

Duboko učenje - Auditorne vježbe

Josip Šarić

Fakultet elektrotehnike i računarstva
Sveučilište u Zagrebu
Zagreb, Hrvatska

31. ožujka 2023.

Zadatak 1

Razmatramo klasifikacijski model s arhitekturom:

- konvolucijski sloj bez nadopunjavanja: 16 jezgara 5×5 , korak 1, aktivacija ReLU;
- sažimanje maksimumom 2×2 ;
- konvolucijski sloj bez nadopunjavanja: 32 jezgre 5×5 , korak 1, aktivacija ReLU;
- sažimanje maksimumom 2×2 ;
- pretvaranje u vektor;
- potpuno povezani sloj dimenzije 10 te aktivacija softmaks;

Na ulaz mreže dovodimo RGB slike veličine 28×28 piksela.

Zadatak 1

- 1 Napišite dimenzije ulaznih i izlaznih tenzora za svaki sloj.
- 2 Koliko ukupno parametara ima zadani model?
- 3 Procijenite memorijsko zauzeće u trenutku nakon izračuna gubitka unakrsne entropije. Postupak učenja zadanog modela provodimo s veličinom mini-grupe 8. Tip podataka je 32-bitni float. Pomoć: u memorijsko zauzeće ubrojiti sve u tome trenutku pohranjene tenzore i parametre modela.
- 4 Kolika su receptivna polja aktivacija u prvom sloju sažimanja odnosno aktivacija u potpuno povezanom sloju? Pomoć: receptivno polje računamo s obzirom na piksele ulazne slike.
- 5 Implementirajte model u Pytorchu.

Zadatak 1 - rješenje 1.1 i 1.2

Sloj	Dimenzija izlaza	Broj paramatera
Ulaz	$28 \times 28 \times 3$	0
Konv1 ($c_{out} = 16, k = 5 \times 5$)	$24 \times 24 \times 16$	$5 \cdot 5 \cdot 3 \cdot 16 + 16$
ReLU	$24 \times 24 \times 16$	0
Maxpool1 ($k = 2 \times 2$)	$12 \times 12 \times 16$	0
Konv2 ($c_{out} = 32, k = 5 \times 5$)	$8 \times 8 \times 32$	$5 \cdot 5 \cdot 16 \cdot 32 + 32$
ReLU	$8 \times 8 \times 32$	0
Maxpool2 ($k = 2 \times 2$)	$4 \times 4 \times 32$	0
Pretvaranje u vektor	512	0
Potpuno povezani (10)	10	$512 \cdot 10 + 10$
Softmaks	10	0
		19178

Zadatak 1 - rješenje 1.3

Parametri: $19178 \cdot 4 = 76712\mathbf{B}$

Zbog unatražnog prolaza moramo zapamtiti ulaze svakog sloja (osim pretvaranja u vektor) zasebno za svaki primjerak minigrupe:

$$8 \cdot (28 \cdot 28 \cdot 3 + 24 \cdot 24 \cdot 16 + 24 \cdot 24 \cdot 16 + 12 \cdot 12 \cdot 16 + 8 \cdot 8 \cdot 32 + 8 \cdot 8 \cdot 32 + 512 + 10 + 10) \cdot 4 = 886912\mathbf{B}$$

Ukupno: $963624\mathbf{B} \approx 0.9\mathbf{MiB}$

Zadatak 1 - rješenje 1.3

Parametri: $19178 \cdot 4 = 76712\mathbf{B}$

Zbog unatražnog prolaza moramo zapamtiti ulaze svakog sloja (osim pretvaranja u vektor) zasebno za svaki primjerak minigrupe:

$$8 \cdot (28 \cdot 28 \cdot 3 + 24 \cdot 24 \cdot 16 + 24 \cdot 24 \cdot 16 + 12 \cdot 12 \cdot 16 + 8 \cdot 8 \cdot 32 + 8 \cdot 8 \cdot 32 + 512 + 10 + 10) \cdot 4 = 886912\mathbf{B}$$

Ukupno: $963624\mathbf{B} \approx 0.9\mathbf{MiB}$

Zadatak 1 - rješenje 1.4

Receptivno polje prvog konvolucijskog sloja: 5×5

Receptivno polje prvog sloja sažimanja: 6×6

(jer vidi dvije susjedne aktivacije konvolucijskog sloja s korakom 1)

Receptivno polje potpuno povezanog sloja: cijela slika! (28×28)

