

Näin koulutat neuroverkkosi

Backpropagation- eli takaisinleviämisalgoritmi

Aaro Salosensaari

Studia Varjomafia V
28.2.2021

Mitä yritän tässä esityksessä selittää

- 1 **Neuroverkkojen opettaminen:** Jonkinlainen käsitys miten *backpropagation*- eli "takaisinleviämis"-algoritmi teoriassa toimii.

Mitä yritän tässä esityksessä selittää

- 1 **Neuroverkkojen opettaminen:** Jonkinlainen käsitys miten *backpropagation*- eli "takaisinleviämis"-algoritmi teoriassa toimii.
- 2 Hieman edellistä Studia Varjomafia-esitystä tarkempi selitys ns "feed-forward" neuroverkkojen toiminnasta.

Mitä yritän tässä esityksessä selittää

- 1 **Neuroverkkojen opettaminen:** Jonkinlainen käsitys miten *backpropagation*- eli "takaisinleviämis"-algoritmi teoriassa toimii.
- 2 Hieman edellistä Studia Varjomafia-esitystä tarkempi selitys ns "feed-forward" neuroverkkojen toiminnasta.

Asioita jotka jäävät esityksen ulkopuolelle:

- Muut koneoppimisen muodot.
- Syväoppivien neuroverkkojen monet käytännölliset yksityiskohdat.
- ...

Sisältö

1 Johdanto

2 Taustaa

- Koneoppiminen
- Kuvat

3 Neuroverkon perusajatus

4 Backpropagation eli "takaisinleviämisalgoritmi"

5 Lopetus

Sisältö

1 Johdanto

2 Taustaa

- Koneoppiminen
- Kuvat

3 Neuroverkon perusajatus

4 Backpropagation eli "takaisinleviämisalgoritmi"

5 Lopetus

Koneoppiminen ja sen alalajeista

Koneoppivat algoritmit

Koneoppiminen tutkii algoritmeja, jotka **opetusdatan** pohjalta oppivat ratkaisemaan **uusia ongelmia**.

Koneoppiminen ja sen alalajeista

Koneoppivat algoritmit

Koneoppiminen tutkii algoritmeja, jotka **opetusdatan** pohjalta oppivat ratkaisemaan **uusia ongelmia**.

Ohjattu koneoppiminen

Ohjatussa koneoppimisessa (*supervised learning*) algoritmilelle annetaan opetusdataa, jossa on syötteitä (*input X*) ja vastaavia ulostuloja (*output y*).

Koneoppiminen ja sen alalajeista

Koneoppivat algoritmit

Koneoppiminen tutkii algoritmeja, jotka **opetusdatan** pohjalta oppivat ratkaisemaan **uusia ongelmia**.

Ohjattu koneoppiminen

Ohjatussa koneoppimisessa (*supervised learning*) algoritmilte annetaan opetusdataa, jossa on syötteitä (*input* X) ja vastaavia ulostuloja (*output* y).

Halutaan, että algoritmi oppii *yleisesti* yhdistämään syötteen haluttuihin ulostuloihin:

$$X \rightarrow y$$

Esimerkki: Kuvasta datamatriisi




X

$\rightarrow (\text{algoritmi}) \rightarrow y = \text{"LAISKIAINEN"}$

Muistutus: Kuva on datamatriisi



Kuva.




Muistutus: Kuva on datamatriisi



Kuva.



Kuva koostuu
RGB-pikseleistä.




Muistutus: Kuva on datamatriisi



Kuva.




Kuva koostuu
RGB-pikseleistä.



Yksinkertaistetaan lisää.
Pikseli = yksi numero 0.0
... 1.0.

Esimerkki: Datamatriisista vektoriksi

- Jokainen matriisi voidaan myös ajatella (ja käsitellä) vektorina.



Sisältö

1 Johdanto

2 Taustaa

- Koneoppiminen
- Kuvat

3 **Neuroverkon perusajatus**

4 Backpropagation eli "takaisinleviämisalgoritmi"


5 Lopetus

Muistutus!

- Tässä esityksessä puhutaan neuroverkoista ja neuroneista.


Muistutus!

- Tässä esityksessä puhutaan neuroverkoista ja neuroneista.
- Ne matemaattinen malli, joka on **inspiroitunut** biologisista hermosoluista.




Muistutus!

- Tässä esityksessä puhutaan neuroverkoista ja neuroneista.
- Ne matemaattinen malli, joka on **inspiroitunut** biologisista hermosoluista.
- ...mutta on myös hyvin yksinkertainen, ei malli biologisista hermosoluista.




Neuroverkon perusajatus

- Neuroverkko koostuu "neuroneista" (*neural unit*).
Neuroni vastaanottaa useita signaaleja $x_1, x_2, \dots$




Neuroverkon perusajatus

- Neuroverkko koostuu "neuroneista" (*neural unit*). Neuron vastaanottaa useita signaaleja $x_1, x_2, \dots$
- ja yksinkertaisella operaatiolla muodostaa niistä syötteen seuraavalle tasolle z .




