x})$ מוחלט המאטה

- (i) E מוחלט המאטה
- (ii) E משיני E משיני \vec{x} סדרה לקטין את E
- (iii) קיים $\delta > 0$ כך שיש שינוי הוא לפחות δ .

$E(\vec{x}) = - \sum_{i,j} x_i w_{ij} x_j$ → אם הסדר הוא 0
(אם לא נקדם זהוסיף משהו)
לקח את כמות δ

אם $w_{ij} = 0$ (חול מ- n)
אם $x_i = 1$ (אם יש מנימוח) $E(\vec{x}) = -n^2$ (נקדם n^2)

$$\Phi(x_j) = \begin{cases} -1 & \sum w_{ij} x_i < \theta \\ x_j & \sum w_{ij} x_i = \theta \\ 1 & \sum w_{ij} x_i > \theta \end{cases}$$

אם הסדר לא 0

הוכחת תכולות:

(i) $E(x) \geq - \sum |w_{ij}|$ ← אם סדר לא 0 אולי מוחסימים

(ii) סדרה אולי יש 2 \vec{x} שני יקטין קצת מוחסימים (סדרה אולי) ולכן נקח את
המנימוח של \vec{x} .

(ii) $E^{new} - E^{old} \rightarrow$ רובים מהאקטור שזה מאקום יציב

$$= - \sum_{i,j} x_i^{new} w_{ij} x_j^{new} - \left(- \sum_{i,j} x_i^{old} w_{ij} x_j^{old} \right)$$

asynchronous $x_i^{new} = x_i^{old}$, $x_i \neq 0$: $\forall i$

$$= - \sum_j x_i^{new} w_{ij} x_j + \sum_j x_i^{old} w_{ij} x_j$$

$$= \left(-x_i^{new} + x_i^{old} \right) \sum_j w_{ij} x_j \rightarrow \text{net in } \Phi$$



$$E = \frac{A}{2} \sum_x \sum_i \sum_{j \neq i} v_i^x v_j^x$$

← אורך קשר
← אורך קשר

$$+ \frac{B}{2} \sum_i \sum_x \sum_{y \neq x} v_i^x v_i^y$$

← כמה זמן קשר
אם יש יותר מסדר אחד מולקולות באותו ערך

$$+ \frac{D}{2} \sum_x \sum_{y \neq x} \sum_i d_{xy} v_i^x (v_{i+1}^y + v_{i-1}^y)$$


← כמה זמן קשר אם יש יותר מסדר אחד מולקולות באותו ערך

$$+ \frac{C}{2} \left(\left(\sum_x \sum_i v_i^x \right) - n \right)^2$$

← כמה זמן קשר אם לא נחרנו ערך

* המסקים קולעים ואני מחפשים מנסים ליהיה של הבליה בצורה E. → אופטימיזציה



בעיה מציאת מקסימום



ישנה תחרה בין הנירונים
וק אתה "שאר"

* כאשר נירון מנצח ים-ים הוא כבר לא מנסה

בצורה של קבוצה המקומית מקסימים (אבל ישאר יק נירון אתה תגדל מה שצדק אים)



"לספק את הספק" נק שקרובים יהיו חיוביים ורחוקים יהיו שליליים.

נרצה להראות שזה פועל, כי כוונתנו היא שיש לנו מקרים:

מקרה I: $x_i^{old} = 1$ $x_i^{new} = -1$

- auto-associative *

$-x_i^{new} + x_i^{old} > 0$ $net_{in} < 0$

$\nabla E < 0$ \Leftarrow המשואה פועלת

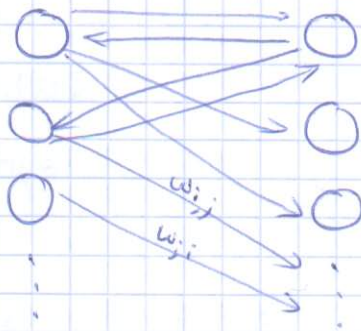
מקרה II: $x_i^{old} = -1$ $x_i^{new} = 1$

$-x_i^{new} + x_i^{old} < 0$ $net_{in} > 0$

$\nabla E < 0$ \Leftarrow

כמה דוגמאות אפשר להשתמש/לשכור עמק סל נייטונים? גאומטריה - 18 חברים.

