


Tomáš Oberhuber

Faculty of Nuclear Sciences and Physical Engineering
Czech Technical University in Prague

Reziduální síť



- viděli jsme, jak síť ResNet využívá tzv. *skip connections*
- zkratka obcházející jednu vrstvu má význam identity

- aktivace jednotlivých vrstev pak lze popsat jako

$$\vec{x}^{(l+1)} = \vec{x}^{(l)} + F(\vec{x}^{(l)})$$

- to lze přepsat do tvaru

$$\vec{x}^{(l+1)} = \vec{x}^{(l)} + \Delta t \cdot F(\vec{x}^{(l)}),$$

pro $\Delta t = 1$

- tento tvar odpovídá Eulerově metodě pro řešení ODR

$$\frac{d\vec{x}}{dt} = F(\vec{x}, t)$$

E. Weinan, A proposal on machine learning via dynamical systems, *Communications in Mathematics and Statistics*, vol. 5, no. 1, pp. 1–11, 2017

T. Q. Chen, Y. Rubanova, J. Bettencourt, and D. K. Duvenaud, “Neural ordinary differential equations,” in *Advances in Neural Information Processing Systems*, pp. 6571–6583, 2018

Optimalizace s ODR

- místo učení NN se tak můžeme zabývat úlohou hledání vhodných parametrů pro ODR tak, aby např. generovala předepsaná data
- vlastně tak hledáme matematický model pro generování experimentálních dat
- jde o úlohu zvanou *physics from data* - [Youtube](#)
- optimalizace s ODR jsou také známé jako **optimální procesy**

L.S. Pontryagin, Mathematical Theory of Optimal Processes: The Mathematical Theory of Optimal Processes, Routledge, 1987.

Mějme ODR tvaru

$$\dot{\vec{u}}(t, \vec{p}) = \vec{f}(\vec{u}(t, \vec{p}), t, \vec{p}) \text{ na } (0, T), \quad (1)$$

$$\vec{u}(0, \vec{p}) = \vec{u}_0(\vec{p}), \quad (2)$$

kde

- \vec{p} je vektor parametrů $\vec{p} \in P \equiv \mathbb{R}^m$
- $\vec{u}(t, \vec{p}) : \langle 0, T \rangle \times P \rightarrow \mathbb{R}^n$ je neznámá funkce
- $\vec{f}(\vec{u}(t, \vec{p}), t, \vec{p}) : \mathbb{R}^n \times \langle 0, T \rangle \times P \rightarrow \mathbb{R}^n$ je daná pravá strana

Optimalizace s ODR

Mějme zobrazení

- $h_1(\vec{u}(t, \vec{p}), t, p) : \mathbb{R}^n \times \langle 0, T \rangle \times P \rightarrow \mathbb{R}$,
- $h_2(\vec{u}(T, \vec{p}), p) : \mathbb{R}^n \times P \rightarrow \mathbb{R}$.

Pak můžeme definovat funkcionál J jako

$$J(\vec{p}) = \int_0^T h_1(\vec{u}(t, \vec{p}), t, p) dt + h_2(\vec{u}(T, \vec{p}), \vec{p})$$

a řešit úlohu

$$\vec{p}^* = \arg \min_{p \in P} J(\vec{p}).$$

Example 1

- předpokládejme, že máme zadaná (experimentální) data $\vec{d}(t)$
- volbou

$$\begin{aligned}h_1(\vec{u}(t, \vec{p}), t, \rho) &= \left| \vec{u}(t, \vec{p}) - \vec{d}(t) \right|^2, \\h_2(\vec{u}(T, \vec{p}), \rho) &= 0\end{aligned}$$

- dostáváme funkcionál

$$J(\vec{p}) = \int_0^T \left| \vec{u}(t, \vec{p}) - \vec{d}(t) \right|^2 dt$$

- a hledáme parametry \vec{p}^* tak, že ODR (10) s pravou stranou $\vec{f}(\vec{u}(t, \vec{p}^*), t, \vec{p}^*)$ generuje naše data.