Neuroverkon perusajatus

- Neuroverkko koostuu "neuroneista" (*neural unit*). Neuroni vastaanottaa useita signaaleja $x_1, x_2, \dots$
- ja yksinkertaisella operaatiolla muodostaa niistä syötteen seuraavalle tasolle z .
- Neuroneista muodostetaan verkko, jossa on useita tasoja. Ensimmäinen taso x syöte, viimeisenä ulostulo y . Yksinkertaisten neuronien iso verkko mahdollistaa hyvin monimutkaista prosessointia.




Neuroverkko hieman yksityiskohtaisemmin



Neuroverkko hieman yksityiskohtaisemmin


Verkon neuronit toimivat yleensä kahdessa vaiheessa.



Neuroverkko hieman yksityiskohtaisemmin

Verkon neuronit toimivat yleensä kahdessa vaiheessa.


- 1 Neuronilla on oma vektori painoja $[w_1 \dots w_n]$.



Neuroverkko hieman yksityiskohtaisemmin

Verkon neuronit toimivat yleensä kahdessa vaiheessa.


- 1 Neuronilla on oma vektori painoja $[w_1 \dots w_n]$.
 $w_i \approx$ kuinka tärkeä x_i on.



Neuroverkko hieman yksityiskohtaisemmin

Verkon neuronit toimivat yleensä kahdessa vaiheessa.


- 1 Neuronilla on oma vektori painoja $[w_1 \dots w_n]$.
 $w_i \approx$ kuinka tärkeä x_i on.
- 2 Tärkeys $= w_1 x_1 + w_2 x_2 + \dots + w_n x_n$.



Neuroverkko hieman yksityiskohtaisemmin

Verkon neuronit toimivat yleensä kahdessa vaiheessa.


- 1 Neuronilla on oma vektori painoja $[w_1 \dots w_n]$.
 $w_i \approx$ kuinka tärkeä x_i on.
- 2 Tärkeys = $w_1 x_1 + w_2 x_2 + \dots + w_n x_n$.
- 3 Syötteiden summalle tehdään muunnos g , joka antaa neuronin ulostulon:
 $g(w_1 x_1 + w_2 x_2 + \dots + w_n x_n) = z$.



Neuroverkko hieman yksityiskohtaisemmin

Verkon neuronit toimivat yleensä kahdessa vaiheessa.


- 1 Neuronilla on oma vektori painoja $[w_1 \dots w_n]$.
 $w_i \approx$ kuinka tärkeä x_i on.
- 2 Tärkeys = $w_1 x_1 + w_2 x_2 + \dots + w_n x_n$.
- 3 Syötteiden summalle tehdään muunnos g , joka antaa neuronin ulostulon:
 $g(w_1 x_1 + w_2 x_2 + \dots + w_n x_n) = z$. Muutos g on mallintaa neuronin **aktivoitumista**.
Latistaa "tärkeyden" nollaan tai korostaa sitä suuresti.



Neuroverkko hieman yksityiskohtaisemmin


Verkon neuronit toimivat yleensä kahdessa vaiheessa.

- 1 Neuronilla on oma vektori painoja $[w_1 \dots w_n]$.
 $w_i \approx$ kuinka tärkeä x_i on.
- 2 Tärkeys = $w_1 x_1 + w_2 x_2 + \dots + w_n x_n$.
- 3 Syötteiden summalle tehdään muunnos g , joka antaa neuronin ulostulon:
 $g(w_1 x_1 + w_2 x_2 + \dots + w_n x_n) = z$. Muutos g on mallintaa neuronin **aktivoitumista**.
Latistaa "tärkeyden" nolnaan tai korostaa sitä suuresti.
- 4 Lineaariset summat + epälineaarinen aktivoituminen $\rightarrow$ monimutkaisia asioita.



Neuroverkko on verkko myös matemaattisesti


■ $g(w_{1,1}\mathbf{x}_1 + w_{1,2}\mathbf{x}_2 + \cdots + w_{1,n}\mathbf{x}_n) = z_1$



Neuroverkko on verkko myös matemaattisesti

■ $g(w_{1,1}\mathbf{x}_1 + w_{1,2}\mathbf{x}_2 + \cdots + w_{1,n}\mathbf{x}_n) = z_1$


■ $g(w_{2,1}\mathbf{x}_1 + w_{2,2}\mathbf{x}_2 + \cdots + w_{2,n}\mathbf{x}_n) = z_2$



Neuroverkko on verkko myös matemaattisesti


■ $g(w_{1,1}x_1 + w_{1,2}x_2 + \dots + w_{1,n}x_n) = \mathbf{z}_1$

■ $g(w_{2,1}x_1 + w_{2,2}x_2 + \dots + w_{2,n}x_n) = \mathbf{z}_2$



Neuroverkko on verkko myös matemaattisesti

- $g(w_{1,1}x_1 + w_{1,2}x_2 + \dots + w_{1,n}x_n) = \mathbf{z}_1$
- $g(w_{2,1}x_1 + w_{2,2}x_2 + \dots + w_{2,n}x_n) = \mathbf{z}_2$
- $g(w_{3,1}\mathbf{z}_1 + w_{3,2}\mathbf{z}_2) = \mathbf{z}_3$
- jne.