BAM
Binary associative memory



אם יש לנו צבצב עם קשר מלא בין הצבצבים, הרי קשר מלא.

תצפית בית

(\vec{x}, \vec{y}) (שומר)


$W = \sum_{\langle \vec{x}, \vec{y} \rangle} \vec{x} \vec{y}^T$

$n \times m$

אם נתק אר המונחים הללו ניתן לומר יריבה וצבצב - עשורה את E למחלים ע - x, y.

TSP

ישנם איש מחרוזת האמור אטום בה לדים ורובים שרממן יהיה מניחתי.



יש לנו n^2 נייטונים ונירבה שכלם למורה נכח שיהיה "רופק" נירון אחר.

נצטרך מפקי שלים בין נייטון ונייטון במחורה. נצטרך מפקי שלים בין נייטון ונייטון במורה.

נצטרך מחק בין נייטונים במורה - למחורה - שונה (מפקי מחבו) נאמר, נצטרך

$v_i^x \rightarrow$ מחזור נייטון במורה x למחורה i

נוירו-מישקיים

תבנית בית 2

- אפשר לבדוק בין הטעות של בחינה של רמאות שונות.
- נדרש לבדוק האם האלגוריתם מקבל בחינה של Text

* **פעלים בוצעו - (1) בחינה/הצגה**

(2) פיסור רמאות

הערה - הפרמטרו ה-one class, אם היינו מפרמטרים ה-two class (1 למינוי 1-2 של text מילים) אזי היינו יכולים לקבל קודם שאינו שייך לאף אחד מה-classes. לכן היה יוצא מה שהתוצר הוא יפוק לאחד class הוא בלתי יותר. לכן קשה להצגה של training set שיש את הפרטים השלמים

B.A.M

תבנית בית 3 - ממוז associative memory סגורה BAM


מס' טלפון - 5678521

(א) הערה - attractors ונקודת מס' טלפון 5678421 'תוצר attractor

← fault tolerance

(ב) נתונים מס' טלפון icons בקובץ 4x4


$\vec{y} \leftarrow 5678521$



$$W = \sum_{p=1}^P \vec{x}^p \vec{y}^p T$$



($w_{ij} = w_{ji}$)



בסיס של מספר נדרש למונח את סוף האנרציה.

$$w_{y,x} = w_{x,y}$$

$$w_{x,y} = w_{y,x}$$

[נתן סדרת של תבנית 1 בתבנית של תבנית 2]

רשתות עם תחרות

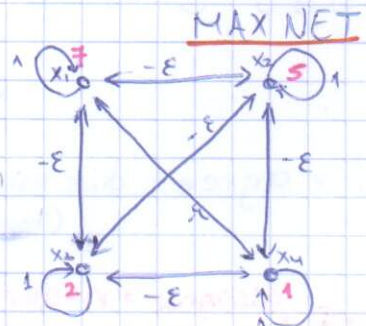
הנוירון נתון $\sum w_i x_i$ (activation)

הנחה - אין 2 נוירונים אלו זכר

$$x_j^{new} = \sum_{i=1}^n w_i x_i^{old} + x_j^{old}$$

~~מחוקק~~

בס' ϵ הנוירון יקרא 'תוא' עליה שלם 0 פה 1-N



$\epsilon = 1/4$

$$X_1^{new} = X_1^{old} + \sum_{i+j} w_i X_i^{old} = 7 - \epsilon(5+2+1) = 5$$

שלב 1

$$X_2^{new} = 5 - \epsilon(7+2+1) = 2.5$$

$$X_3^{new} = 2 - \epsilon(7+5+1) < 0$$

$$X_4^{new} = 1 - \epsilon(7+5+2) < 0$$

כל עבר לא מוגדמים בשלם הקא

$$X_1^{new} = 5 - \epsilon \cdot 2.5 \approx 4.4$$

שלב 2

$$X_2^{new} = 2.5 - \epsilon \cdot 5 = 1.25$$


$$X_3^{new} = 4.4 - \epsilon \cdot 1.25 = 4.1$$

שלב 3


$$X_4^{new} = 1.25 - \epsilon \cdot 4.4 \approx 0.1 \rightarrow \text{בשלב הקא יתכנס ל-0}$$

← המקסימום הינו X_1 .