Example 2

- mějme zadaný finální stav $\vec{d}(T)$
- volbou

$$h_1(\vec{u}(t, \vec{p}), t, p) = 0,$$

$$h_2(\vec{u}(T, \vec{p}), p) = \left| \vec{u}(T, \vec{p}) - \vec{d}(T) \right|^2$$

- dostáváme funkcionál

$$J(\vec{p}) = \left| \vec{u}(T, \vec{p}) - \vec{d}(T) \right|^2$$

- a hledáme parametry \vec{p}^* tak, že počáteční podmínka (10) vede k finálnímu stavu $\vec{d}(T)$, tj. můžeme řešit *inverzní úlohu* k úloze (10)-(10)

Optimalizace s ODR

- pro nalezení optimálních parametrů \vec{p}^* opět potřebujeme spočítat

$$\nabla_{\vec{p}} J(\vec{p})$$

- to lze udělat třemi různými způsoby
 - 1 přímým výpočtem pomocí malých perturbací parametrů \vec{p}
 - pro větší počet parametrů to může být výpočetně velmi náročné
 - 2 algoritmicky pomocí tzv. *automatic differentiation* - Julia
 - u ODR je to v současnosti často nejjednodušší přístup
 - 3 odvozením tzv. **adjungovaná rovnice** (*adjoint equation*) - obdoba backpropagation

Adjungovaná rovnice

- pro odvození adjungované rovnice použijeme Lagrangeovy multiplikátory
- definujeme funkcionál $J^*(\vec{p})$ jako

$$J^*(\vec{p}) = \int_0^T h_1 + \vec{\lambda}_1^T (\vec{u}(\vec{p}) - \vec{f}) dt + h_2 + \vec{\lambda}_2^T (\vec{u}|_{t=0} - \vec{u}_0)$$

kde $\vec{\lambda}_{1,2} \in C(\langle 0, T \rangle; \mathbb{R}^n)$ jsou Lagrangeovy multiplikátory

- pokud \vec{u} je řešení ODR (10)-(10) potom

$$\begin{aligned}\dot{\vec{u}} - \vec{f} &= 0 \text{ na } (0, T), \\ \vec{u}|_{t=0} - \vec{u}_0 &= 0,\end{aligned}$$

a $J(\vec{p}) = J^*(\vec{p})$ platí pro všechna $\vec{\lambda}_{1,2}$

Adjungovaná rovnice

- gradient J^* má tvar

$$\begin{aligned} \nabla_{\vec{p}} J^*(\vec{p}) = & \int_0^T \frac{\partial h_1}{\partial \vec{u}} \frac{\partial \vec{u}}{\partial \vec{p}} + \frac{\partial h_1}{\partial \vec{p}} + \vec{\lambda}_1^T \left(\frac{\partial \dot{\vec{u}}}{\partial \vec{p}} - \frac{\partial \vec{f}}{\partial \vec{u}} \frac{\partial \vec{u}}{\partial \vec{p}} - \frac{\partial \vec{f}}{\partial \vec{p}} \right) dt + \\ & \frac{\partial h_2}{\partial \vec{u}} \frac{\partial \vec{u}}{\partial \vec{p}} \Big|_{t=T} + \frac{\partial h_2}{\partial \vec{p}} \Big|_{t=T} + \vec{\lambda}_2^T \left(\frac{\partial \vec{u}}{\partial \vec{p}} \Big|_{t=0} + \frac{\partial \vec{u}_0}{\partial \vec{p}} \right) \end{aligned}$$

- výpočet $\partial \vec{u} / \partial \vec{p}$ a $\partial \dot{\vec{u}} / \partial \vec{p}$ by vyžadoval opětovné řešení původní ODR a postupnými perturbacemi \vec{p}
- těchto členů se chceme zbavit