Zadatak 1 - rješenje 1.5

```
class MyModel(nn.Module):  
def __init__(self):  
    super().__init__()   
    self.seq = nn.Sequential(  
        nn.Conv2d(3, 16, 5),  
        nn.ReLU(),  
        nn.MaxPool2d(kernel_size=2, stride=2),  
        nn.Conv2d(16, 32, 5),  
        nn.ReLU(),  
        nn.MaxPool2d(kernel_size=2, stride=2),  
        nn.Flatten(),  
        nn.Linear(512, 10),  
        nn.Softmax(dim=-1)  
    )  
def forward(self, x):  
    return self.seq(x)  
def loss(self, x, y_oh):  
    probs = self.forward(x)  
    return -(probs.log() * y_oh).sum(-1).mean()
```


Zadatak 2

Razmatramo sloj dubokog modela koji ulazni vektor \mathbf{p} transformira u izlazni vektor \mathbf{q} koristeći skalarne parametre w_0 , w_1 i w_2 , a može se opisati jednadžbom: $q_i = w_0 \cdot p_{i-1} + w_1 \cdot p_i + w_2 \cdot p_{i+1}$.

Odredite Jakobijan gubitka po ulazu i Jakobijan gubitka po parametrima ako je poznat Jakobijan gubitka po izlazu.

Napišite kod koji bi omogućio uklapanje sloja u duboki model proizvoljne složenosti. Sloj izrazite razredom koji implementira sučelje `Layer` iz prvog zadatka druge laboratorijske vježbe te implementira sljedeće metode:

```
forward(self, inputs), backward_inputs(self, grads), te  
backward_parameters(self, grads).
```

Izvedba treba osigurati da dimenzionalnost izlaznog vektora bude jednaka dimenzionalnosti ulaznog vektora.

Pomoć: numpyjev tenzor x proizvoljne dimenzionalnosti možemo nadopuniti nulama sljedećim pozivom: `np.lib.pad(x, 1, mode='constant')`.

Zadatak 2 - Jakobijan izlaza po ulazu

$$\frac{\partial \mathbf{q}}{\partial \mathbf{p}} = \begin{bmatrix} w_1 & w_2 & 0 & 0 & 0 & 0 & 0 & \dots & 0 \\ w_0 & w_1 & w_2 & 0 & 0 & 0 & 0 & \dots & 0 \\ 0 & w_0 & w_1 & w_2 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & w_0 & w_1 & w_2 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & w_0 & w_1 & w_2 & 0 & \dots & 0 \\ & & & & \dots & & & & \\ 0 & 0 & 0 & 0 & \dots & 0 & w_0 & w_1 & w_2 \\ 0 & 0 & 0 & 0 & \dots & 0 & 0 & w_0 & w_1 \end{bmatrix} \quad (1)$$

(2)

Zadatak 2 - Jakobijan gubitka po ulazu

$$\frac{\partial L}{\partial \mathbf{p}} = \frac{\partial L}{\partial \mathbf{q}} \frac{\partial \mathbf{q}}{\partial \mathbf{p}} = \left[\frac{\partial L}{\partial q_0}, \frac{\partial L}{\partial q_1}, \frac{\partial L}{\partial q_2}, \frac{\partial L}{\partial q_3}, \dots, \frac{\partial L}{\partial q_{n-1}} \right] \cdot \begin{bmatrix} w_1 & w_2 & 0 & 0 & 0 & 0 & 0 & \dots & 0 \\ w_0 & w_1 & w_2 & 0 & 0 & 0 & 0 & \dots & 0 \\ 0 & w_0 & w_1 & w_2 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & w_0 & w_1 & w_2 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & w_0 & w_1 & w_2 & 0 & \dots & 0 \\ & & & & \dots & & & & \\ 0 & 0 & 0 & 0 & \dots & 0 & w_0 & w_1 & w_2 \\ 0 & 0 & 0 & 0 & \dots & 0 & 0 & w_0 & w_1 \end{bmatrix}$$

Skalarni umnošci vektora retka $\frac{\partial L}{\partial q}$ sa stupcima matrice $\frac{\partial \mathbf{q}}{\partial \mathbf{p}}$ podsjećaju na konvoluciju. Doista, nadopunjavanjem to i postizemo...