Mexican Hat




זו תמונה טיפוסית ל, אולם כבר קורה בפיקום של המקסימום האחרים.



כלים מתחם תפליק של Sharpening


יורה פון "חיבור"

סיבוכיות תולדות - נתון הכפויס הוא לא חלק מהמקסימום/נייטונים



אסר בגו-ממא:

Hamming Net



כסוף רק אלז יהיה מוצק זה אמור שרבי קרובים לא-סופים הינם

אם המקסימום אנתנו בשלם האלו י"לכ כמו ה- input

$\vec{w} \odot \vec{v} = \text{agree} - \text{disagree}$
(hamming distance)

Bipolar

$\vec{w} \odot \vec{v} = \text{disagree} = n - \text{agree}$
 $\vec{w} \odot \vec{v} = \text{agree} - (n - \text{agree}) = 2\text{agree} - n$

$n = \text{agree} + \text{disagree}$

$$\vec{w} \odot \vec{v} = 2 \text{ agree} - n$$

←

$$\text{agree} = \frac{\vec{w} \odot \vec{v}}{2} + \frac{n}{2}$$

$\vec{e}_1, \vec{e}_2, \dots, \vec{e}_7$
אקסטרס


נקודת אור המוקדים לעיתים האקסטרס חלקי 2.

אקסטרס Bias: $\frac{n}{2}$

מרחב המוקדים



⇒
אקסטרס
של המרחב




(מקום המוקדים
של המוקדים)

* מתארים את המוקדים לפי המוקדים הדיאגנאליים שלהם (זה מייצג את הוויכוח).

2-class	data	+	-	המרחב המייצג המקורי של המוקדים
1-class	data	+		
0-class	data			

0-class - יש רק data ולא יבוא לכאורה class לשייך.

אם זה טוב?




נקודת קצה שלו נאלץ קשרים ולקיים ויכוח את האקסטרס


de תחנות.

טוב, שמים Topology של כמה II

אמנם: אפולונית קו:




אם לא
אפולונית
יש מרחב



ניתן גם להשתמש ב:

אפולונית ב-NNNN



אקסטרס
מוקדים

Self Organizing Neural Network: Kohonen Network

(1) \vec{x} אקסטרס

(2) Find closest \vec{z} to \vec{x} in המרחב המייצג in Kohonen level



learning

(3)

Clustering - הרעיון

אנשים \rightarrow סופרמאזיות קו :

בהתחלה לבחור תצורה אחת
לא בהכרח "מאונד"
נרצה שבסוף יהיה מאונד.



* נקודה את נולם
לנקודה.

ניווט הכי קרוב

את נסתור על היכולת של (2 בעצמים)

• - נקודה חדשה

← קירוב

בעצם נחפש את הניווט הכי קרוב

אתרי ההתנסות של האלמנטים התחילה תהיה מסומנת

$$\{ \vec{x} \mid \min \| \vec{u} - \vec{x} \| \}$$

$N(\vec{x})$ - neighborhood

α - learning parameter

Algorithm

(1) בחר נקודת \vec{u} (סגור)

(2) find closest \vec{z} to \vec{u} (by Hamming net or min. Euclidian distance)

in the weights space in kohonen level

(3) Learning :

$$\vec{x}_i^{new} = (1-\alpha)\vec{x}_i^{old} + \alpha\vec{u} \quad ; \quad \vec{x} \in N(\vec{z})$$

\leftarrow מנסים בניווט \vec{u}

(4) update N (בהתחלה N גדולה) \rightarrow מאט, מאט יהיו פחות שונים

(5) update α

* בעצם מנסים N יותר ויותר α .

אלמנטים כשהמספרים כבר קטנים.

18/7/08

נוירו-חיסונים

(*) ה-Hamming Net האטאבים יוצרו ע"י מקטים מוקטור הקלט באשר
מה מקטים תלויים במידת קטור הקלט.

(*) אם אין אטאבים מראש?

נניח שיש 7 נוירונים, נבחר מקטים רנדומליים ואז אטא הקטאם
יתקבלו ע-7 קבוצות.

