

Testovací data (Test Data)

Testovací data představují nezávislou část datasetu, která slouží k finálnímu vyhodnocení kvality natrénovaného modelu. Jejich nejdůležitější vlastností je, že jsou pro model „**neviditelná**“ – algoritmus k nim nesmí mít přístup během procesu učení ani během ladění parametrů.

Účelem testovacích dat je simulovat reálné nasazení (produkci), kdy model dostává zcela nové vstupy od uživatelů.

1. Role v životním cyklu modelu

V rámci procesu rozdělení dat (Data Splitting) tvoří testovací data poslední instanci:

- **Trénovací data:** Model z nich čerpá znalosti.
- **Validační data:** Vývojář podle nich upravuje nastavení (např. hloubku sítě).
- **Testovací data:** Pouze pro závěrečné měření přesnosti. Pokud model na testovacích datech propadne, celý proces se musí vrátit na začátek.

2. Problém kontaminace dat (Data Leakage)

K **úniku dat** (Data Leakage) dochází, pokud se informace z testovací sady neúmyslně dostanou do trénovacího procesu. To vede k falešnému optimismu – model vypadá jako geniální (má 99% úspěšnost), ale v realitě selhává, protože si jen „pamatuje“ testovací otázky.

Jak zabránit kontaminaci:

- Striktní oddělení dat hned na začátku projektu.
- Zajištění, že se duplicitní záznamy nenacházejí v obou sadách.
- Časové oddělení (u časových řad): trénování na starších datech, testování na nejnovějších.

3. Metriky vyhodnocení na testovacích datech

Na základě výsledků z testovacích dat vypočítáváme metriky, které nám řeknou, jak je model dobrý:

Metrika	Význam	Příklad
Accuracy (Přesnost)	Procento správně určených případů.	„Model trefil 95 % obrázků.“
Precision	Schopnost neoznačit chybně negativní případ jako pozitivní.	„Kolik z označených spamů byl skutečně spam?“
Recall (Úplnost)	Schopnost najít všechny pozitivní případy.	„Našel model všechny nádory na snímcích?“
F1 Score	Harmonický průměr mezi Precision a Recall.	Ideální pro nevyvážená data.

4. Zobecnění (Generalizace)

Hlavním cílem použití testovacích dat je ověřit **schopnost zobecnění**.

- Pokud má model skvělé výsledky na trénovacích datech, ale mizerné na testovacích, došlo k **Overfittingu** (přetrénování). Model se naučil šum a specifické chyby trénovací sady, místo aby pochopil obecné pravidlo.
- Pokud jsou výsledky špatné u obou sad, jde o **Underfitting** (podtrénování) – model je příliš jednoduchý.

5. Zlatá pravidla pro testovací data

- **Nikdy netrénovat na testovacích datech:** Jakmile se model „podívá“ na testovací data, ztrácí tato sada svou objektivitu.
- **Stejná distribuce:** Testovací data musí pocházet ze stejného prostředí jako trénovací (např. pokud trénujete na fotkách z profi foťáku, nemůžete testovat jen na rozmazaných fotkách z mobilu).
- **Dostatečná velikost:** Testovací sada musí být dost velká, aby výsledky byly statisticky významné (obvykle se volí 10–20 % z celkového objemu).

Příklad z praxe: Představte si testovací data jako závěrečnou zkoušku ve škole. Trénovací data jsou učebnice. Pokud učitel dá do zkoušky přesně stejné příklady, které jsou v učebnici, nezjistí, zda žák látku pochopil, nebo se ji jen naučil nazpaměť. Proto musí být ve zkoušce (testovacích datech) příklady nové, ale ze stejné látky.

[Zpět na AI rozcestník](#)

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

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

Last update: **2025/12/31 14:26**

