

1. **MLE regrese:** Máte na střeše senzor, který měří fyzikální veličinu $x \in \mathbb{R}^+$ související s rychlostí větru, jako je např. úhlová rychlost větrného mlýnku. Předpokládáme, že pro dané měření x , má rychlost větru $y \in \mathbb{R}^+$ Rayleighovo rozdělení pravděpodobnosti:

$$p(y|x, w) = (y - wx) \exp(- (y - wx)^2)$$


kde $w \in \mathbb{R}$ je neznámý parametr.

- 1.1 Dostanete trénovací sadu $\mathcal{D} = \{(x_1, y_1) \dots (x_N, y_N)\}$ měřených veličin x_i a odpovídajících rychlostí větru y_i . Zapište optimalizační problém, který odpovídá maximálně věrohodnému odhadu parametrů modelu w a pokud je to možné, zjednodušte výsledný optimalizační problém na vhodnou **ztrátovou funkci**.

- 1.2 **Nakreslete výpočetní graf** odvozené ztrátové funkce pro jeden trénovací příklad (x, y) a spočítejte jeho **gradient** vzhledem k w .

- 1.3 Uvažujte nyní, že 1/10 měření nesouvisí se skutečnou rychlostí větru (např. kvůli nějaké vnitřní poruše senzoru). Proto v 1/10 všech tréninkových příkladů pochází rychlost větru y z rovnoměrného rozdělení $y \sim U(0, y_{max})$. **Nakreslete tvar rozdělení pravděpodobnosti**, které modeluje takový případ.

2. **Vector-jacobian-product:** Uvažujte výpočetní graf níže:



Graf se skládá ze dvou funkcí:

- a) $\text{diag}(\mathbf{x})$ funkce, která vrací úhlopříčku vstupní matice $\mathbf{x} \in \mathbb{R}^{N \times N}$ jako sloupcový vektor $\mathbf{y} \in \mathbb{R}^{N \times N}$, který je složený z diagonálních prvků. Například pro $N = 3$, funkce funguje následovně:

$$\mathbf{y} = \text{diag}(\mathbf{x}) = \text{diag} \left(\begin{bmatrix} x_{11} & x_{12} & x_{13} \\ x_{21} & x_{22} & x_{23} \\ x_{31} & x_{32} & x_{33} \end{bmatrix} \right) = \begin{bmatrix} x_{11} \\ x_{22} \\ x_{33} \end{bmatrix}$$

- b) L1-ztrátová funkce, která je definována jako součet absolutních hodnot rozdílů:


$$\mathcal{L} = \sum_i |\mathbf{z}_i - \mathbf{y}_i|$$

- 2.1 Navrhněte efektivní implementaci funkce vracějící **vector-jacobian-product** $\text{vjp}_{\text{diag}}(\mathbf{x}, \mathbf{v})$, kde vektor $\mathbf{v} \in \mathbb{R}^N$ je upstream gradient.

- 2.2 Vypočtěte **gradient** ztrátové funkce $\mathcal{L}$ vzhledem k $\mathbf{x}$ (tj. $N \times N$ matice).
- 2.3 Diskutujte rozdíl mezi vaší efektivní implementací vjp_{diag} a naivním násobením jakobiánů (pouze jedna krátká věta).

3. Losses and Overfitting:

- 3.1 Během přednášek jsme diskutovali následující tři problémy, které se objevují při fitování funkce do dat ve smyslu nejmenších čtverců. **Jaký je hlavní zdroj, který tyto problémy způsobuje?** Vyberte právě jednu odpověď.



- overfitting
 - underfitting
 - výsledný problém je nepříznivý pro optimalizaci (velké plochy s nulovým gradientem)
 - odpovídající tvar ztrátové funkce má ostré minimum, které způsobuje špatné zobecnění testovacích dat
 - model předpokládá, že výstupy y mají normální (Gaussové) rozdělení pro danou hodnotou x .
 - KL-divergence není definována
 - je velký rozdíl mezi trénovacím/testovacím pravděpodobnostním rozdělením (training/testing distribution mismatch).
- 3.2 **Jak mohou omezit přefitování (overfitting)?** Vyberte žádnou, jednu nebo více odpovědí:
 - Nikdy nepředpokládat Gaussovský šum.
 - Použití hodně velké (ideálně nekonečné) datové sady
 - Vyhnout se plochému minimu (flat minimum) ve ztrátové funkci
 - Musím udržovat váhy v klasifikátoru/regresoru vždy kladné.
 - Musím udržovat váhy v klasifikátoru/regresoru vždy záporné.
 - Musím použít co nejhlubší konvoluční síť.
 - Musím použít správný model, který zahrnuje co nejvíc apriorních znalostí o řešeném problému.
 - Vyhnout se ostrému minimu (sharp minimum) ve ztrátové funkci.
 - Použít plně diferencovatelnou ztrátovou funkci.
 - Implementovat všechny Vector-Jacobian-Product funkce na GPU.
 - Vždy předpokládat Gaussovský šum.