קציית ה-Uniform / non-Uniform

צריך שהמקטות ה-clusters יהיה שונה למהתפוצות ה-data

~~Equal Neighboring Map~~

לכן, במקרה שה-data לא מתפלג אחיד אז יהיו cluster
שיבחרו הרבה פעמים ← נדרש לתת להם קבץ אל מנת שאתים ייבחרו.

$$P_j^{new} = P_j^{old} + \beta (y_j - P_j^{old})$$

$$0 < \beta < 1$$

$$y_j = \begin{cases} 1 & \text{if neuron } j \text{ is the winning neuron} \\ 0 & \text{otherwise} \end{cases}$$

(*) בהתחלה נבחר הרבה שכנים להזכה כדי שיסתברו.


אטא, אטא נצמצם כמה שכנים, נניח כדי ע"כאות את ה-data points
בצורה טובה.

Counter Propagation

כעוזבים עסקות מניקה של סליחה.

optimal look up table


יש מה מוזבא של כניסות.
למחר או המיקום והערך



מחולץ של ס
הקברים
שניכסו
ל-x

$$\vec{y}^{\text{new}} := \vec{y}^{\text{old}} + \beta (\vec{y}' - \vec{y}^{\text{old}})$$

$$y = \frac{1}{x}$$



יותר מהיר - back Propog.

אם פחות מוקד מני

* נקד המנהל הספר Ritter להסבר טוב יותר.

Full back propagation
(עם ה-y לא קודם)

25/7/08

ניירו-חילוקיים


(*) Kohonen נותן Equi Probable Map

ההסתברות של data point "פול" כחלק מהנתיבות שלה עם את הנתיבות.

(*) הפשוט אין-פול domain - (ה)

← אפשר עבור Sampling בק שהיו יותר נקודות בקול

או אופוזיציה או מרחב התקנים



(*) חלק מהמרחב מציבים ניוון לפעם אחת שניו.

חלק מהמרחב בוחנים (נירון זקוף) ← מתנוון אחת מחדש
 ורשת אופוזיציה רק עם הזמן

בחינת הוספת הנוסף

אופוזיציה: מה ניוונים כמה העלים, ~~משהו~~

← ניוון מנצב של:

האמצעותם מקדם האופוזיציה באופןיות מצבם ונק' הנפוצות מייצגות את העלים.

האמצעותם מוצג את האופוזיציה ומחבר בין העלים בזווית האופוזיציה.

שמונים של Kohonen

(*) חלק ממערכת יותר זכורה ← שמונים את ההתנהגות האופוזיציה של

ה - data

(*) שמונים את מקומות Clustering) את הערכים מהתוצאות.

← Counter propag.

Counter Propagation

$$f(\vec{x}) = \vec{y}$$

(*) מוסיבים זיה

← עיבוד את $\langle \vec{x}', \vec{y}' \rangle$

סיפוס

מכאילים

Data - δ


מציאות

זכריות.

$\langle \vec{x}, \vec{y} \rangle$

יש סגן את ה-data, מ-ה-Sampling
 אני רוצים לקדם את חלק-סיפוסים
 (אני יוציא מראש כמה אב-סיפוסים יש סגן)
 כמו כן, אני רוצים למצוא את הערכים שהם
 ואת אלו שקרויים עמים.


← סיווג הנקודות של הלג-ס'וליס - kohonen
 ← סיווג הנקודים הלג-ס'וליס Counter propagation (עמך מילוח)



(אב ס'וליס)

$$y^{new} := y^{old} + \alpha (\dots)$$

(*) תוק כבי סיווג מלכדים את הנקודים לאת הלג.



