

PŘÍRODOU INSPIROVANÉ ALGORITMY

- Víem s cílem - máme data s labelem
 - ↳ klasifikace
 - ↳ regrese ... chceme nějakou spojzon hodnotu
- Víem bez cíle - data bez labelu
 - ↳ clustering
 - ↳ generování podobných dat

Zpětnorazební víem

- agent se může naučit chovat se v nejlepším daném prostředí
- zpětná vazba = reward za akce (score nebo hru)

Zpětnorazební víem

- agent dělá akce, za to dostává odměny a mění tak svůj prostředí

Def: Markovský rozhodovací proces je čtverice (S, A, P, R)

- S ... stav
- A ... akce
- P ... $P_a(s, s') = \text{fst. přechod} \text{ do } s' \text{ při provedení } a \text{ ve stavu } s$
- R ... $R_a(s, s') = \text{odměna za } \rightarrow$

Markovský působení: P závisí pouze na a, s (ne na předchozích akcích...)

Def: Policy agenta je $\pi: S \times A \rightarrow [0, 1]$. Píše se $a \sim \pi(s)$

$$\hookrightarrow \pi(a, s) = \text{fst. když } s \text{ provedu } a$$

↳ pěstná distribuce

\Rightarrow cíl je maximalizovat celkovou odměnu

$$R^\pi = \sum_{t=0}^{\infty} \gamma^t \underbrace{R_{s_t}(s_t, s_{t+1})}_{r_t}, a_t \sim \pi(s_t).$$

↳ $\gamma < 0$... diskontní faktor \rightarrow aby se konvergovalo

Def: Hodnota stavu s je $V^\pi(s) := \mathbb{E}[R^\pi | s_0 = s]$

Hodnota akce ve stavu s je $Q^\pi(s, a) := \mathbb{E}[R^\pi | s_0 = s \text{ a } a_0 = a]$

\Rightarrow cíl: Najít π^* , aby $V^{\pi^*}(s) = \max_{\pi} V^{\pi}(s)$.

\rightarrow v možnosti Q může přecít nejlepší akci, ale potom málo explorační.

- ϵ -greedy policy: Aké bude správná podobnost?

$(1-\epsilon) \dots \underset{a}{\operatorname{argmax}} Q(s,a) \dots$ explozace

$\epsilon \dots$ náhodná akce ... explorace

- Monte-Carlo metody \rightarrow pro nalezení normy Q

\rightarrow děláme hodné simulaci - main Q $^{\pi}$, kde $Q^{\pi}(s,a)$: výplňte

\Rightarrow prověděte slavnou akci a pravidlo π , dokud nedojde do cíle
 \hookrightarrow někam si kopírujte, kolik to výplňte

\Rightarrow nakonec ještě hodnotu uděláme bladnou normu Q

- Q-learning

Bellmanovy rovnice:

$$V^{\pi}(s) = \mathbb{E}_{a, s_1} \left[r_0 + \sum_{s=1}^{\infty} \gamma^s r_s \mid s_0 = s \right] = \mathbb{E}_{a, s_1} \left[r_0 + \gamma V^{\pi}(s_1) \mid s_0 = s \right]$$

$$= \sum_a \pi(a,s) \cdot \sum_{s'} P_a(s, s') \cdot (R_a(s, s') + \gamma \cdot V^{\pi}(s'))$$

\hookrightarrow možné akce \downarrow možné přechody $\downarrow r_0$

Zlepšení: prověděte s s akci a , dostanete r a přenesu se do s'

$$V(s) \leftarrow V(s) + \alpha (r + \gamma V(s') - V(s)) , \quad \alpha \text{ je parametr učením}$$

\rightarrow Q-learning výplývající Q^{π} , funguje stejně

$$Q^{\pi}(s, a) = \mathbb{E}_{s'} \left[r_0 + \gamma \mathbb{E}_{a'} [Q^{\pi}(s', a')] \right]$$

$\pi =$ reální nejlepší akci
 $\& Q$ pro daný stav

$$= \sum_{s'} P_a(s, s') \cdot (R_a(s, s') + \gamma \sum_{a'} \pi(s', a') \cdot Q^{\pi}(s', a'))$$