Adjungovaná rovnice

- začneme s výrazem $\partial \dot{\vec{u}} / \partial \vec{p}$

$$\begin{aligned} \int_0^T \vec{\lambda}_1^T \frac{\partial \dot{\vec{u}}}{\partial \vec{p}} dt &= \int_0^T \vec{\lambda}_1^T \frac{\partial}{\partial \vec{p}} \frac{\partial \vec{u}}{\partial t} dt \\ &= \int_0^T \vec{\lambda}_1^T \frac{\partial}{\partial t} \frac{\partial \vec{u}}{\partial \vec{p}} dt \\ &= - \int_0^T \frac{\partial \vec{\lambda}_1^T}{\partial t} \frac{\partial \vec{u}}{\partial \vec{p}} dt + \left[\vec{\lambda}_1^T \frac{\partial \vec{u}}{\partial \vec{p}} \right]_0^T \\ &= - \int_0^T \frac{\partial \vec{\lambda}_1^T}{\partial t} \frac{\partial \vec{u}}{\partial \vec{p}} dt + \vec{\lambda}_1^T \frac{\partial \vec{u}}{\partial \vec{p}} \Big|_{t=T} - \vec{\lambda}_1^T \frac{\partial \vec{u}}{\partial \vec{p}} \Big|_{t=0}, \end{aligned}$$

Adjungovaná rovnice

- a tak dostaneme

$$\begin{aligned} \nabla_{\vec{p}} \mathcal{J}^*(\vec{p}) &= \int_0^T \left(\frac{\partial h_1}{\partial \vec{u}} - \dot{\vec{\lambda}}_1^T - \vec{\lambda}_1^T \frac{\partial \vec{f}}{\partial \vec{u}} \right) \frac{\partial \vec{u}}{\partial \vec{p}} + \frac{\partial h_1}{\partial \vec{p}} - \vec{\lambda}_1^T \frac{\partial \vec{f}}{\partial \vec{p}} dt + \\ &\quad \left(\vec{\lambda}_1^T + \frac{\partial h_2}{\partial \vec{u}} \right) \frac{\partial \vec{u}}{\partial \vec{p}} \Big|_{t=T} + \frac{\partial h_2}{\partial \vec{p}} \Big|_{t=T} + \left(\vec{\lambda}_2^T - \vec{\lambda}_1^T \right) \frac{\partial \vec{u}}{\partial \vec{p}} \Big|_{t=0} + \vec{\lambda}_2^T \frac{\partial \vec{u}_0}{\partial \vec{p}} \end{aligned}$$

Adjungovaná rovnice

- a splněním následujících vztahů

$$\frac{\partial h_1}{\partial \vec{u}} - \dot{\lambda}_1^T - \bar{\lambda}_1^T \frac{\partial \vec{f}}{\partial \vec{u}} = 0, \quad (3)$$

$$\left(\bar{\lambda}_1^T + \frac{\partial h_2}{\partial \vec{u}} \right)_{t=T} = 0, \quad (4)$$

$$\left(\bar{\lambda}_2 - \bar{\lambda}_1 \right) |_{t=0} = 0. \quad (5)$$

- můžeme nulovat výrazy před $\frac{\partial \vec{u}}{\partial \vec{p}}$

Adjungovaná rovnice

- (3)-(4) lze splnit řešením adjungované ODR

$$-\frac{\partial \vec{\lambda}_1}{\partial t} = \vec{\lambda}_1 \frac{\partial \vec{f}}{\partial \vec{u}} - \frac{\partial h_1}{\partial \vec{u}} \text{ na } (0, T), \quad (6)$$

$$\vec{\lambda}_1 |_{t=T} = -\frac{\partial h_2}{\partial \vec{u}} |_{t=T} \quad (7)$$

- a následně nastavit

$$\vec{\lambda}_2 |_{t=0} = \vec{\lambda}_1 |_{t=0} .$$

- uvedená ODR má počáteční podmínku zadanou v bodu $t = T$

Adjungovaná rovnice

- provedeme transformaci

$$\vec{\lambda}_1^*(t) = \vec{\lambda}_1(T - t) \text{ for } t \in \langle 0, T \rangle$$

- a vidíme, že

$$\frac{\partial \vec{\lambda}_1^*}{\partial t} = -\frac{\partial \vec{\lambda}_1}{\partial t} \quad \text{a} \quad \vec{\lambda}_1^*(0) = \vec{\lambda}_1(T)$$