- layer 3: grosberg layer
- layer 2: kohonen layer
- layer 1: input units


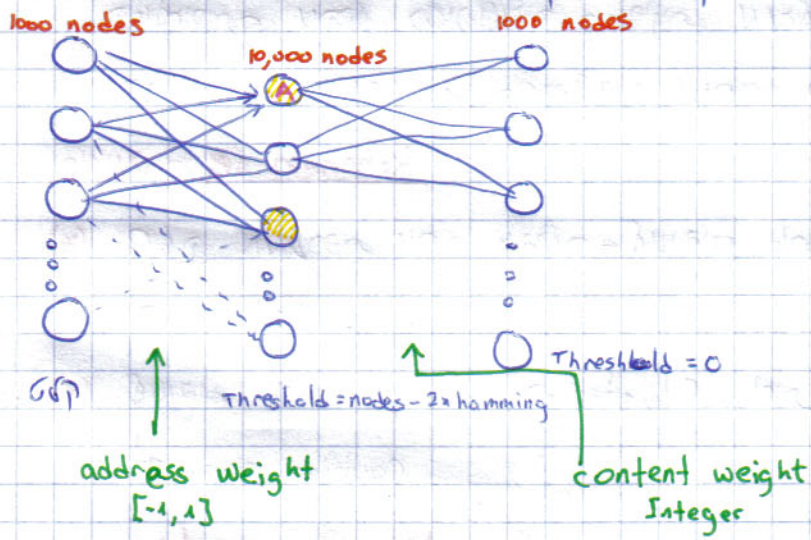
↓
 optimum look up טבלת מילוח
 table

* ~~מיון~~ cluster points $x \in$ (סיווג הנקודות של הלג-ס'וליס)

SDM (kanerva)

(*) הרצון-סיווג בקבוצות של ניוונים כבי ס'וליס את מרחב הכתובות.

יש מ ס'וליס שמיצעים מקום מילוח 2^m כתובות.



Address Space Virtual 2^m

→ ס'וליס מילוח של $[-1, 1]$

* hamming - נחזק את ס'וליס הנקודים למסוף קבוצת (מרחק קטן) ולס'וליס מילוחים

Address 1 1 0 1 0 0 0 0

בנקודים מ'י' מספיק קרוב (המרחק hamming)

למקרה שניתן.


Address (קבוצה רגולרית)	Content	hamming dist.	selected
0000 0010		4	-
00010001	3 3 -27-265	3	X
01000100	32 + 52444	3	X
01111010		4	-
10101111		7	-
10001001		4	-
10010011	00000000	3	X
11011011	2222 -2-2-2-2	3	X

* נניח והמרחק הינו 3
 וחסוניה לניצוא
 9 7 -8 5 7 0 8 7
 1 1 0 1 1 * 1 1

הספרה 0
 ה'תלמיד'
 כיוון ש-
 00000000

יכול להיות שבמקום תמונה של ספרה (קפ) תמונה של ספרה (במקום, במקום) ספרה "שמה" תמונה של ספרה. → ה-content במקום

חברה סגורה



יתרונות של NN:

- יוניברסל
- יוניפורמל ← זינקו: כל פונ' רציפה יוניפורמית
- אינדיקציה
- אלוטורמים מקסימים

- מספר תפלות ביטורים → האלמנטים של Kohonen
- מודלים לא-ליניאריים → בעולם הסף

חסרונות של NN:

- האימוץ הינו פרימיטיבי → איטי למשל ב-P.B.
- המצב הפרימיטיבי אינו סגור → (גורם לבצע הרבה ניסיונות)
- לא יבוצו איפה מוצא מתאים לאילו בעיה
- לא יבוצו איפה ארטימטיקה אברה אברה
- פרוטקטים לא יבוצו - α, מומנטום ...
- בעיית over training.
- נדרש הרבה כוח חישוב

Non Recurrent ← לא חוזר

אלהי:
 perceptron - מודל פשוט, מיון בסיסי - פיתוח מודל, מה תוצאת המודל.
 התבוננות perceptron
 Feed forward - ניתוח טכניקות, B.P. מודל

Recurrent ← חוזר

Hopfield → זיכרון
 BAM → זיכרון
 - סיכום אקסטרמי, קשה לזכור את ה attractor של כל דברים. אם שומרים תבואים
 מודל (אם סימטרי) ← סגור אקסטרמי
 ↓
 Energy / מודל התבוננות & Hopfield

Kohonen - self organizing, SOM (לא מספיק מודל)

SDM - סיכום אקסטרמי, fault tolerance

* זיכרון & חוסר רגישות לטעויות.

* אם יהיה SDM - ART-1 (אולי תהיה שאלה אם זהו כזה SDM)

* זיכרון מודל: איפה רשת מתאים עם מנת לזכור רכב? נדרש מודל
 בין אלגוריתמים (חסרונות ויתרונות)

* סכום קולט summary.ps