

## 『深層学習』第1,2刷正誤表

この度は、標記書籍をお買い求めいただき誠にありがとうございました。

標記書籍に誤りがありました。訂正し、深くお詫び申し上げます。

ページ数	位置	誤	正
1	下から 2行目 ～	入力層から逆に伝播させ、各層の重みの勾配を計算するという方法です。この計算の際、入力層から離れた	出力層から逆に伝播させ、各層の重みの勾配を計算するという方法です。この計算の際、出力層から離れた
2	2行目	いわゆる勾配消失問題という呼ばれる現象が	いわゆる勾配消失問題と呼ばれる現象が
3	8行目	異なる原理に基づいて行われるもの、	異なる原理に基づいて行われるもの、
11	3行目	retified linear function	rectified linear function
15	下から 1行目	正接双曲線関数	双曲線正接関数
18	5～6 行目	その場合は出力層はユニット2つとなり、	その場合は出力層はユニットが2つとなり、
34	2行目	次に平均を差し引いた後のデータの各成分 $x_{ni}$ を、その標準偏差	またデータの各成分を平均を差し引いた上で、標準偏差
35	下から 5行目	model avaraging	model averaging
37	下から 7行目	$\Delta \mathbf{w}^{(t-1)} \equiv \mathbf{w}^{(t-1)} - \mathbf{w}^{(t-2)}$	$\Delta \mathbf{w}^{(t-1)} \equiv \mathbf{w}^{(t)} - \mathbf{w}^{(t-1)}$
39	19行目	$\sigma = \sigma_u / M^{-2}$	$\sigma = \sigma_u / M^{1/2}$
49	10行目	$E_n = d \log y + (1-d) \log(1-y)$	$E_n = -d \log y - (1-d) \log(1-y)$
49	13行目	$\begin{aligned} \delta^{(L)} &= \frac{d}{y} \cdot \frac{dy}{du} + \frac{1-d}{1-y} \left( -\frac{dy}{du} \right) \\ &= d(1-y) - (1-d)y = d - y \end{aligned}$	$\begin{aligned} \delta^{(L)} &= -\frac{d}{y} \cdot \frac{dy}{du} - \frac{1-d}{1-y} \left( -\frac{dy}{du} \right) \\ &= -d(1-y) + (1-d)y = y - d \end{aligned}$
50	下から 7行目	順伝播計算は、 $\mathbf{U}^{(1)} \equiv \mathbf{X}$	順伝播計算は、 $\mathbf{Z}^{(1)} \equiv \mathbf{X}$
51	11行目	逆伝播計算は $\Delta^{(L)} = \mathbf{D} - \mathbf{Y}$ とした後、	逆伝播計算は $\Delta^{(L)} = \mathbf{Y} - \mathbf{D}$ とした後、
51	下から 4行目	$E = \sum_{n=1}^N E_n(\mathbf{W})$	$E = \sum_{n=1}^N E_n(\mathbf{W})/N$
52	3行目	$E = \sum_{n=1}^N E_n(\mathbf{W})$	$E = \sum_{n=1}^N E_n(\mathbf{W})/N$
52	2番目の式	$\partial \mathbf{b}^{(l)} = \frac{1}{N} \Delta^{(l)} \mathbf{1}_N^\top$	$\partial \mathbf{b}^{(l)} = \frac{1}{N} \Delta^{(l)} \mathbf{1}_N$
52	下から 1行目	$\frac{\partial E}{\partial w_{ji}^{(l)}} = \frac{E(\dots, w_{ij}^{(l)} + \varepsilon, \dots) - E(\dots, w_{ij}^{(l)}, \dots)}{\varepsilon}$	$\frac{\partial E}{\partial w_{ji}^{(l)}} = \frac{E(\dots, w_{ji}^{(l)} + \varepsilon, \dots) - E(\dots, w_{ji}^{(l)}, \dots)}{\varepsilon}$
53	1行目	ここで $E(\dots, w_{ij}^{(l)} + \varepsilon, \dots)$ という表記は、 $E(\mathbf{w})$ の変数 $\mathbf{w}$ のうち $w_{ij}^{(l)}$ だけに $\varepsilon$ を加算するという意味です。 $\varepsilon \rightarrow 0$ の極限をとると、上の式は偏微分 $\partial E(\mathbf{w}) / \partial w_{ij}^{(l)}$ の定義に一致します。	ここで $E(\dots, w_{ji}^{(l)} + \varepsilon, \dots)$ という表記は、 $E(\mathbf{w})$ の変数 $\mathbf{w}$ のうち $w_{ji}^{(l)}$ だけに $\varepsilon$ を加算するという意味です。 $\varepsilon \rightarrow 0$ の極限をとると、上の式は偏微分 $\partial E(\mathbf{w}) / \partial w_{ji}^{(l)}$ の定義に一致します。