Zlepšení: \hookrightarrow learning-role \hookrightarrow nová hodnota \hookrightarrow původní hodnota

$$Q(s, a) \leftarrow Q(s, a) + \alpha (r + \gamma \max_a Q(s', a') - Q(s, a))$$

\hookrightarrow reální nejlepší akci co mám

SARSA

- Q-learning je smyčce pro zlepšení reprezentace nejlepší akci podle Q-matice
- ↪ policy je implicitně určena Q-maticí \Rightarrow je to off-policy alg.
- sarsa může argumentovat i vícenásobnou policy:

$$Q(s, a) \leftarrow Q(s, a) + \alpha (r + \gamma Q(s', a') - Q(s, a))$$

\downarrow \downarrow
 $a \sim \pi(s)$ $a' \sim \pi(s')$

\Rightarrow Q-learning využívá $a := \arg\max_a Q(s, a)$

Problém: Musí být hodnoty stavů, spojité stavový řádek \Rightarrow diskretizace

Deep Q-learning - DQL \rightarrow Q nepřeje možností trénovat

→ řeší problém hodnoty stavů, místo Q-matice má neuronku

\Rightarrow myšlenka: neuronka dostane stav a vrátí vektor odměn

↪ pro každou predikuje odměnu \Rightarrow vlastní řádek Q-matice

↪ policy = využívá nejlepší akci

→ mechanismus: vkládám si hodnoty

$s \dots$ kde jsem byl
 $a \dots$ co jsem udělal } experience buffer T
 $s' \dots$ kam jsem se dostal } ↪ kladné za několik her
 $r \dots$ odměna } → parametry této neuronky

\Rightarrow chci $Q^\theta(s, a) = r + \gamma \max_{a'} Q^\theta(s', a')$

↪ $Q^\theta(s, a)$ znamená: výhodnost situace s a vzhledem k reálnému řádku a

\Rightarrow loss = $\sum_{(s, a, s', r) \in T} \underbrace{(r + \gamma \max_{a'} Q^\theta(s', a') - \underbrace{Q^\theta(s, a)}_{{\text{odhad}}})^2}_{\text{realita}} \dots \text{MSE}$

Target network: abych si ty parametry θ neměnil pod rukama při trénování

Tak mám 2 situace: Q^θ a Q^ϕ .

\Rightarrow myslím θ ale během akce $\max_{a'} Q^\phi(s', a')$

\Rightarrow jednou ráci a nastavim $Q^\theta := Q^\phi$

• DDPG = Deep Deterministic Policy Gradient

→ řešení spojité akce: „oloč rolamem o 17° “ místo „rohu do prava“

⇒ máme 2 sítě

Q^{θ} ... učí se odmítnout

μ^{ϕ} ... učí se akce $\rightarrow \mu^{\phi}(s)$ vráti akci a , co maximizuje Q

$$\rightarrow \text{loss } Q = \sum_{(s, a, s', r) \in T} (r + \gamma Q^{\theta}(s', \mu^{\phi}(s')) - Q^{\theta}(s, a))^2 \quad \downarrow \text{vlastní policy}$$

→ učení μ : chci aby dávala co nejlepší akci pro stav s

$$\Rightarrow \max \mathbb{E}_s [Q(s, \mu(s))] \quad \text{pomocí gradient-descent}$$

• Policy gradient metody

→ policy ~ sítě (funkce) s parametry ϕ

↳ chceme maximizovat celkovou odmítnutou $\mathbb{E} [\text{celková odmítnutá reakce}]$

→ dá se najít gradient téhle věci a optimizovat ho pomocí

↳ vyskytuje se tam kumulovaný odmítnutý $G_s = r_s + r_{s+1} + \dots + r_T \rightarrow$ konec