Zadatak 2 - Jakobijan gubitka po ulazu

$$\frac{\partial L}{\partial \mathbf{p}} = \left[0, \frac{\partial L}{\partial q_0}, \frac{\partial L}{\partial q_1}, \frac{\partial L}{\partial q_2}, \frac{\partial L}{\partial q_3}, \dots, \frac{\partial L}{\partial q_{n-1}}, 0 \right] \cdot$$

$$\begin{bmatrix} w_2 & 0 & 0 & 0 & 0 & 0 & 0 & \dots & 0 \\ w_1 & w_2 & 0 & 0 & 0 & 0 & 0 & \dots & 0 \\ w_0 & w_1 & w_2 & 0 & 0 & 0 & 0 & \dots & 0 \\ 0 & w_0 & w_1 & w_2 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & w_0 & w_1 & w_2 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & w_0 & w_1 & w_2 & 0 & \dots & 0 \\ & & & & \dots & & & & \\ 0 & 0 & 0 & 0 & \dots & 0 & w_0 & w_1 & w_2 \\ 0 & 0 & 0 & 0 & \dots & 0 & 0 & w_0 & w_1 \\ 0 & 0 & 0 & 0 & \dots & 0 & 0 & 0 & w_0 \end{bmatrix}$$

$$= \text{pad}\left(\frac{\partial L}{\partial \mathbf{q}}, 1, \text{val} = 0\right) \star \text{flip}(\mathbf{w})$$

Jakobijan izlaza po parametrima

$$\frac{\partial q}{\partial w} = \begin{bmatrix} 0 & p_0 & p_1 \\ p_0 & p_1 & p_2 \\ p_1 & p_2 & p_3 \\ p_2 & p_3 & p_4 \\ p_3 & p_4 & p_5 \\ & \dots & \\ p_{n-2} & p_{n-1} & 0 \end{bmatrix}$$

Jakobijan gubitka po parametrima

$$\begin{aligned}\frac{\partial L}{\partial \mathbf{w}} &= \frac{\partial L}{\partial \mathbf{q}} \frac{\partial \mathbf{q}}{\partial \mathbf{w}} \\ &= \left[\frac{\partial L}{\partial q_0}, \frac{\partial L}{\partial q_1}, \frac{\partial L}{\partial q_2}, \frac{\partial L}{\partial q_3}, \dots, \frac{\partial L}{\partial q_{n-1}} \right] \cdot \\ &\quad \begin{bmatrix} 0 & p_0 & p_1 \\ p_0 & p_1 & p_2 \\ p_1 & p_2 & p_3 \\ p_2 & p_3 & p_4 \\ p_3 & p_4 & p_5 \\ & \dots & \\ p_{n-2} & p_{n-1} & 0 \end{bmatrix}\end{aligned}$$

Ovaj umnožak također možemo izraziti unakrsnom korelacijom:

$$\frac{\partial L}{\partial \mathbf{w}} = \text{pad}(\mathbf{p}, 1, \text{val} = 0) \star \frac{\partial L}{\partial \mathbf{q}}$$

Zadatok 2 - kod

```
class Layer:
    def forward(self, p):
        self.p = p
        p2 = np.lib.pad(p, 1, 'constant')
        q = (p2[0:p.shape[0]] * self.w0 +
             p * self.w1 +
             p2[2:p.shape[0]+2] * self.w2)
        return q

    def backward_inputs(self, dq):
        dq2 = np.lib.pad(dq, 1, 'constant')
        dp = dq * self.w1 + dq2[0:dq.shape[0]] * self.w2 + dq2[2:dq.shape[0]+2] * self.w0
        return dp

    def backward_params(self, dq):
        dq2 = np.lib.pad(dq, 1, 'constant')
        dw0 = np.dot(self.p, dq2[2:dq.shape[0]+2])
        dw1 = np.dot(self.p, dq)
        dw2 = np.dot(self.p, dq2[0:dq.shape[0]+0])
        return np.array((dw0, dw1, dw2))
```

Zadatak 2 - kod

```
def forward_alt(self, p):  
    self.p = p  
    p2 = np.lib.pad(p, 1, 'constant')  
    q = np.zeros_like(p)  
    for i in range(len(q)):  
        q[i] = p2[i] * self.w0  
                + p2[i+1] * self.w1  
                + p2[i+2] * self.w2  
    return q
```


Zadatak 3

Razmatramo klasifikacijski model kojeg opisuju sljedeće jednačbe:

$$\mathbf{h} = \text{ReLU}(\mathbf{W} \cdot \mathbf{x} + \mathbf{b}) \quad (3)$$

$$\mathbf{h}_2 = \text{ReLU}(\mathbf{W}_2 \cdot \mathbf{h} + \mathbf{b}_2) \quad (4)$$

$$\mathbf{s} = \text{softmax}(\mathbf{W}_3 \cdot \mathbf{h}_2 + \mathbf{b}_3 + \mathbf{h}) \quad (5)$$

Početne vrijednosti parametara modela su: $\mathbf{W} = \begin{bmatrix} 1 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$,

$\mathbf{W}_2 = \mathbf{W}_3 = \mathbf{I}$, $\mathbf{b} = \mathbf{b}_2 = \mathbf{b}_3 = \mathbf{0}$. Na ulaz modela dovodimo podatak $\mathbf{x} = [1 \ 2 \ 3]^\top$ koji bi se trebao klasificirati u razred $y = 0$. Gubitak je negativna log-izglednost.