62	10 行目	任意の正則な $D_y \times D_y$ 行列 $\mathbf{Q}$ に対し,	任意の $D_y \times D_y$ の直交行列 $\mathbf{Q}$ に対し,
63	1 行目	$\forall (D_y \leq D_x)$ 場合であっても,	$\forall (D_y > D_x)$ 場合であっても,
65	12 行目	$\frac{\partial \hat{\rho}_j}{\partial u_j^{(l)}} = f'(u_j^{(l)})$	$\frac{\partial \hat{\rho}_j}{\partial u_j^{(l)}} = \frac{1}{N} f'(u_j^{(l)})$
65	式 (5.4)	$\delta_j^{(l)} = \left\{ \cdots + \left( -\frac{\rho}{\hat{\rho}_j} + \frac{1-\rho}{1-\hat{\rho}_j} \right) \right\} f'(u_j^{(l)})$	$\delta_j^{(l)} = \left\{ \cdots + \beta \left( -\frac{\rho}{\hat{\rho}_j} + \frac{1-\rho}{1-\hat{\rho}_j} \right) \right\} f'(u_j^{(l)})$
65	脚注	*6 2 層のネットワークに限れば、スパース正則化の対象となる中間層より下に重みを持つ層はないので、パラメータの更新式を修正するだけで済みます。	削除
85	図 6.5 図 6.6		
95	7 行目	$\bar{x}_{ij} = \frac{1}{K} \sum_{k=0}^{K-1} \sum_{(p,q) \in P_{ij}} w_{pq} x_{i+p,j+q,k}$	$\bar{x}_{ij} = \frac{1}{K} \sum_{k=0}^{K-1} \sum_{(p,q) \in P_{ij}} w_{pqk} x_{i+p,j+q,k}$
96	1 番目 2 番目 の式	$\mathbf{u}^{(l)} = \mathbf{W}^{(l)} \mathbf{u}^{(l-1)} + \mathbf{b}^{(l)}$ $\mathbf{z}^{(l)} = f^{(l)}(\mathbf{u})$	$\mathbf{u}^{(l)} = \mathbf{W}^{(l)} \mathbf{z}^{(l-1)} + \mathbf{b}^{(l)}$ $\mathbf{z}^{(l)} = f^{(l)}(\mathbf{u}^{(l)})$
99	10 行目	約 200,000 ミニバッチ、すなわち $2 \text{万} \times 128 / (\text{総学習サンプル} = \text{数百万}) = \text{約 } 25 \text{ エポック}$ ほど	約 200,000 ミニバッチ、すなわち $20 \text{万} \times 128 / (\text{総学習サンプル} = \text{約百万}) = \text{約 } 25 \text{ エポック}$ ほど
114	13 行目	ネットワーク内部にある帰路に	ネットワーク内部にある帰路に
114	図 7.3 (a)		
114	図 7.3 (b)		
115	式 (7.1)	$E(\mathbf{w}) = \sum_n \dots$	$E(\mathbf{w}) = - \sum_n \dots$
116	10 行目	をそれぞれ $\mathbf{v}^t = (v_j^t)$ と $\mathbf{y}^t = (y_j^t)$ のように	をそれぞれ $\mathbf{v}^t = (v_k^t)$ と $\mathbf{y}^t = (y_k^t)$ のように
119	式 (7.7) 第 2 項	$\sum_{j'} w_{jj'} \delta_{j'}^{t+1}$	$\sum_{j'} w_{j'j} \delta_{j'}^{t+1}$
120	1 行目	$\frac{\partial E}{\partial w_{jj'}} = \sum_{t=1}^T \frac{\partial E}{\partial u_j^t} \frac{\partial u_j^t}{\partial w_{jj'}} = \sum_{t=1}^T \delta_j^t z_j^{t-1}$	$\frac{\partial E}{\partial w_{jj'}} = \sum_{t=1}^T \frac{\partial E}{\partial u_j^t} \frac{\partial u_j^t}{\partial w_{jj'}} = \sum_{t=1}^T \delta_j^t z_{j'}^{t-1}$