! Edyť je G_s velké, tak rozhodně hodnotu ∇ může být velká

→ trenuje se to vlastní

• Actor-critic

→ místo G_s použijeme něco jiného ... treba přimé $Q(s, a) \approx \text{DQL}$

→ něbo advantage:

$$A(s, a) := Q(s, a) - V(s)$$

↳ generuje odmítnutou reakci
↳ odmítnutá reakce mi přinese konkrétní akce

→ sítě pro V ... actor, vybírá akce \rightarrow trenují formou

→ sítě pro V ... critic ... řídí jak dobré jsou stav, kam jsou reakce

↳ A se dá využít bez $Q \Rightarrow$ nepotřebujeme sítě pro Q

• Asynchronous Advantage Actor-Critic - A3C

↳ paralelizace sítě ... hráče víc než jednoho, průměrné výhry

EVOLUČNÍ ALGORITMUS

• Genetický algoritmus

pedimex = posloupnost $0 \alpha^1$

→ písek: Součet posloupnosti S ... chci $S' \subseteq S$ aby $\sum S' = \ell$

$$\text{fitness} = -(k - \sum x_i s_i)^2 \quad \text{pedimex} = \{0, 1\}^{181}$$

Q :: chci max fit

Algoritmus:

1. $P_0 \leftarrow$ náhodná populace

2. While not happy:

3. $f \leftarrow$ fitness (P_S)

4. Pro $i = 0, \dots, |P|/2$:

$p_1, p_2 \leftarrow$ selekce (P_S, f)

$\sigma_1, \sigma_2 \leftarrow$ křížení (p_1, p_2)

$s_1 \leftarrow$ mutace (σ_1)

$s_2 \leftarrow$ mutace (σ_2)

$$P_{S+1} = P_S \cup \{s_1, s_2\}$$

→ bud může zahrát
dělat novou populaci
nebo nejprve udělat
mixing - pool

• Selekce: Rulecková

$$p_i = \frac{f_i}{\sum_j f_j}$$

x

Ternárnová

1. $p_1, p_2 \leftarrow$ náhodný pedimex
2. vyhrajte ten s větším fitness

• Křížení

1) uniformní: každý náhodný bit je s sebou rodičem

2) jednobodové:

3) m-bodové:

↳ dědičí i vše rodičů


• Mutace: s nájazdem sancí flipnu i-tý bit

Složitější hledání řešením

- kategorie $k \in [n]$... rozcestník bit
- permutace hod. 1 ($1, 2, \dots, n$)
 - ↳ řešba památkami si cesty v grafu - obchodní cestigraf

- mutace:

- probodání 2 hodnoty
- shift pod posloupnosti: $\underline{1} \underline{2} \underline{3} \underline{4} \underline{5} \rightarrow \underline{1} \underline{4} \underline{2} \underline{3} \underline{5}$
- rotace $\underline{\dots \dots \dots \dots \dots}$: $\underline{1} \underline{2} \underline{3} \underline{4} \underline{5} \underline{6} \rightarrow \underline{1} \underline{2} \underline{5} \underline{4} \underline{3} \underline{6}$



zpravidla
cesta
obch.-cest

- křížení = crossover

- sbládání permutací ... velká změna
- rozbíjení na cykly a počet je fiksovaný } ne moc
- OK (order crossover) $\rightarrow \sim 2$ -cestné ř.

1	2	3	4	5	6	7	8	9
4	5	2	1	7	9	3	6	8
2	4	5	1	7	9	3	6	8
1	3	2	4	5	6	7	9	8
2	1	3	4	5	6	7	8	9

\rightarrow doplňte 10, aby to byla plná řada

- PMX (Partially mapped crossover)

1	2	3	4	5	6	7	8	9
4	5	2	1	7	9	3	6	8
4	2	5	1	7	9	3	8	6
1	3	2	4	5	6	7	9	8
2	1	3	4	5	6	7	9	8

\rightarrow 10 cest k zdroji, výpočty
 \rightarrow jinak mi řešení pro běžení
segment definuje nothing

- ER (Edge Recombination) - slouží pro obchodního cest.

