

Paskaita 1

Šiuo metu didelis dėmesys yra skiriamas Dirbtinio intelekto problematikai: šios technologijos galimybes, taikymams, jos vystymui (ar vystymuisi be žmonių pagalbos?).

DI (Artificial Intelligence AI)

Aptarsime, kokio vietą užima Masininis mokymasis (Machine learning) ir koks yra ML ryšys su kitomis technologijomis (real. žodžiai)

[Gilusi mokymasis (Deep learning)
Neuroniniai tinklai - jų taikymo pagrindai ir ML technologija]

GM - vyksta tada, kai kompiuteriai / mašinos mokosi naudodamos neuroninius tinklus (analogas neuronų žmogaus smegenyse)

DI yra nekslo šaka, orientuota
į masinę, gelincis imituoti protau-
janti / apsimelianty elgesi, kuriuos
šios mašinos sugeba priimti sprendimus
t.y. spresti suformuluotas pakankamai
abstrakčias sąlygas.

Paminėjus, kad kompiuteriai visada
buvo naudojami sudėtingų sąlygų
sprendimui, bet dažniausiai jie
naudojo konkrečius algoritmus greičiau
apibrėžose situacijoje. Visada naudojami
duomenys, kurie apibrėžia mus domian-
tanti situacija, algoritmai gali
analizuoti šiuos duomenis ar juos
apdoroti (modeluoti, prognozuoti), bet
ne išmochti, paaiškinti pasleptas
struktūras, ryšius, kuriuos patelbi
žmogaus smegenys.

DI svarbūs atkryvumi:

- a) paieška internete (paieškos mašinos, web search engines)
- b) kalbos atpažinimo mašinos
- c) automobilių valdymas / vairavimo automobilių sistemos (Tesla)
- d) strateginis žaidimų programos (Tachmentai, Go).

Nėra beakademijos gūvėtos rėbos, beuėras technologijās shorts DI, o beuėras laityti klasėuėleuėis technologijams

Pamėnėsimė bėndymams sėmėlėuėis žmogams sėmegėmų vėklp (uės uėdėgmas spėndėmų pėrėmėmų išskėrtėmų sėgėmų m sėmegėmų fėuėlėjėmė.

Mašėmėis uėdėgmas (akcentuojant statistėmėis mėtdus) domėnuojā DI sėmėlėmėmėse sėkėmėmėse.

MM - šai V kompiuterini, algoritmai,
kurie automatiškai atlieka paau-
dovui sukauptą patirtį ir duomenis,
kuriais gauna

Pastaba

Gilesni mokymaisi paversdama
neuronini, šiuo technologij, apuskaun
neuronini, šiuo labai svarbu sureti
pakaunus kele, reprezentatyri
duomeny. Idomen pr., bei genausi
šiuo mety, darbtine salumetu, zaidumu
programu bei apmokama (mokesu)
zaidama pati su saku!

Vieną pagrindini, MM technologij,
reandas statistika metodu strategiu

mokymos ir sprendimuy pvelimuo
elapuose

Tačiau būtina nagrinėti ir dar kelias sritis, kurios esmingai veikia įmonės MM.

- Tai:
- 1) matematinis optimavimas
 - 2) duomenų gavyba (data mining), kur naudojamos kurios mokymosi strategijos, pirmiausia strategija be mokymų

Galime bendriai apibrėžti, kad MM algoritmai yra tokie, kur algoritmas gebėjimas priimti sprendimus (prognozės tikslumas) - dideją (gerėja) sunkiau priimt algoritmo patikslinti (išanalizuoti) daugiau duomenų!

MM yra orientuotas į sprendimų/prognozės atlikimą, remiantis toms žiniomis/savyboms, kurios sukauptos mokymosi metu. Duomenų gavyba papildo šį gebėjimą - kur išlaikoma ši šiol nežinomy pasiepti savybių/ryšių, kurie yra duomenyse

Kaip matysime paskaitose ryšys tarp MM
ir optimizavimo yra p tiesioginis - daug
mokymon išdėstinių yra formuluojamu
kaip optimizavimo išdėstiniui.

