

Tutoraufgabe (Backpropagation für komplexwertige Netze)

In dieser Aufgabe sollen die Gleichungen (BP1) – (BP4) des Backpropagation-Algorithmus auf komplexwertige neuronale Netze verallgemeinert werden, d.h. $w^\ell, b^\ell, z^\ell, a^\ell$ sind jetzt komplexe Matrizen bzw. Vektoren. Wir nehmen an, dass die Aktivierungsfunktion in einer offenen Menge $U \subset \mathbb{C}$ holomorph ist, was ja insbesondere auf die Sigmoid-Funktion $\sigma(z) = 1/(1 + e^{-z})$ zutrifft. Wie im reellen Fall verwenden wir die Hilfsgröße

$$\delta_j^\ell := \frac{\partial C}{\partial z_j^\ell},$$

wobei jetzt allerdings die Ableitungsoperatoren als Wirtinger- oder Dolbeault-Operatoren aufgefasst werden:

$$\frac{\partial}{\partial z} = \frac{1}{2} \left(\frac{\partial}{\partial x} - i \frac{\partial}{\partial y} \right), \quad \frac{\partial}{\partial \bar{z}} = \frac{1}{2} \left(\frac{\partial}{\partial x} + i \frac{\partial}{\partial y} \right)$$

mit $z = x + iy, x, y \in \mathbb{R}$. Außerdem benötigen wir noch die folgende Kettenregel, die sich durch direktes Nachrechnen verifizieren lässt:

$$\frac{\partial}{\partial z} (g \circ f) = \left(\frac{\partial g}{\partial w} \circ f \right) \cdot \frac{\partial f}{\partial z} + \left(\frac{\partial g}{\partial \bar{w}} \circ f \right) \cdot \frac{\partial \bar{f}}{\partial z}.$$

Die Kostenfunktion C ist weiterhin reellwertig (so dass deren Minimierung überhaupt Sinn ergibt), und somit nicht komplex differenzierbar.

Hinweis: Die \mathbb{C} -lineare Multiplikation $w \mapsto z \cdot w$ mit einer vorgegebenen komplexen Zahl $z = x + iy$ lässt sich durch Identifikation $\mathbb{C} \cong \mathbb{R}^2$ auch als \mathbb{R} -lineare Abbildung auffassen. Anwendung auf $1 = (1, 0)$ und $i = (0, 1)$ ergibt die Matrixdarstellung

$$A_z = (z|iz) = \begin{pmatrix} x & -y \\ y & x \end{pmatrix}. \tag{1}$$

Umgekehrt ist eine reelle 2×2 -Matrix $A = (z_1|z_2)$ mit Spaltenvektoren $z_1, z_2 \in \mathbb{C}$ also von der Form (1), wenn $z_2 = iz_1$ bzw. $z_1 + iz_2 = 0$.

Eine Funktion $f : U \subset \mathbb{C} \rightarrow \mathbb{C}$ ist bekanntlich genau dann in $z \in U$ komplex differenzierbar, wenn

$$f(w) = f(z) + f'(z) \cdot (w - z) + o(w - z) \quad (w \rightarrow z). \tag{2}$$

Identifizieren wir $\mathbb{C} \cong \mathbb{R}^2$, dann ist f (als Funktion $U \subset \mathbb{R}^2 \rightarrow \mathbb{R}^2$) genau dann reell differenzierbar, wenn

$$f(w) = f(z) + Df(z) \cdot (w - z) + o(w - z) \quad (w \rightarrow z).$$

Hierbei ist $Df(z) \in \mathbb{R}^{2 \times 2}$ die Jakobi-Matrix. Die stärkere Bedingung "komplex differenzierbar" bedeutet also, dass das Matrix-Vektor-Produkt $Df(z) \cdot (w - z)$ als Multiplikation zweier komplexer Zahlen aufgefasst werden kann. Zerlegen wir $Df = (\partial_x f | \partial_y f)$, dann ist dies laut obiger Diskussion äquivalent zu den Cauchy-Riemann'schen Differentialgleichungen

$$\frac{\partial f}{\partial \bar{z}} \equiv \frac{1}{2} (\partial_x f + i \partial_y f) = 0,$$

wobei $\partial/\partial \bar{z}$ der (konjugierte) Wirtinger-Operator ist. Die komplexe Ableitung ist dann $f'(z) = \partial f(z)/\partial z$.

Als direkte Folgerung erhält man für f komplex differenzierbar in z :

$$\frac{\partial \bar{f}}{\partial z} = \frac{1}{2} (\partial_x \bar{f} - i \partial_y \bar{f}) = \frac{1}{2} \overline{(\partial_x f + i \partial_y f)} = \overline{\left(\frac{\partial f}{\partial \bar{z}} \right)} = 0. \tag{3}$$

(a) Zeigen Sie, dass (formal identisch zum reellwertigen Fall)

$$\delta_j^L = \frac{\partial C}{\partial a_j^L} \sigma'(z_j^L), \tag{BP1}$$

wobei $\partial/\partial a_j^L$ die Wirtinger-Ableitung bezüglich a_j^L ist und σ' die komplexe Ableitung der Aktivierungsfunktion. Wie lautet $\partial C/\partial a_j^L$ für die quadratische Kostenfunktion $C = \frac{1}{2} \|y - a^L\|^2$?