• 3.3 Označte, které z následujících tvrzení jsou PRAVDA/NEPRAVDA:

- 2D fitování přímky ve smyslu nejmenších čtverců odpovídá minimalizaci KL-divergence mezi skutečným rozdělením dat p_{data} a normálním (Gaussovským) rozdělením s lineárním průměrem zkonstruovaným následovně

$$p(\mathbf{x}, y|\mathbf{w}) = \mathcal{N}(y; w_1x + w_0, \sigma^2)$$

- Hodnota globálního optima následujícího problému je vždy rovna nule

$$\min_{\mathbf{w}} D_{KL}(p_{\text{data}}(\mathbf{x}, y) \parallel p(\mathbf{x}, y|\mathbf{w})) = 0$$

- Hodnota globálního optima následujícího problému je vždy nezáporná

$$\min_{\mathbf{w}} D_{KL}(p_{\text{data}}(\mathbf{x}, y) \parallel p(\mathbf{x}, y|\mathbf{w})) \geq 0$$

- Konvoluční síť se nikdy nepřefitovává na obrazových datech.
- $D_{KL}(p_{\text{data}}(\mathbf{x}, y) \parallel p(\mathbf{x}, y|\mathbf{w}))$ je monotónně rostoucí funkce vah $\mathbf{w}$.
- $D_{KL}(p_{\text{data}}(\mathbf{x}, y) \parallel p(\mathbf{x}, y|\mathbf{w}))$ má právě jedno lokální minimum.
- Gradient konvoluční vrstvy lze spočítat jako konvoluci.
- Každý vstup do konvoluční vrstvy vždy ovlivňuje všechny pixely ve výstupní příznakové mapě (feature map).

4. **Convolution:** Předpokládejme, že vstupní příznaková mapa (feature map) do konvoluční vrstvy je $3 \times 10 \times 10$ (channels $\times$ height $\times$ width).

- 4.1 Jaká je velikost a počet konvolučních jader/filtrů (kernels/filters), pokud by výstup měl být $10 \times 3 \times 3$? (předpokládejme stride=1, padding=0 a dilation_rate=1)


- 4.2 Jaký je padding konvoluční vrstvy, pokud je velikost jádra/filtru $3 \times 3 \times 3$ a výstup by měl být $7 \times 12 \times 12$ (stride=1 a dilation_rate = 1)?

- 4.3 Uvažujme nyní jednokanálový vstup $1 \times 10 \times 10$. Mějme síť sestávající se ze dvou konvolučních vrstev (bez jakékoli aktivační funkce). Každá vrstva má pouze jedno jádro 3×3 následujícího tvaru:

$$\mathbf{w} = \begin{bmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \\ w_{31} & w_{32} & w_{33} \end{bmatrix}, \quad \mathbf{v} = \begin{bmatrix} v_{11} & v_{12} & v_{13} \\ v_{21} & v_{22} & v_{23} \\ v_{31} & v_{32} & v_{33} \end{bmatrix}$$

Můžete tyto dvě vrstvy nahradit plně propojenou vrstvou (fully-connected layer)? Pokud je to možné, jaké budou její váhy? Pokud to není možné, zdůvodněte.

- 4.4 Uvažte následující výpočetní graf s 1D konvolucí. Vypočtěte $\frac{\partial \mathbf{z}}{\partial \mathbf{w}}$ a $\frac{\partial \mathcal{L}}{\partial \mathbf{w}}$:



$$\frac{\partial \mathbf{z}}{\partial \mathbf{w}} =$$

$$\frac{\partial \mathcal{L}}{\partial \mathbf{w}} =$$

5. Napište nám cokoliv co se vám zatím libilo/nelíbilo a jak bychom to měli změnit. Pokud máte stále dost času, nakreslete nám obrázek na téma ”**Učení robotů a Halloween**”. Vybraná díla budou zveřejněna na stránkách předmětu, nejkreativnější výtvar bude **odměněn lahváčem**.