- adjungovanou rovnicí (6)-(7) lze tedy transformovat na tvar

$$\frac{\partial \vec{\lambda}_1^*}{\partial t} = \vec{\lambda}_1^* \frac{\partial \vec{f}(\vec{u}(T - t, \vec{p}), T - t, \vec{p})}{\partial \vec{u}} - \frac{\partial h_1(T - t)}{\partial \vec{u}} \text{ na } (0, T), \quad (8)$$

$$\vec{\lambda}_1^* |_{t=0} = -\frac{\partial h_2}{\partial \vec{u}} \quad (9)$$

Adjungovaná rovnice

Výpočet gradientu pak vypadá takto:

1: vyřeš primární rovnici

$$\begin{aligned}\dot{\vec{u}}(t, \vec{p}) &= \vec{f}(\vec{u}(t, \vec{p}), t, \vec{p}) \text{ na } (0, T), \\ \vec{u}(0, \vec{p}) &= \vec{u}_0(\vec{p}),\end{aligned}$$

2: za pomoci znalosti primárního řešení vyřeš adjungovanou rovnici

$$\begin{aligned}\frac{\partial \vec{\lambda}_1^*}{\partial t} &= \vec{\lambda}_1^* \frac{\partial \vec{f}(\vec{u}(T-t, \vec{p}), T-t, \vec{p})}{\partial \vec{u}} - \frac{\partial h_1(T-t)}{\partial \vec{u}} \text{ na } (0, T), \\ \vec{\lambda}_1^* |_{t=0} &= -\frac{\partial h_2}{\partial \vec{u}}\end{aligned}$$

3: s pomocí znalosti $\vec{\lambda}_1^*$ dopočítej $\lambda_1(t) = \lambda_1^*(T-t)$ a $\vec{\lambda}_2 |_{t=0} = \vec{\lambda}_1 |_{t=0}$

4: nakonec spočítej samotný gradient

$$\nabla_{\vec{p}} J^*(\vec{p}) = \int_0^T \left(\frac{\partial h_1}{\partial \vec{p}} - \vec{\lambda}_1 \frac{\partial \vec{f}}{\partial \vec{p}} \right) dt + \frac{\partial h_2}{\partial \vec{p}} |_{t=T} + \vec{\lambda}_2 \frac{\partial \vec{u}_0}{\partial \vec{p}}$$

Adjungovaná rovnice

Pro jednoduchost nyní předpokládejme, že je

$$\frac{\partial h_1}{\partial \vec{u}} = 0.$$

Pak je má adjungovaná rovnice tvar

$$\frac{\partial \vec{\lambda}_1^*}{\partial t} = \vec{\lambda}_1^* \frac{\partial \vec{f}}{\partial \vec{u}} \text{ na } (0, T),$$

což vede na exponenciální řešení.

Adjungovaná rovnice

- To je velká nevýhoda tohoto přístupu, rovnice na intervalu $(0, T)$ často diverguje/exploduje (blow-up).
- Je to proto, že pokud špatně odhadneme parametry ODR, pak na celém intervalu $(0, T)$ vzniká veliká odchylka primární rovnice od zadaných dat a adjungovaná rovnice na to pak reaguje velkou citlivostí.
- Tato metoda je tak velice citlivá na dostatečně přesný počáteční odhad parametrů ODR.

Sparse Identification of Non-linear Dynamycs

Uvažujme ODR tvaru:

$$\begin{aligned}\dot{\vec{u}}(t) &= \vec{f}(\vec{u}(t), t, \mathbb{P}) \text{ na } (0, T), \\ \vec{u}(0) &= \vec{u}_0,\end{aligned}$$

Funkci f budeme hledat ve tvaru

$$f_j(\vec{u}, t, \mathbb{P}) = \sum_{i=1}^{q_j} p_i^{(j)} \phi_i(\vec{u}, t) = (\vec{p}^{(j)})^T \vec{\phi}(\vec{u}, t).$$

Zavedeme si matici naměřených dat v různých časech t_1, \dots, t_m

$$\mathbb{X} = \begin{pmatrix} \vec{x}(t_1)^T \\ \vdots \\ \vec{x}(t_m)^T \end{pmatrix} \in \mathbb{R}^{m,n},$$

a podobně matici derivací

$$\dot{\mathbb{X}} = \begin{pmatrix} \dot{\vec{x}}(t_1)^T \\ \vdots \\ \dot{\vec{x}}(t_m)^T \end{pmatrix} \in \mathbb{R}^{m,n}.$$

