

Neural ODEs (Neural Ordinary Differential Equations)

Neural ODEs představují revoluční přístup k architektuře neuronových sítí, kde namísto specifikování posloupnosti diskretních skrytých vrstev definujeme spojitý vývoj stavu sítě pomocí **obyčejných diferenciálních rovnic (ODE)**.

Tento koncept byl představen v roce 2018 (Chen et al.) a získal ocenění za nejlepší příspěvek na prestižní konferenci NeurIPS.

Rozdíl mezi klasickou sítí a Neural ODE

Klasické sítě (ResNet)

V běžných reziduálních sítích se stav mění v diskretních krocích: $h_{t+1} = h_t + f(h_t, \theta_t)$
Kde h_t je stav v dané vrstvě a f je funkce (vrstva) s parametry θ .

Neural ODEs

V Neural ODEs tento vztah zobecňujeme do spojitého času. Změnu stavu popisujeme derivací:
 $\frac{dh(t)}{dt} = f(h(t), t, \theta)$ Pro získání výstupu v čase T pak síť „řeší“ tento systém od počátečního stavu $h(0)$ pomocí numerického řešiče (ODE Solver).

Hlavní výhody Neural ODEs

- Paměťová efektivita:** Při trénování není nutné ukládat mezivýsledky všech vrstev pro zpětnou propagaci (backpropagation). Neural ODEs mohou počítat gradienty pomocí metody „adjoint sensitivity“, což vyžaduje konstantní paměť bez ohledu na hloubku „sítě“.
- Spojité data a časové řady:** Ideální pro modelování dat, která přicházejí v nepravidelných časových intervalech (např. lékařské záznamy nebo finanční trhy), protože model může počítat stav v libovolném čase t .
- Adaptivní přesnost:** Během testování (inference) lze měnit přesnost řešiče. Pro rychlý odhad zvolíme nižší přesnost, pro kritické aplikace vysokou přesnost, aniž by bylo nutné síť přetrénovat.

Využití v praxi

Oblast	Aplikace
Fyzikální simulace	Modelování pohybu tekutin, planetárních drah nebo robotiky, kde platí fyzikální zákony.
Medicína	Analýza nepravidelně měřených dat od pacientů (např. srdeční tep v čase).

Oblast	Aplikace
Generativní modely	Základ pro spojité normalizační toky (Continuous Normalizing Flows), které transformují jednoduché distribuce na komplexní data.

Výzvy a omezení

- **Výpočetní náročnost:** Numerické řešení diferenciálních rovnic může být pomalejší než dopředný průchod klasickou sítí, zejména pokud je dynamika systému komplexní.
- **Stabilita řešiče:** Výběr správného řešiče (např. Eulerova metoda vs. Runge-Kutta) je kritický pro přesnost a rychlost modelu.

— *Související pojmy:* [Hluboké učení](#), [Vertex AI](#), [Architektury CPU](#) (vliv na efektivitu výpočtů)

From:
<https://serviceit.cz/> - IT ENCYKLOPEDIE

Permanent link:
https://serviceit.cz/doku.php?id=neural_odes

Last update: **2026/01/05 19:42**