120	3行目	$\frac{\partial E}{\partial w_{kj}^{out}} = \sum_{t=1}^T \frac{\partial E}{\partial v_k^t} \frac{\partial v_k^t}{\partial w_{kj}^{out}} = \sum_{t=1}^T \delta_j^t z_j^t$	$\frac{\partial E}{\partial w_{kj}^{out}} = \sum_{t=1}^T \frac{\partial E}{\partial v_k^t} \frac{\partial v_k^t}{\partial w_{kj}^{out}} = \sum_{t=1}^T \delta_k^{out,t} z_j^t$
122	下から 2行目	内部のメモリセルは	内部のメモリセル（図 7.7a）は
123	2,3, 4,6式	$u_j^t = \sum_j w_{ji}^{in} x_j^t + \sum_{j'} w_{jj'} z_j^{t-1}$ $\dots = f \left( \sum_j w_{ji}^{F,in} x_j^t + \sum_{j'} w_{jj'}^F z_j^{t-1} + s_j^{t-1} \right)$ $\dots = f \left( \sum_j w_{ji}^{I,in} x_j^t + \sum_{j'} w_{jj'}^I z_j^{t-1} + s_j^{t-1} \right)$ $\dots = f \left( \sum_j w_{ji}^{O,in} x_j^t + \sum_{j'} w_{jj'}^O z_j^{t-1} + s_j^t \right)$	$u_j^t = \sum_j w_{ji}^{in} x_i^t + \sum_{j'} w_{jj'} z_{j'}^{t-1}$ $\dots = f \left( \sum_i w_{ji}^{F,in} x_i^t + \sum_{j'} w_{jj'}^F z_{j'}^{t-1} + w_j^F s_j^{t-1} \right)$ $\dots = f \left( \sum_i w_{ji}^{I,in} x_i^t + \sum_{j'} w_{jj'}^I z_{j'}^{t-1} + w_j^I s_j^{t-1} \right)$ $\dots = f \left( \sum_i w_{ji}^{O,in} x_i^t + \sum_{j'} w_{jj'}^O z_{j'}^{t-1} + w_j^O s_j^t \right)$
123	10行目 追加	$w_j^F, w_j^I$ はそれぞれ、メモリセルから忘却ゲートと入力ゲートの値を決めるユニット（図 7.7 の f と c)への結合の $s_j^{t-1}$ の重みです。これらは下で扱う出力ゲートに関する同様の結合とあわせて、「のぞき穴 (peephole)」結合とも呼ばれています。	
	上の 123 ページ の訂正 および 追加に ついて の備考	最初に提案された LSTM ( $w_j^F = w_j^I = w_j^O = 0$ に相当、文献 [30]) では、出力ゲートが閉じていると各ゲートはセルの状態を知ることができず、タスクによってはこれが問題となる場合がありますが、「のぞき穴」結合はこれを解決します（参考：F.A. Gers, N. N. Schraudolph, and J. Schmidhuber. Learning Precise Timing with LSTM Recurrent Networks. <i>Journal of Machine Learning Research</i> , 3:115-143, 2002）。	
124	12行目	$u_k^{out,t} = \sum_j w_{kj} z_j^t$ であり, $\frac{\partial u_k^{out,t}}{\partial u_j^{O,t}} = w_{kj} f'(u_j^{O,t}) f(s_j^t)$	$v_k^t = \sum_j w_{kj}^{out} z_j^t$ であり, $\frac{\partial v_k^t}{\partial u_j^{O,t}} = w_{kj}^{out} f'(u_j^{O,t}) f(s_j^t)$
		となります。もう一つの伝播先の、次時刻のメモリユニットへの総入力についても同様に計算でき、したがって $g_j^{O,t}$ を出力するユニットのデルタは	となります。もう一つの伝播先の、次時刻のメモリユニットへの総入力についても同様に計算でき、したがって $g_j^{O,t}$ を出力するユニットのデルタは
		$\epsilon_j^t = \sum_k w_{kj} \delta_k^{out,t} + \sum_{j'} w_{j'j} \delta_{j'}^{t+1}$	$\epsilon_j^t = \sum_k w_{kj}^{out} \delta_k^{out,t} + \sum_{j'} w_{j'j} \delta_{j'}^{t+1}$
125	最初 の式	$\delta_j^{cell,t} = \delta_j^t + g_j^{F,t+1} \phi_j^{t+1} + \delta_j^{I,t+1} + \delta_j^{F,t+1} + \delta_j^{O,t}$	$\delta_j^{cell,t} = \delta_j^t + g_j^{F,t+1} \delta_j^{cell,t+1} + w_j^I \delta_j^{I,t+1} + w_j^F \delta_j^{F,t+1} + w_j^O \delta_j^{O,t}$
127	9行目	'ccba'	'cbab'
129	10行目 11行目	$p(\mathbf{l} \mathbf{X}) = \alpha_{ L' ,T} + \alpha_{ L' +1,T}$ のように計算できます（図 7.8 にもあるように、有効なパスはいつも、最後の時刻 $t = T$ では $ L' $ か $ L' +1$ のいずれかに到達するはずであることから）。	$p(\mathbf{l} \mathbf{X}) = \alpha_{ \mathbf{l}' ,T} + \alpha_{ \mathbf{l}' -1,T}$ のように計算できます（図 7.8 にもあるように、有効なパスはいつも、最後の時刻 $t = T$ では $ \mathbf{l}' $ か $ \mathbf{l}' -1$ のいずれかに到達するはずであることから）。
129	最後 の式	$-\sum_n \log p(\mathbf{d} \mathbf{X})$	$-\sum_n \log p(\mathbf{d}_n \mathbf{X}_n)$