Dále si zavedeme bázi funkcí, ze kterých budeme \vec{f} vyjadřovat:

$$\Phi(\mathbb{X}) = \left(\vec{1} \ \mathbb{X} \ \mathbb{X}^2 \ \dots \ \mathbb{X}^d \ \dots \ \sin(\mathbb{X}) \ \dots \right) \in \mathbb{R}^{m,q},$$

kde např.

$$\sin(\mathbb{X}) = \begin{pmatrix} \sin(\vec{x}(t_1)^T) \\ \vdots \\ \sin(\vec{x}(t_m)^T) \end{pmatrix} = \begin{pmatrix} \sin(x_1(t_1)) & \dots & \sin(x_n(t_1)) \\ \vdots & \ddots & \vdots \\ \sin(x_1(t_m)) & \dots & \sin(x_n(t_m)) \end{pmatrix}$$

- \mathbb{X}^d je matice jejíž sloupcové indexy odpovídají všem možným polynomům složek vektoru $\vec{x}(t_i)$ pro $i = 1, \dots, m$.

Zavedeme ještě matici

$$\mathbb{F} = \begin{pmatrix} \vec{f}(\vec{u}, t_1, \vec{p})^T \\ \vdots \\ \vec{f}(\vec{u}, t_m, \vec{p})^T \end{pmatrix} \in \mathbb{R}^{m,n},$$

Pak má ale platit

$$\dot{\mathbb{X}} = \mathbb{F} = \Phi(\mathbb{X})\mathbb{P},$$

kde $\mathbb{P} = (\vec{p}_1, \dots, \vec{p}_n)$, kde $\vec{p}_i \in \mathbb{R}^q$.

Řešíme tedy úlohu

$$\mathbb{P} = \arg \min_{\mathbb{P}} \left\| \dot{\mathbb{X}} - \Phi(\mathbb{X})\mathbb{P} \right\| + \lambda \|\mathbb{P}\|_1,$$

což je lineární regrese.

Jako příklad si uvedeme Lorenzův atraktor:

$$\begin{aligned}\dot{x} &= \sigma(y - x), \\ \dot{y} &= x(\rho - z) - y, \\ \dot{z} &= xy - \beta z.\end{aligned}$$

Pak dostáváme

$$\dot{\mathbb{X}} = \begin{pmatrix} \dot{x}(t_1) & \dot{y}(t_1) & \dot{z}(t_1) \\ \dot{x}(t_2) & \dot{y}(t_2) & \dot{z}(t_2) \\ \vdots & \vdots & \\ \dot{x}(t_m) & \dot{y}(t_m) & \dot{z}(t_m) \end{pmatrix}$$

SINDy - příklad

Jako bázi zavedeme

$$\Phi(\mathbb{X}) = \begin{pmatrix} 1 & x|_{t_1} & y|_{t_1} & z|_{t_1} & x^2|_{t_1} & y^2|_{t_1} & z^2|_{t_1} & xy|_{t_1} & xz|_{t_1} & yz|_{t_1} \\ 1 & x|_{t_2} & y|_{t_2} & z|_{t_2} & x^2|_{t_2} & y^2|_{t_2} & z^2|_{t_2} & xy|_{t_2} & xz|_{t_2} & yz|_{t_2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x|_{t_m} & y|_{t_m} & z|_{t_m} & x^2|_{t_m} & y^2|_{t_m} & z^2|_{t_m} & xy|_{t_m} & xz|_{t_m} & yz|_{t_m} \end{pmatrix} \in \mathbb{R}^{m,q},$$

A následně

$$\mathbb{P} = (\vec{p}_x, \vec{p}_y, \vec{p}_z) \in \mathbb{R}^{q,n}.$$

- ① DiffEqFlux.jl – A Julia Library for Neural Differential Equations
- ② Ch. Rackauckas, M. Innes, Y. Ma, J. Bettencourt, L. White, V. Dixit, *DiffEqFlux.jl - A Julia Library for Neural Differential Equations*, arXiv:1902.02376.
- ③ V.M Alexejev, V.M.Tichomirov, S.V.Fomin, *Matematická teorie optimálních procesů*, Academia, 1991.