Neuroverkko on verkko myös matemaattisesti


- $g(w_{1,1}x_1 + w_{1,2}x_2 + \dots + w_{1,n}x_n) = \mathbf{z}_1$

- $g(w_{2,1}x_1 + w_{2,2}x_2 + \dots + w_{2,n}x_n) = \mathbf{z}_2$

- $g(w_{3,1}\mathbf{z}_1 + w_{3,2}\mathbf{z}_2) = \mathbf{z}_3$

- jne.

- Viimeisen ulostulon y voisi kirjoittaa isona yhtälönä:




Neuroverkko on verkko myös matemaattisesti

- $g(w_{1,1}x_1 + w_{1,2}x_2 + \dots + w_{1,n}x_n) = \mathbf{z}_1$

- $g(w_{2,1}x_1 + w_{2,2}x_2 + \dots + w_{2,n}x_n) = \mathbf{z}_2$

- $g(w_{3,1}\mathbf{z}_1 + w_{3,2}\mathbf{z}_2) = \mathbf{z}_3$

- jne.



- Viimeisen ulostulon y voisi kirjoittaa isona yhtälönä:

$$y = g(w_i \mathbf{z}_3 + \dots) = g(w_i g(w_{3,1} \mathbf{z}_1 + w_{3,2} \mathbf{z}_2) + \dots)$$


Neuroverkko on verkko myös matemaattisesti

- $g(w_{1,1}x_1 + w_{1,2}x_2 + \dots + w_{1,n}x_n) = \mathbf{z}_1$

- $g(w_{2,1}x_1 + w_{2,2}x_2 + \dots + w_{2,n}x_n) = \mathbf{z}_2$

- $g(w_{3,1}\mathbf{z}_1 + w_{3,2}\mathbf{z}_2) = \mathbf{z}_3$

- jne.



- Viimeisen ulostulon y voisi kirjoittaa isona yhtälönä:

$$y = g(w_i \mathbf{z}_3 + \dots) = g(w_i g(w_{3,1} \mathbf{z}_1 + w_{3,2} \mathbf{z}_2) + \dots)$$

$$\text{yleisesti } y = M(x) \quad \text{missä } x = [x_1 \dots, x_n]$$

tai


Neuroverkko on verkko myös matemaattisesti

- $g(w_{1,1}x_1 + w_{1,2}x_2 + \dots + w_{1,n}x_n) = \mathbf{z}_1$

- $g(w_{2,1}x_1 + w_{2,2}x_2 + \dots + w_{2,n}x_n) = \mathbf{z}_2$

- $g(w_{3,1}\mathbf{z}_1 + w_{3,2}\mathbf{z}_2) = \mathbf{z}_3$

- jne.



- Viimeisen ulostulon y voisi kirjoittaa isona yhtälönä:

$$y = g(w_i \mathbf{z}_3 + \dots) = g(w_i g(w_{3,1} \mathbf{z}_1 + w_{3,2} \mathbf{z}_2) + \dots)$$

$$\text{yleisesti } y = M(x) \quad \text{missä } x = [x_1 \dots, x_n]$$

tai

$$y = M(x) = g(W_L g(W_{L-1} g(\dots g(W_1 x)))) ,$$

missä W_L matriisi kaikista tason L vektoreista w_l .



Hengähdystauko!



Neuroverkon tiivistelmä

Tiivistelmä: Jos neuronin i sisääntulo on $[x_1, \dots, x_n]$, sen ulostulo z_i on

$$g(w_{i,1}x_1 + w_{i,2}x_2 + \dots + w_{i,n}x_n) = g(w_i \cdot x), w_i = [w_{i,1}, \dots, w_{i,n}].$$

Neuroverkon tiivistelmä

Tiivistelmä: Jos neuronin i sisääntulo on $[x_1, \dots, x_n]$, sen ulostulo z_i on

$$g(w_{i,1}x_1 + w_{i,2}x_2 + \dots + w_{i,n}x_n) = g(w_i \cdot x), w_i = [w_{i,1}, \dots, w_{i,n}].$$

Neuroverkon tiivistelmä

Tiivistelmä: Jos neuronin i sisääntulo on $[x_1, \dots, x_n]$, sen ulostulo z_i on

$$g(w_{i,1}x_1 + w_{i,2}x_2 + \dots + w_{i,n}x_n) = g(w_i \cdot x), w_i = [w_{i,1}, \dots, w_{i,n}].$$

- Jokaisella neuronilla on
 - vektori painoja $[w_1 \dots w_n]$, jotka kertovat mitä mieltä neuroni on syötteistä $x_1, \dots, x_n$
 - ja aktivointifunktio g joko korostaa tai latistaa neuronin mielipidettä.