Mokymon procese siekiama sumažinti
klaidų lygį tarp žmonių bei kompiuterio
lygiu ir kompiuterio patiklų variantų

Ryšys su statistikos metodais yra
labai, labai glaudus - todėl MM
paskaitose turėsime pabrėžti statistikos
& žinias. Tačiau šiuo metu šis metodas
psichologijos tikslas: statistikoje ir
patiklų duomenų konstruojame tikrus
duomenis būdams tikimybių pasiskirstymų
- t. y. laisvė, kad turime duomenų
apibūdinti didesnę populiaciją ir to formu
duomenų formuluojamu hipotezė apie
šios populiacijos savybes. MM siekiama nustatyti
ryšius (reštas, struktūra) tarp mokymon
duomenyse (o ne didesnio popul)

MM technologijoje skiriamas 3 didelės grupės (reikšis) tipus)

1. Masininis mokymasis su mokytoju (supervised learning)

Kompiuteriu pateikiamas duomenis
ir "mokytojo" nurodytas atsakymas / rezultatai.
Kompiuteris turi išmokti (susidaryti) taisykles, algoritmus), kaip generuoti
teisingus atvaizdarius.
(Regresijos modeliai, klasifikacija)

2. Masininis mokymasis be mokytojo (unsupervised learning).

Pateikiamas tik duomenys, be jokių
papildomų "etikečių" (labels).

Uždavotės - generuoti / paraišyti tam
tikras struktūras duomenyse (klaste-
rizuoti duomenis)

Aprašyti mokymosi be mokytojų pagrindinis tikslas (techninis) yra sukonstruoti populiacijai tikimybes tankio funkcijas ~~plot~~ (artim). (panaudojant šiuos duomenis).

$\int_a^b p(x) dx$ yra tikimybė, kad atsitiktinio dydžio reikšmė bus \in intervalo $[a, b]$.

3. Sustiprintas mokymasis (reinforcement learning)

Kompiuterio programai reikia dinamiškoje aplinkoje, kur ji siekia tam tikro tikslo (vaduoti automobilį, žaisti šachmatais)

Dinaminio proceso metu, programa gauna informaciją kaip jau sekasi (pelnas, apdovanojimas), ji stengiasi maksimalizuoti savo pelną

Ypač reikiamas dinaminio programavimo, genetiniai algoritmai.

Mokymasi su mokytoju:

a) Regresijos metodai - leidžia prognozuoti atlytinių procesų reikšmes (temperatūros pokyčiai, energijos poreikis, elektros grandinės apkrovos didėjimas)

b) Klasifikavimo metodai - prognozuoja žmonių reikšmes, procesų, galimus įgyti kelias reikšmes

(e. laiškas yra spausmas, ar ne, anglis yra gėrybėmis ar piktumais

~~u. t. t. t.~~

vėrdų (skaidis, raudis, grafius objektų) atpažinimas, kalbos atpažinimas

Mokymasi be mokytojo


Klasterizavimas yra vienas iš pagrindinių, ~~šiuo~~ metodikų

- ištome duomenyse paslėptą rasti, struktūrą
- grupuojame duomenis

Objektų atpažinimo uždaviniai

Genų sekų analizė

Rinkos analizė.



Esant dideliam duomenų kiekiui ir nemažai porcijų dideliam dydžiui apmokymų procesas gali būti labai lėgas. Tada dažnai naudojamas dar vienas standartinis žingsnis.

Duomenų porcijose sumažinama atskirtųjų komponentų skaičius ir paliekamas tik nedidelis jų skaičius (reikia „išinti“ tik svarbią informaciją).

Porz. biųjutiklis analizėje atliekama 400 matavimų skirtingais laiko momentais (esant fiktyviam medžiagų koncentracijai reikšmėms).

Standartinis metodas - pagrindinių komponentų analizė (Principal Component Analysis).

Biųjutiklis išdaro atvejų paliekamas 5-8 pagrindiniai komponentai.