Lösungsvorschlag Anwenden der Wirtinger-Kettenregel liefert zunächst

$$\delta_j^L = \frac{\partial C}{\partial z_j^L} = \sum_k \left(\frac{\partial C}{\partial a_k^L} \frac{\partial a_k^L}{\partial z_j^L} + \frac{\partial C}{\partial \bar{a}_k^L} \frac{\partial \bar{a}_k^L}{\partial z_j^L} \right) = \frac{\partial C}{\partial a_j^L} \frac{\partial a_j^L}{\partial z_j^L} + \frac{\partial C}{\partial \bar{a}_j^L} \frac{\partial \bar{a}_j^L}{\partial z_j^L},$$

wobei wir für das zweite Gleichheitszeichen ausgenutzt haben, dass $a_k^L = \sigma(z_k^L)$ nur von z_k^L abhängt. Laut Voraussetzung ist die Aktivierungsfunktion σ holomorph, und damit

$$\frac{\partial a_j^L}{\partial z_j^L} = \sigma'(z_j^L)$$

die komplexe Ableitung von σ in z_j^L . Außerdem gilt laut Gl. (3), dass $\partial a_j^L / \partial z_j^L = 0$. Insgesamt erhält man

$$\delta_j^L = \frac{\partial C}{\partial a_j^L} \sigma'(z_j^L).$$

Zur Berechnung von $\partial C / \partial a_j^L$ für die quadratische Kostenfunktion betrachten wir zunächst die Abbildung $z \in \mathbb{C} \mapsto \frac{1}{2}|z|^2 = \frac{1}{2}(x^2 + y^2)$, wobei $z = x + iy$. Deren Wirtinger-Ableitung beträgt

$$\frac{\partial}{\partial z} \frac{1}{2}|z|^2 = \frac{1}{2} (\partial_x - i\partial_y) \frac{1}{2}(x^2 + y^2) = \frac{1}{2}(x - iy) = \frac{1}{2}\bar{z}.$$

Ebenso berechnet man

$$\frac{\partial}{\partial a_j^L} \frac{1}{2} \|y - a^L\|^2 = \frac{\partial}{\partial a_j^L} \sum_k \frac{1}{2} |y_k - a_k^L|^2 = \frac{1}{2} \overline{(a_j^L - y_j)}.$$

(b) Leiten Sie (wiederum formal identisch zum reellwertigen Fall) den Zusammenhang

$$\delta^\ell = \text{diag}(\sigma'(z^\ell)) \cdot (w^{\ell+1})^T \cdot \delta^{\ell+1} \quad (\text{BP2})$$

für alle $\ell < L$ her, wobei die Ableitung σ' komponentenweise an den Einträgen von z^ℓ ausgewertet wird.

Lösungsvorschlag Laut Wirtinger-Kettenregel gilt

$$\delta_j^\ell = \frac{\partial C}{\partial z_j^\ell} = \sum_k \left(\frac{\partial C}{\partial z_k^{\ell+1}} \frac{\partial z_k^{\ell+1}}{\partial z_j^\ell} + \frac{\partial C}{\partial \overline{z_k^{\ell+1}}} \frac{\partial \overline{z_k^{\ell+1}}}{\partial z_j^\ell} \right).$$

$z_k^{\ell+1}$ als Funktion von z_j^ℓ ist eine Verkettung holomorpher Abbildungen und damit wiederum holomorph. Somit gilt $\partial \overline{z_k^{\ell+1}} / \partial z_j^\ell = 0$ gemäß Gl. (3), d.h. der zweite Term in der Klammer verschwindet. Für den ersten Term erhalten wir

$$\frac{\partial z_k^{\ell+1}}{\partial z_j^\ell} = \frac{\partial}{\partial z_j^\ell} \left(\sum_m w_{km}^{\ell+1} \sigma(z_m^\ell) + b_k^{\ell+1} \right) = w_{kj}^{\ell+1} \sigma'(z_j^\ell)$$

und somit insgesamt

$$\delta_j^\ell = \sum_k \delta_k^{\ell+1} w_{kj}^{\ell+1} \sigma'(z_j^\ell).$$

Dies ist (BP2) in Komponentenform.

(c) Verifizieren Sie ebenso

$$\frac{\partial C}{\partial b_j^\ell} = \delta_j^\ell \quad (\text{BP3})$$

sowie

$$\frac{\partial C}{\partial w_{jk}^\ell} = a_k^{\ell-1} \delta_j^\ell. \quad (\text{BP4})$$

Lösungsvorschlag Argumentation wie in (b) und im reellwertigen Fall.

(d) Wie kann man nun den Gradienten der Kostenfunktion bezüglich des Real- und Imaginärteils von w_{jk}^ℓ bzw. b_j^ℓ erhalten?

Lösungsvorschlag Direkt aus der Definition der Wirtinger-Ableitungsoperatoren erhält man für eine *reellwertige* Funktion $f : \mathbb{C} \rightarrow \mathbb{R}$

$$\frac{\partial f}{\partial x} = 2 \text{Re} \left(\frac{\partial f}{\partial z} \right), \quad \frac{\partial f}{\partial y} = -2 \text{Im} \left(\frac{\partial f}{\partial z} \right),$$

also interpretiert als Funktion $f : \mathbb{R}^2 \rightarrow \mathbb{R}$

$$\nabla f = 2 \overline{\left(\frac{\partial f}{\partial z} \right)}.$$

Anwenden auf (BP3) und (BP4) liefert den gesuchten Gradienten der Kostenfunktion.