Neuroverkon tiivistelmä

Tiivistelmä: Jos neuronin i sisääntulo on $[x_1, \dots, x_n]$, sen ulostulo z_i on

$$g(w_{i,1}x_1 + w_{i,2}x_2 + \dots w_{i,n}x_n) = g(w_i \cdot x), w_i = [w_{i,1}, \dots, w_{i,n}].$$

- Jokaisella neuronilla on
 - vektori painoja $[w_1 \dots w_n]$, jotka kertovat mitä mieltä neuroni on syötteistä $x_1, \dots x_n$
 - ja aktivointifunktio g joko korostaa tai latistaa neuronin mielipidettä.

Neuroverkon tiivistelmä

Tiivistelmä: Jos neuronin i sisääntulo on $[x_1, \dots, x_n]$, sen ulostulo z_i on

$$g(w_{i,1}x_1 + w_{i,2}x_2 + \dots + w_{i,n}x_n) = g(w_i \cdot x), w_i = [w_{i,1}, \dots, w_{i,n}].$$

- Jokaisella neuronilla on
 - vektori painoja $[w_1 \dots w_n]$, jotka kertovat mitä mieltä neuroni on syötteistä $x_1, \dots, x_n$
 - ja aktivointifunktio g joko korostaa tai latistaa neuronin mielipidettä.
- Neuronit muodostavat verkon M . (Merkintä: W_l = tason l painot matriisina.)

$$M(x) = g(W_L g(W_{L-1} g(\dots g(W_1 x))))$$

Neuroverkon tiivistelmä

Tiivistelmä: Jos neuronin i sisääntulo on $[x_1, \dots, x_n]$, sen ulostulo z_i on

$$g(w_{i,1}x_1 + w_{i,2}x_2 + \dots + w_{i,n}x_n) = g(w_i \cdot x), w_i = [w_{i,1}, \dots, w_{i,n}].$$

- Jokaisella neuronilla on
 - vektori painoja $[w_1 \dots w_n]$, jotka kertovat mitä mieltä neuroni on syötteistä $x_1, \dots, x_n$
 - ja aktivointifunktio g joko korostaa tai latistaa neuronin mielipidettä.
- Neuronit muodostavat verkon M . (Merkintä: W_l = tason l painot matriisina.)

$$M(x) = g(W_L g(W_{L-1} g(\dots g(W_1 x))))$$

- Jos parametrit $W_1, \dots, W_L$ on valittu oikein, niin viimeinen ulostulo $M(x) = y = \text{"kissa"}$ kun ensimmäiselle tasolle annetaan kuva jossa on kissa.

Neuroverkon tiivistelmä

Tiivistelmä: Jos neuronin i sisääntulo on $[x_1, \dots, x_n]$, sen ulostulo z_i on

$$g(w_{i,1}x_1 + w_{i,2}x_2 + \dots + w_{i,n}x_n) = g(w_i \cdot x), w_i = [w_{i,1}, \dots, w_{i,n}].$$

- Jokaisella neuronilla on
 - vektori painoja $[w_1 \dots w_n]$, jotka kertovat mitä mieltä neuroni on syötteistä $x_1, \dots, x_n$
 - ja aktivointifunktio g joko korostaa tai latistaa neuronin mielipidettä.
- Neuronit muodostavat verkon M . (Merkintä: W_l = tason l painot matriisina.)

$$M(x) = g(W_L g(W_{L-1} g(\dots g(W_1 x))))$$

- Jos parametrit $W_1, \dots, W_L$ on valittu oikein, niin viimeinen ulostulo $M(x) = y = \text{"kissa"}$ kun ensimmäiselle tasolle annetaan kuva jossa on kissa.

Eli miten niiden painojen oppiminen tapahtuu?

Sisältö

1 Johdanto

2 Taustaa

- Koneoppiminen
- Kuvat

3 Neuroverkon perusajatus

4 **Backpropagation eli "takaisinleviämisalgoritmi"**

5 Lopetus

Neuroverkon ulostulo

- Muistutus: neuroverkko M syö sisääntulot x , tekee asioita (kullakin tasolla $l = 1 \dots L$ parametrit W_l), ja sylkee ulostulon $M(x) = y = \text{"kissa"}$.

Neuroverkon ulostulo

- Muistutus: neuroverkko M syö sisääntulot x , tekee asioita (kullakin tasolla $l = 1 \dots L$ parametrit W_l), ja sylkee ulostulon $M(x) = y = \text{"kissa"}$.
- Oikeastaan y on vektori todennäköisyyksiä $y = [0.99, 0.01, 0.0, \dots]$.

Neuroverkon ulostulo

- Muistutus: neuroverkko M syö sisääntulot x , tekee asioita (kullakin tasolla $l = 1 \dots L$ parametrit W_l), ja sylkee ulostulon $M(x) = y = \text{"kissa"}$.
- Oikeastaan y on vektori todennäköisyyksiä $y = [0.99, 0.01, 0.0, \dots]$.
...joiden merkitys on sovittu:



$\rightarrow$		y
$M_w(x) = y$	kissa	0.99
	koira	0.01
	laiskiainen	0.0
	...	..