130	下から 4行目	$\hat{\mathbf{I}} = \mathcal{B}(\boldsymbol{\pi})$ とする方法です.	$\hat{\mathbf{I}} = \mathcal{B}(\hat{\boldsymbol{\pi}})$ とする方法です.
134	最初 の式	$\Phi(\mathbf{x}_n   \boldsymbol{\theta})$	$\Phi(\mathbf{x}_n, \boldsymbol{\theta})$
135	下から 4行目	例えば $M = 10$ では	例えば $M = 20$ では
139	2番目 の式	$L(\boldsymbol{\theta}) = \sum_{n=1}^N p(\mathbf{v}_n   \boldsymbol{\theta})$	$L(\boldsymbol{\theta}) = \prod_{n=1}^N p(\mathbf{v}_n   \boldsymbol{\theta})$
141	7行目	隠れ変数を指定したときの可視変数の条件付き 分布 $p(\mathbf{v}   \mathbf{h}, \boldsymbol{\theta})$ は、定義により	可視変数を指定したときの隠れ変数の条件付き 分布 $p(\mathbf{h}   \mathbf{v}, \boldsymbol{\theta})$ は、定義により
149	式 (8.20 c)	$\Delta b_j = \epsilon (h_j^{(0)} - p_j^{(T)})$	$\Delta b_j = \epsilon (p_j^{(0)} - p_j^{(T)})$
150	11行目 14行目	$\sigma(x - i + 5)$	$\sigma(x - i + 0.5)$
152	最初 の式	$p(\mathbf{h}^{(l)}   \mathbf{h}^{(l+1)}) = \prod_i \sigma(b_i^{(l)} + \sum_j w_{ij}^{(l+1)} h_j^{(l+1)})$	$p(h_i^{(l)} = 1   \mathbf{h}^{(l+1)}) = \sigma(b_i^{(l)} + \sum_j w_{ij}^{(l+1)} h_j^{(l+1)})$
152	2番目 の式	$p(h_j^{(l)}   \mathbf{h}^{(l-1)}) = \dots$	$p(h_j^{(l)} = 1   \mathbf{h}^{(l-1)}) = \dots$
153	式の 最後 の項	$-\sum_j \sum_k w_{ij}^{(2)} h_j^{(1)} h_j^{(2)}$	$-\sum_j \sum_k w_{jk}^{(2)} h_j^{(1)} h_k^{(2)}$
154	最後 の式	$p(v_i   \mathbf{h}^{(1)}) = \dots$	$p(v_i = 1   \mathbf{h}^{(1)}) = \dots$
155	最初 の式	$p(h_j^{(l)}   \mathbf{h}^{(l-1)}) = \dots$	$p(h_j^{(l)} = 1   \mathbf{h}^{(l-1)}) = \dots$