


← Současné metody detekce grav. vln

Na data lze nahlížet třemi způsoby:

- časová řada
 ↗ v současnosti nejpožívanější transformatorová architektura
- spektrogram
 ↗ doména CNN - jako dráček
- frekvenční prostor
 ↗ komplexní Fourierova transformace, používají se vícevrstvé perceptronové sítě na bínch ve frekvencích



GENEROVÁNÍ TRÉNOVACÍCH DAT

Výpočet z Einsteinových rovnic zbytečně náročný, používají se náhradní modely pro generování h

→ existují (i čistě empirické) modely pro vygenerování průběhu vlny

~~Proces~~

Pomocí modelů se nageneryjí průběhy pro různé kombinace parametrů; přičte se šum (modelování šumu také velký problém?)

Musí se cílit také na správnou klasifikaci dat, kde žádná vlna není, pouze šum

DETEKCE SIGNÁLU V DATECH

Neuronová síť pro vstupní data $h(t)$ (nebo spektrogram) udá pravděpodobnost, že data obsahují vlnu, a případně parametry ~~signálu~~ signálu

Pravděpodobnost ale musí být dostatečně vysoká, aby se jednalo o pozitivní detekci

Tato prvotní detekce je ideální doménou konvolučních neuronových sítí (v časové řadě)

HODNOCENÍ ÚSPĚŠNOSTI MODELŮ

- Přesnost - poměr úspěšných detekcí ke všem bémům (může být zavádějící u nevyvážených dat)
 ↗ kladných i záporných?
- Preciznost - poměr ~~kladných~~ kladných detekcí ke všem signálům s vlnou
-
-
-
-

KLASIFIKACE GLITCHŮ

Různé typy; můžou se projevit např. jen v některých filtrech nebo doménách (Fourier, Q-transform)

Gravity Spy Project - dobrovolnický projekt pro manuální klasifikaci, když si program není rady

ODHAD PARAMETRŮ ZDROJE

1. Přímá regrese

Vytřénovaná neuronová síť na interpolovaných nebo vypočítaných signálech, vyplivne odhadnuté parametry zdroje (ale bez pravděpodobnosti / odchylek)

2. Odhad Bayesovského rozdělení

Složitější, ale obecnější model, který dává pravděpodobnostní rozdělení ve všech parametrech pro daný signál

Používá se metoda normalizujících toků - začne se s Gaussovským rozdělením a trénink obnáší vytvoření posloupnosti infinitesimálních izomorfických transformací, které z gaussovy udělají stejný tvar, jako mají data. Transformace poté lze aplikovat inverzně na nová data a získat normální rozdělení, resp. něco jemu blízké.

NEURONOVÉ SÍTĚ S FYZIKÁLNÍM MODELEM

Obecně neuronové sítě při trénování hledají $\cos$ - ztrátová funkce nemusí vystihovat minimum, nebo se zaseknout ~~ve~~ ve špatném lokálním minimu

→ ztrátovou funkci můžeme modifikovat tak, aby penalizovala nefyzikální řešení

$$\text{např. } \mathcal{L}_{\text{phys}} = h(t; M_{\text{pred}}) - h(t; M_{\text{in}})$$

$\uparrow$ hmotnost předpovězená neuronovou sítí $\uparrow$ hmotnost použita při generování dat

Zákonů zachování typicky také dobrými příspěvky

INTERPRETOVATELNOST

Je problematické ověřit, zda se neuronová síť naučila správnou fyziku, protože se v principu jedná o zvláštní kombinace zvláštních funkcí

Obdobně, ve vnitřnostech neuronové sítě nedokážeme najít případnou novou fyziku

Validace se provádí např. vkládáním jen části signálu, kde víme, že se z nich dají zjistit konkrétní parametry

SOUČASNÉ PROBLÉMY

- Trénování na simulovaných datech ne vždy funguje na reálných datech
- Nejzajímavější detekce jsou jevy, které jsme nikdy předtím neviděli, ale pro trénování bychom je museli vidět již dříve
- Interpretovatelnost
- Kombinace s dalšími typy detekcí (multi-messenger astronomy)

BUDOUCÍ VÝVOJ

- základový model, nezávislý na detektoru a dobře vystihující fyziku
- učení bez učitele (nemusí se ručně klasifikovat trénovací data)

DOMÁCÍ ÚKOLY

- ① ^{složitý} sestavit neuronovou síť, která z vlny určí hmotnosti a spinu
- ② ^{jednoduchý}
 - i. Napsat esej o obsahu přednášky (2 strany)
 - ii. Pomocí PyCBC vygenerovat vlny pro binární černé díry