Neuroverkon ulostulo ja virhe

- ... siis jos painot W oikein. Jos painot eivät ole oikein vastaus on väärin:

Neuroverkon ulostulo ja virhe

- ... siis jos painot W oikein. Jos painot eivät ole oikein vastaus on väärin:



$$\rightarrow$$
$$M_W(x) = y$$

	y
kissa	0.0865
koira	0.11234
laiskiainen	0.349
...	(kohinaa)

Neuroverkon ulostulo ja virhe

- ... siis jos painot W oikein. Jos painot eivät ole oikein vastaus on väärin:



$$\rightarrow$$
$$M_W(x) = y$$

	y
kissa	0.0865
koira	0.11234
laiskiainen	0.349
...	(kohinaa)

Neuroverkon ulostulo ja virhe (ii)

Kertaus:

- Sarja kuvia eläimistä joille tiedämme oikeat vektorit = opetusdata = y_{opetus} .

Neuroverkon ulostulo ja virhe (ii)

Kertaus:

- Sarja kuvia eläimistä joille tiedämme oikeat vektorit = opetusdata = y_{opetus} .
- Valitaan jokin sopiva virhefunktio L jolle syötetään sekä neuroverkon ennuste y ja y_{opetus} . Jos $y = y_{\text{opetus}}$ niin $L = 0$.

Neuroverkon ulostulo ja virhe (ii)

Kertaus:

- Sarja kuvia eläimistä joille tiedämme oikeat vektorit = opetusdata = y_{opetus} .
- Valitaan jokin sopiva virhefunktio L jolle syötetään sekä neuroverkon ennuste y ja y_{opetus} . Jos $y = y_{\text{opetus}}$ niin $L = 0$.
- Kuva $x \rightarrow$ verkko antaa ulostulon $M_W(x) = y \rightarrow$ lasketaan $L(y, y_{\text{opetus}})$.


Neuroverkon ulostulo ja virhe (ii)

Kertaus:

- Sarja kuvia eläimistä joille tiedämme oikeat vektorit = opetusdata = y_{opetus} .
- Valitaan jokin sopiva virhefunktio L jolle syötetään sekä neuroverkon ennuste y ja y_{opetus} . Jos $y = y_{\text{opetus}}$ niin $L = 0$.
- Kuva $x \rightarrow$ verkko antaa ulostulon $M_W(x) = y \rightarrow$ lasketaan $L(y, y_{\text{opetus}})$.
- Haluamme löytää parametrit $W = [w_{1,1}, \dots, w_{h,k}]$ joilla virhe on pieni kaikille kuville.



Haluamme löytää parametrit joilla virhe on pieni

■ Arvataan?





Haluamme löytää parametrit joilla virhe on pieni

■ Arvataan?



Haluamme löytää parametrit joilla virhe on pieni



■ Arvataan?



■ Neuroverkoissa parametreja $\approx h \times k$,

Haluamme löytää parametrit joilla virhe on pieni

■ Arvataan?



- Neuroverkoissa parametreja $\approx h \times k$,
 - h = neuroverkon syvyys,
 - k = alemman tason neuronit. $h \times k$ = **paljon**.

Hengähdystauko.




Hengähdystauko.




DERIVAATTA.


Yksiulotteinen virhemaasto ja derivaatta



Yksiulotteinen virhemaasto ja derivaatta



Kaksiulotteinen virhemaasto ja gradientti



Neuroverkon virhemaasto ja gradientti

■ Virhefunktio

$$L = L(y, y_{\text{opetus}}) = L(M(x_{\text{opetus}}), y_{\text{opetus}})$$

Neuroverkon virhemaasto ja gradientti

- Virhefunktio

$$L = L(y, y_{\text{opetus}}) = L(M(x_{\text{opetus}}), y_{\text{opetus}})$$

- Derivaatta $\frac{dL}{dw_{h,i}}$. Gradientti $\left[\frac{\partial L}{\partial w_{h,1}}, \dots, \frac{\partial L}{\partial w_{h,k}} \right] = \nabla_{w_h} L$.

Neuroverkon virhemaasto ja gradientti

- Virhefunktio

$$L = L(y, y_{\text{opetus}}) = L(M(x_{\text{opetus}}), y_{\text{opetus}})$$

- Derivaatta $\frac{dL}{dw_{h,i}}$. Gradientti $\left[\frac{\partial L}{\partial w_{h,1}}, \dots, \frac{\partial L}{\partial w_{h,k}} \right] = \nabla_{w_h} L$.

- Neuroverkon funktio muoto tunnetaan:

$$y = M(x) = g(W_L g(W_{L-1} g(\dots g(W_1 x))))$$

Neuroverkon virhemaasto ja gradientti

- Virhefunktio

$$L = L(y, y_{\text{opetus}}) = L(M(x_{\text{opetus}}), y_{\text{opetus}})$$

- Derivaatta $\frac{dL}{dw_{h,i}}$. Gradientti $\left[\frac{\partial L}{\partial w_{h,1}}, \dots, \frac{\partial L}{\partial w_{h,k}} \right] = \nabla_{w_h} L$.

- Neuroverkon funktio muoto tunnetaan:

$$y = M(x) = g(W_L g(W_{L-1} g(\dots g(W_1 x))))$$

- joten $\nabla_{w_h} L$ voidaan laskea jokaiselle tasolle h .