- 1 Provedite unaprijedni prolaz i odredite predikciju modela.
- 2 Odredite gubitak.
- 3 Odredite gradijente po \mathbf{W} .

Zadatak 3 - rješenje

Unaprijedni prolaz:

$$\mathbf{x} = [1, 2, 3]^T \quad (6)$$

$$\mathbf{a} = \mathbf{W} \cdot \mathbf{x} + \mathbf{b} = [3, 3]^T \quad (7)$$

$$\mathbf{h} = \text{ReLU}(\mathbf{a}) = [3, 3]^T \quad (8)$$

$$\mathbf{a}_2 = \mathbf{W}_2 \cdot \mathbf{h} + \mathbf{b}_2 = [3, 3]^T \quad (9)$$

$$\mathbf{h}_2 = \text{ReLU}(\mathbf{a}_2) = [3, 3]^T \quad (10)$$

$$\mathbf{s} = \mathbf{W}_3 \cdot \mathbf{h}_2 + \mathbf{b}_3 + \mathbf{h} = [6, 6]^T \quad (11)$$

$$\mathbf{p} = \text{softmax}(\mathbf{s}) = [0.5, 0.5]^T \quad (12)$$

Gubitak:

$$L = -\ln p(\underline{y} = 0 \mid \mathbf{x}, \boldsymbol{\theta}) = -\ln(p_{[0]}) = \ln(2) \approx 0.693$$

Zadatak 3 - rješenje

Gradijent:

$$\frac{\partial L}{\partial \mathbf{s}} = \mathbf{p} - \mathbf{y}_{\text{oh}} = [0.5, 0.5] - [1, 0] = [-0.5, 0.5] \quad (13)$$

$$\frac{\partial L}{\partial \mathbf{h}_2} = \frac{\partial L}{\partial \mathbf{s}} \frac{\partial \mathbf{s}}{\partial \mathbf{h}_2} = \frac{\partial L}{\partial \mathbf{s}} \mathbf{W}_3 \quad (14)$$

$$= [-0.5, 0.5] \quad (15)$$

$$\frac{\partial L}{\partial \mathbf{a}_2} = \frac{\partial L}{\partial \mathbf{h}_2} \frac{\partial \mathbf{h}_2}{\partial \mathbf{a}_2} = [-0.5, 0.5] \quad (16)$$

$$\frac{\partial L}{\partial \mathbf{h}} = \frac{\partial L}{\partial \mathbf{s}} \frac{\partial \mathbf{s}}{\partial \mathbf{h}} = \frac{\partial L}{\partial \mathbf{a}_2} \mathbf{W}_2 + \frac{\partial L}{\partial \mathbf{s}} \quad (17)$$

$$= [-0.5, 0.5] + [-0.5, 0.5] = [-1, 1] \quad (18)$$

$$\frac{\partial L}{\partial \mathbf{a}} = \frac{\partial L}{\partial \mathbf{h}} \frac{\partial \mathbf{h}}{\partial \mathbf{a}} = [-1, 1] \quad (19)$$

Zadatak 3 - rješenje

Gradijent:

$$\frac{\partial L}{\partial \mathbf{W}_{[i,\cdot]}} = \frac{\partial L}{\partial \mathbf{a}} \frac{\partial \mathbf{a}}{\partial \mathbf{W}_{[i,\cdot]}} = \frac{\partial L}{\partial \mathbf{a}_{[i]}} \frac{\partial \mathbf{a}_{[i]}}{\partial \mathbf{W}_{[i,\cdot]}} \quad (20)$$

$$= \frac{\partial L}{\partial \mathbf{a}_{[i]}} \mathbf{x}^\top \quad (21)$$

$$\frac{\partial L}{\partial \mathbf{W}_{[1,\cdot]}} = -1 \cdot [1, 2, 3] \quad (22)$$

$$\frac{\partial L}{\partial \mathbf{W}_{[2,\cdot]}} = 1 \cdot [1, 2, 3] \quad (23)$$

$$\nabla_{\mathbf{W}} L = \begin{bmatrix} -1 & -2 & -3 \\ 1 & 2 & 3 \end{bmatrix} \quad (24)$$