

Strojové učení v širším kontextu

Strojové učení (ML) představuje změnu paradigmatu v softwarovém inženýrství. Je to most mezi statistikou, informatikou a kognitivní vědou. V širším slova smyslu jde o automatizaci samotného procesu tvorby algoritmů.

1. Změna paradigmatu (Software 2.0)

Andrej Karpathy (přední vědec v oboru AI) označuje strojové učení jako **Software 2.0**.

- **Software 1.0 (Tradiční):** Kód píše lidé (např. v C++, Pythonu). Je čitelný, ale složitý na údržbu u komplexních úloh, jako je rozpoznávání obrazu.
- **Software 2.0 (ML):** Lidé definují cíl a architekturu (např. [neuronovou síť](#)), ale samotné parametry „píše“ proces optimalizace na základě dat. Výsledný „kód“ (váhy sítě) je pro člověka nečitelný, ale v dané úloze mnohem výkonnější.

2. Datová věda jako základ (Data Science)

ML nemůže existovat bez kvalitních dat. Širší kontext zahrnuje celý proces **Data Science**:

1. **Sběr dat (Ingestion):** Získávání surovin z logů, senzorů nebo uživatelských vstupů.
2. **Čištění (Cleaning):** Odstranění šumu a chyb (nejvíce časově náročná část).
3. **Feature Engineering:** Výběr nejdůležitějších vlastností dat, které mají na výsledek vliv.
4. **Trénování a Evaluace:** Samotné strojové učení.

3. Socio-ekonomický dopad

Strojové učení mění ekonomiku mnoha odvětví:

- **Personalizace jako standard:** ML umožnilo vznik „ekonomiky pozornosti“ (Netflix, TikTok), kde algoritmus zná uživatele lépe než on sám.
- **Demokratizace expertízy:** ML modely umožňují provádět lékařskou diagnostiku nebo právní analýzu v místech, kde chybí lidské experti.
- **Prediktivní údržba:** V průmyslu ML předpovídá poruchy strojů dříve, než nastanou, což šetří miliardy korun.

4. Limity a rizika (Teoretický rámec)

- **Problém „Černé skříňky“ (Explainability):** U hlubokých sítí víme, ŽE fungují, ale často přesně nevíme, PROČ se rozhodly konkrétním způsobem. To je problém v lékařství nebo soudnictví.
- **Přetrénování (Overfitting):** Situace, kdy se model „naučí“ trénovací data nazpaměť“ včetně jejich chyb, ale nedokáže zobecnit své znalosti na nové situace.
- **Kvalita dat (GIGO - Garbage In, Garbage Out):** Pokud model trénujeme na zaujatých nebo nekvalitních datech, výsledky budou stejně špatné nebo diskriminační.

5. Budoucnost: Směrem k AGI?

V širším kontextu je dnešní ML považováno za tzv. **Narrow AI** (úzkou AI). Současný výzkum směřuje k:

- **Transfer Learning:** Schopnost modelu využít znalosti z jedné úlohy pro jinou.
- **Few-shot Learning:** Schopnost učit se z minimálního množství příkladů (podobně jako lidé).
- **Multimodalita:** Modely, které současně chápou text, obraz, zvuk i fyzikální zákony.

Související články:

- [Strojové učení: Technické základy](#)
- [Umělá inteligence: Historie a filozofie](#)
- [Neuronové sítě: Motor dnešního ML](#)

Tagy: it ml data-science software-engineering ai futurology

From:

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

Permanent link:

https://serviceit.cz/doku.php?id=it:sw:strojove_uceni

Last update: **2026/01/02 20:32**