Virheen takaisinleviämisalgoritmi

- Backpropagation eli "takaisinleviäminen" on tehokas tapa laskea gradientit. Miten?

Virheen takaisinleviämisalgoritmi

- Backpropagation eli "takaisinleviäminen" on tehokas tapa laskea gradientit. Miten?
- Intuitio (lukiolaisille): Ketjusääntö! $\frac{d}{dx} f(h(x)) = f'(h(x))h'(x)$.

Virheen takaisinleviämisalgoritmi

- Backpropagation eli "takaisinleviäminen" on tehokas tapa laskea gradientit. Miten?
- Intuitio (lukiolaisille): Ketjusääntö! $\frac{d}{dx} f(h(x)) = f'(h(x))h'(x)$.
- Sovellettuna neuroverkon virheeseen $L(M(x), y)$:

Virheen takaisinleviämisalgoritmi

- Backpropagation eli "takaisinleviäminen" on tehokas tapa laskea gradientit. Miten?
- Intuitio (lukiolaisille): Ketjusääntö! $\frac{d}{dx} f(h(x)) = f'(h(x))h'(x)$.
- Sovellettuna neuroverkon virheeseen $L(M(x), y)$:

$$\frac{d}{dw_{ij}} L(M(x), y)$$

Virheen takaisinleviämisalgoritmi

- Backpropagation eli "takaisinleviäminen" on tehokas tapa laskea gradientit. Miten?
- Intuitio (lukiolaisille): Ketjusääntö! $\frac{d}{dx} f(h(x)) = f'(h(x))h'(x)$.
- Sovellettuna neuroverkon virheeseen $L(M(x), y)$:

$$\frac{d}{dw_{ij}} L(M(x), y) = \frac{d}{dw_{ij}} L(g(W_i g(\dots)), y)$$

Virheen takaisinleviämisalgoritmi

- Backpropagation eli "takaisinleviäminen" on tehokas tapa laskea gradientit. Miten?
- Intuitio (lukiolaisille): Ketjusääntö! $\frac{d}{dx} f(h(x)) = f'(h(x))h'(x)$.
- Sovellettuna neuroverkon virheeseen $L(M(x), y)$:

$$\begin{aligned}\frac{d}{dw_{ij}} L(M(x), y) &= \frac{d}{dw_{ij}} L(g(W_I g(\dots)), y) \\ &= L'(g(W_I g(\dots)), y) \frac{d}{dw_{ij}} g(W_I g(\dots))\end{aligned}$$

Virheen takaisinleviämisalgoritmi

- Backpropagation eli "takaisinleviäminen" on tehokas tapa laskea gradientit. Miten?
- Intuitio (lukiolaisille): Ketjusääntö! $\frac{d}{dx} f(h(x)) = f'(h(x))h'(x)$.
- Sovellettuna neuroverkon virheeseen $L(M(x), y)$:

$$\begin{aligned}\frac{d}{dw_{ij}} L(M(x), y) &= \frac{d}{dw_{ij}} L(g(W_I g(\dots)), y) \\ &= L'(g(W_I g(\dots)), y) \frac{d}{dw_{ij}} g(W_I g(\dots)) \\ &= L'(g(W_I g(\dots)), y) g' \left(W_I g(\dots) \frac{d}{dw_{ij}} W_I g(\dots) \right)\end{aligned}$$

Virheen takaisinleviämisalgoritmi

- Backpropagation eli "takaisinleviäminen" on tehokas tapa laskea gradientit. Miten?
- Intuitio (lukiolaisille): Ketjusääntö! $\frac{d}{dx} f(h(x)) = f'(h(x))h'(x)$.
- Sovelletuna neuroverkon virheeseen $L(M(x), y)$:

$$\begin{aligned}\frac{d}{dw_{ij}} L(M(x), y) &= \frac{d}{dw_{ij}} L(g(W_I g(\dots)), y) \\ &= L'(g(W_I g(\dots)), y) \frac{d}{dw_{ij}} g(W_I g(\dots)) \\ &= L'(g(W_I g(\dots)), y) g' \left(W_I g(\dots) \frac{d}{dw_{ij}} W_I g(\dots) \right) \\ &= L'(g(W_I g(\dots)), y) g' \left(W_I g(\dots) W_I \frac{d}{dw_{ij}} g(\dots) \right)\end{aligned}$$

Virheen takaisinleviämisalgoritmi

- Backpropagation eli "takaisinleviäminen" on tehokas tapa laskea gradientit. Miten?
- Intuitio (lukiolaisille): Ketjusääntö! $\frac{d}{dx} f(h(x)) = f'(h(x))h'(x)$.
- Sovelletuna neuroverkon virheeseen $L(M(x), y)$:

$$\begin{aligned}\frac{d}{dw_{ij}} L(M(x), y) &= \frac{d}{dw_{ij}} L(g(W_I g(\dots)), y) \\ &= L'(g(W_I g(\dots)), y) \frac{d}{dw_{ij}} g(W_I g(\dots)) \\ &= L'(g(W_I g(\dots)), y) g' \left(W_I g(\dots) \frac{d}{dw_{ij}} W_I g(\dots) \right) \\ &= L'(g(W_I g(\dots)), y) g' \left(W_I g(\dots) W_I \frac{d}{dw_{ij}} g(\dots) \right)\end{aligned}$$

ja jatkuu ja jatkuu

Mitäh?