\rightarrow pro každou vrchol můžeme sestavit řadu řadících

- * 1: 2 9 7
- * 2: 1 3 5
- * 3: 2 4 9 6
- * 4: 3 5 8
- * 5: 4 6 2
- * 6: 5 7 3 8
- * 7: 6 8 1 9
- * 8: 7 9 6 4
- * 9: 1 8 7 3

\rightarrow vybíráme vrcholy s nejméně sousedy \rightarrow řadidlo stejné
 \rightarrow pořadí vrcholů řešení \rightarrow místní

4 \rightarrow 5 \rightarrow 2 \rightarrow 3 \rightarrow 6 \rightarrow 1 \rightarrow 7 \rightarrow 8 \rightarrow 9

- Spojita optimalizace * spoj. jedinec \in m-rozmížd. kontinuální interval \mathbb{R}
jedinec $\in \mathbb{R}^n$, fitness $f: \mathbb{R}^n \rightarrow \mathbb{R}$
 - Křížení $\hookrightarrow f$ nemusí být spojita, ale ten prostor má
 - 1-bod, 2-bod ... něco moc
 - aritmetické
$$\vec{\sigma}_1 = w\vec{f}_1 + (1-w)\vec{f}_2$$


$$\vec{\sigma}_2 = (1-w)\vec{f}_1 + w\vec{f}_2$$

křížení obal
 - 1) $w \in (0, 1) \Rightarrow$ konverguje k prvnímu \rightarrow jedinec \in hule (populace)
 - 2) $w \in (-1, 2) \rightarrow$ musí se do datového rozsahu obarvit
 - mutace
 - 1) unbiased ... postře regeneruje nové číslo z toho intervalu
 - 2) biased ... upraví hodnotu na danou pozici
$$\hookrightarrow x_i \leftarrow x_i + \sigma \cdot N(0, 1) \rightarrow$$
 normální rozdělení

\downarrow
 konstanta
 - Evoluční strategie
 - spojuje jedince, evoluje i jejich hyperparametry toho algoritmu
 - \rightarrow třeba σ \rightarrow jak ho rovnat?
 - 1) moc velké \Rightarrow vlastně dílčím unbiased
 - 2) moc male' \Rightarrow pomalu konverguje
 - \rightarrow dává i jiné postupy různost \Rightarrow v 10 generaci $\sigma = 0.99$
 - 1/5-pravidlo: chci, aby $\approx \frac{1}{5}$ jedinců byla lepší než rodice
 - \hookrightarrow pokud jich je moc lepších \Rightarrow snížit σ
 - \hookrightarrow málo \Rightarrow snížit σ
 - $\dots \sigma \approx 0 \Rightarrow \frac{1}{2}$ lepší ale nikam se nedostane

Neseparabilní funkce


→ funkce je separabilní = lze jednotlivé proměnné optimalizovat nezávisle na sobě



$$x_i \sim \mathcal{O} N(0, 1)$$

→ předpokladem, že fce roste stejně ve všech směrech

Nesepravidelní:



→ lze použít kovarianční matici
co říká, že na sobě závisí drozice proměnných

Diferenciální evoluce

→ příspěk jde se vyrovnávat s nesepravidelností

→ předpokládám, že populace má proboly které mají fce

→ vyberu 4 rodice $\vec{\mu}_1, \vec{\mu}_2, \vec{\mu}_3, \vec{\mu}_4$

$$\vec{\sigma}' \leftarrow \vec{\mu}_1 + c \cdot (\vec{\mu}_2 - \vec{\mu}_3) \quad \dots c \in (0, 2), \text{ často } 0.8$$

$$\vec{\sigma} \leftarrow \text{uniform křížení } (\vec{\sigma}', \vec{\mu}_4, \lambda)$$


→ fce, že vyberu $\vec{\sigma}$

→ relativní frekvence asymptotické

podud $f_{\text{fit}}(\vec{\sigma}) > f_{\text{fit}}(\vec{\mu}_4)$:

nahradi $\vec{\mu}_4$ v populaci tím $\vec{\sigma}$

⇒ v podstatě tato je mutace $\vec{\mu}_4$



separabilní
lze optimalizovat
ve složkách

GENETICKÉ PROGRAMOVÁNÍ - Lineární

jedinec = posloupnost instrukcí v nějakém technologickém progr. jazyce
 ↳ jazyk "slash /A" ... jednoduchý assembler (na Cihabu)

- 2 registry - F float
 ↳ I int ... používá se na adresaci

- famílie ... fóle


instrukce: input, save, add, output, m, jump
 ↳ F \leftarrow input ↳ I \leftarrow m