Mitäh?

- Tämä *on* esityksen vaikein asia.
- $L'(g(W_I g(\dots), y) g' \left(W_I g(\dots) W_I \frac{d}{dw_{ij}} g(\dots) \right))$

Mitäh?

- Tämä *on* esityksen vaikein asia.
- $L'(g(W_I g(\dots), y) g' \left(W_I g(\dots) W_I \frac{d}{dw_{ij}} g(\dots) \right))$
- Sisältää
 - 1 termejä jotka on jo laskettu kun menttiin verkossa eteenpäin,

Mitäh?

- Tämä *on* esityksen vaikein asia.
- $L'(g(W_I g(\dots), y) g' \left(W_I g(\dots) W_I \frac{d}{dw_{ij}} g(\dots) \right))$
- Sisältää
 - 1 termejä jotka on jo laskettu kun mentiin verkossa eteenpäin,
 - 2 funktioiden L ja g derivaattoja,

Mitäh?

- Tämä *on* esityksen vaikein asia.
- $L'(g(W_l g(\dots), y) g' \left(W_l g(\dots) W_l \frac{d}{dw_{ij}} g(\dots) \right))$
- Sisältää
 - 1 termejä jotka on jo laskettu kun mentiin verkossa eteenpäin,
 - 2 funktioiden L ja g derivaattoja,
 - 3 toistuvaa rakennetta, jossa tason l derivaatat riippuvat ainoastaan edessä olevien tasojen $l + 1, l + 2, \dots, L$ termeistä.

Mitäh?

- Tämä *on* esityksen vaikein asia.
- $L'(g(W_l g(\dots), y) g' \left(W_l g(\dots) W_l \frac{d}{dw_{ij}} g(\dots) \right))$
- Sisältää
 - 1 termejä jotka on jo laskettu kun mentiin verkossa eteenpäin,
 - 2 funktioiden L ja g derivaattoja,
 - 3 toistuvaa rakennetta, jossa tason l derivaatat riippuvat ainoastaan edessä olevien tasojen $l + 1, l + 2, \dots, L$ termeistä.
- ...??? PROFIT:

Mitäh?

- Tämä *on* esityksen vaikein asia.
- $L'(g(W_l g(\dots), y) g' \left(W_l g(\dots) W_l \frac{d}{dw_{ij}} g(\dots) \right))$
- Sisältää
 - 1 termejä jotka on jo laskettu kun mentiin verkossa eteenpäin,
 - 2 funktioiden L ja g derivaattoja,
 - 3 toistuvaa rakennetta, jossa tason l derivaatat riippuvat ainoastaan edessä olevien tasojen $l + 1, l + 2, \dots, L$ termeistä.
- ...??? PROFIT:
- Lasku voidaan tehdä tehokkaasti menemällä *taaksepäin*.

Takaisin leviäminen

- Neuroverkon ulostulo $M(x)$ ja virhe $L(M(x), y)$ lasketaan ensin taso tasolta **eteenpäin** (*forward pass*)

Takaisin leviäminen


- Neuroverkon ulostulo $M(x)$ ja virhe $L(M(x), y)$ lasketaan ensin taso tasolta **eteenpäin** (*forward pass*)
- ...jos laskujen välivaiheet tallennetaan, *niin* jokainen $\frac{d}{dw_{ij}} L(\dots)$ saadaan menemällä lähes samat askeleet **taaksepäin** (*backpropagation*, "takaisin leviäminen")

Takaisin leviäminen

- Neuroverkon ulostulo $M(x)$ ja virhe $L(M(x), y)$ lasketaan ensin taso tasolta **eteenpäin** (*forward pass*)
- ... jos laskujen välivaiheet tallennetaan, *niin* jokainen $\frac{d}{dw_{ij}}L(\dots)$ saadaan menemällä lähes samat askeleet **taaksepäin** (*backpropagation*, "takaisin leviäminen")
 - (ja tekemällä muutamia yksinkertaisia derivointilaskuja g' ja L').

Takaisin leviäminen

- Neuroverkon ulostulo $M(x)$ ja virhe $L(M(x), y)$ lasketaan ensin taso tasolta **eteenpäin** (*forward pass*)
- ... jos laskujen välivaiheet tallennetaan, *niin* jokainen $\frac{d}{dw_{ij}} L(\dots)$ saadaan menemällä lähes samat askeleet **taaksepäin** (*backpropagation*, "takaisin leviäminen")
 - (ja tekemällä muutamia yksinkertaisia derivointilaskuja g' ja L').



Mitäh??!?!?!?

Mitäh??!?!?!?

Uusi hengähdystauko.



Tiivistelmä:

- 1 Neuroverkko koostuu tasoista neuroneita.

Tiivistelmä:

- 1 Neuroverkko koostuu tasoista neuroneita.
- 2 Huonoilla parametreilla neuroverkon ulostulot $M(x) \rightarrow$ suuri virhe $L(M(x), y_{\text{opetus}})$.

Tiivistelmä:

- 1 Neuroverkko koostuu tasoista neuroneita.
- 2 Huonoilla parametreilla neuroverkon ulostulot $M(x) \rightarrow$ suuri virhe $L(M(x), y_{\text{opetus}})$.
- 3 Gradientti $\nabla L_{w_h} = \left[\frac{\partial L}{\partial w_{h,1}}, \dots, \frac{\partial L}{\partial w_{h,k}} \right]$ kertoo parhaan arvauksen mistä etsiä uusia parametrin arvoja tason h parametreille $w_{h,j}$.

Tiivistelmä:

- 1 Neuroverkko koostuu tasoista neuroneita.
- 2 Huonoilla parametreilla neuroverkon ulostulot $M(x) \rightarrow$ suuri virhe $L(M(x), y_{\text{opetus}})$.
- 3 Gradientti $\nabla L_{w_h} = \left[\frac{\partial L}{\partial w_{h,1}}, \dots, \frac{\partial L}{\partial w_{h,k}} \right]$ kertoo parhaan arvauksen mistä etsiä uusia parametrin arvoja tason h parametreille $w_{h,j}$.
- 4 Backpropagation-algoritmi on tehokas tapa laskea gradientti kaikille $w_{i,j}$ etenemällä taso kerrallaan takaisinpäin.

Tiivistelmä:

- 1 Neuroverkko koostuu tasoista neuroneita.
- 2 Huonoilla parametreilla neuroverkon ulostulot $M(x) \rightarrow$ suuri virhe $L(M(x), y_{\text{opetus}})$.
- 3 Gradientti $\nabla L_{w_h} = \left[\frac{\partial L}{\partial w_{h,1}}, \dots, \frac{\partial L}{\partial w_{h,k}} \right]$ kertoo parhaan arvauksen mistä etsiä uusia parametrin arvoja tason h parametreille $w_{h,j}$.
- 4 Backpropagation-algoritmi on tehokas tapa laskea gradientti kaikille $w_{i,j}$ etenemällä taso kerrallaan takaisinpäin.
- 5 Kun gradientti on laskettu, parametreja W siirretään pieni askel ∇L :n osoittamaan suuntaan.

Tiivistelmä:

- 1 Neuroverkko koostuu tasoista neuroneita.
- 2 Huonoilla parametreilla neuroverkon ulostulot $M(x) \rightarrow$ suuri virhe $L(M(x), y_{\text{opetus}})$.
- 3 Gradientti $\nabla L_{w_h} = \left[\frac{\partial L}{\partial w_{h,1}}, \dots, \frac{\partial L}{\partial w_{h,k}} \right]$ kertoo parhaan arvauksen mistä etsiä uusia parametrin arvoja tason h parametreille $w_{h,j}$.
- 4 Backpropagation-algoritmi on tehokas tapa laskea gradientti kaikille $w_{i,j}$ etenemällä taso kerrallaan takaisinpäin.
- 5 Kun gradientti on laskettu, parametreja W siirretään pieni askel ∇L :n osoittamaan suuntaan.
- 6 Algoritmi toistetaan uudestaan kunnes virhe pieni.

Tiivistelmä:

- 1 Neuroverkko koostuu tasoista neuroneita.
- 2 Huonoilla parametreilla neuroverkon ulostulot $M(x) \rightarrow$ suuri virhe $L(M(x), y_{\text{opetus}})$.
- 3 Gradientti $\nabla L_{w_h} = \left[\frac{\partial L}{\partial w_{h,1}}, \dots, \frac{\partial L}{\partial w_{h,k}} \right]$ kertoo parhaan arvauksen mistä etsiä uusia parametrin arvoja tason h parametreille $w_{h,j}$.
- 4 Backpropagation-algoritmi on tehokas tapa laskea gradientti kaikille $w_{i,j}$ etenemällä taso kerrallaan takaisinpäin.
- 5 Kun gradientti on laskettu, parametreja W siirretään pieni askel ∇L :n osoittamaan suuntaan.
- 6 Algoritmi toistetaan uudestaan kunnes virhe pieni.

TLDR: Neuroverkko opetetaan laittamalla tietokone laskemaan paljon isoja derivaattalaskuja.

Sisältö

1 Johdanto

2 Taustaa

- Koneoppiminen
- Kuvat

3 Neuroverkon perusajatus

4 Backpropagation eli "takaisinleviämisalgoritmi"

5 Lopetus

Yksityiskohtia joita tässä ei käsitelty

- Paljon teknisiä yksityiskohtia: millainen on verkon rakenne, kuinka pitkiä askelia otetaan, jne.
- Jyrkimmän pudotuksen suunnan valitseminen ei välttämättä johda parhaimpaan mahdolliseen lopputulokseen. Satunnaisuutta syntyy vaihtelemalla harjoituskuvia askeleiden välissä.
- Neuroverkon harjoittaminen ei muutenkaan ole käytännössä suoraviivaista.
- ...