↳ soudí jumpům se může recyklovat \Rightarrow pojednává doba je hrazena rázem

- křížení: sebehodnotné, m-hodnotné
- mutace: změna instrukce

Kartézské GP *

→ maticka $m \times m$



Gramatická evoluce *

→ máj progr. jazyk = berlekampova gramatika

$$\text{Expr} \rightarrow \text{Var} \mid (\text{Expr} + \text{Expr}) \mid (\text{Expr} * \text{Expr}) \mid \sin(\text{Expr}) \quad \text{mod 4}$$

$$\text{Var} \rightarrow x_1 \mid x_2 \mid x_3 \quad \text{mod 3}$$

→ jedinec = posloupnost čísel: 2 4 5 2 3 1 2 4 1 2

→ různy rozdíl mezi nejdrejšími metotinály

$$E \xrightarrow{2} (E * E) \xrightarrow{4 \equiv 0} (V + E) \xrightarrow{5 \equiv 2} (X_3 * E) \xrightarrow{2} (X_3 * E * E) \xrightarrow{3} (X_3 * \sin(E) * E)$$

Problemy:

- a) na konci může docházet k nemovitým → udeľávám jedinec dosť dlouho
- b) společně se dělají mutace a křížení - 1 změna \Rightarrow úplně jiný následek

Symbolická regrese - učení s učitelem

* Vstup: množina dvojic $(\vec{x}, y) \rightarrow$ čer mají f aby $f(\vec{x}) = y$
 \Rightarrow minimalizují $\sum (f(x_i) - y)^2 \dots \text{MSE}$

\rightarrow výmyslní operátory, co s ním používou: +, -, *, exp, sin, ...

\rightarrow sám řeší třeba sám Kartesijm GP / Gram. ev. nebo SGP

Stromové genetické programování

• Terminál: vstupy x_1, x_2, \dots

konstanty: -1, 0, 1, 2 ... jen když nejdůležitější

• neterminál: +, -, ...

\hookrightarrow další si může vyrobit

\rightarrow generování stromu

1) full: málokdy vytvoří strom daného blouby \rightarrow vše tam musí být terminál

2) grow: $\xrightarrow{\quad} | \xrightarrow{\quad} | \xrightarrow{\quad}$ s daným # neterminálů

\Rightarrow výška se do frunívá půl na půl

• Křížení: prohození podstromu

• mutace:

1) nahrazení n-árního neterminálu za jiný $\ominus \rightarrow \oplus$


2) nahrazení terminálu

3) rozšíření stromu: nahrazení neterminálu jeho listem

4) změna stromu: $\xrightarrow{\quad} | \xrightarrow{\quad}$ máhodlným stromem (mugem)

\rightarrow omerání velikosti jedince \swarrow penalizace fitness
 \searrow nositarem limita na bloubu / # net.

• automatizace def. fce - ADF




\rightarrow algoritmus může vytvářet nové neterminály - ADF

\rightarrow pro ADF ještě omezíme pouze terminál a met.

\rightarrow jedinci kříží svou RAINY i ADFem

\rightarrow ADF se keředicky mohou rodit, ale musíme se vyhnout cyklu



Typování GP

- je + semanticka dan návíc typ
- metamínaly obsahují informace co herou a vracejí

$<, >, ==, !=$ (float, float) \rightarrow bool

$+, -, *, /$ (float, float) \rightarrow float

$||, \&$ (bool, bool) \rightarrow bool

if-then-else (bool, float, float) \rightarrow float \rightarrow Semantický operátor

- výčtem a množením stejně, ale musíme udržet typem kompatibilitu

Evidence pravidel

- chci objekty rozřadit do kategorií ... kdežto stávky mají → tah

- možnost pravidel: podle výběru na stav → tah

→ jedinec = vektor rukou k pravidlu

↳ výhodnou cestou = vyberu tah co má nejvíce celkovou výhodu

NEURONOVÉ SÍTE

- preprocessing dat \rightarrow standardně nějaké $x_1, \dots, x_n \rightarrow y$

• číslové působení \rightarrow měřítkovat na interval $[0, 1]$

↳ normalizace = odečíst \bar{x}_m a dělit std. dev.

• kategorické působení \rightarrow např. 5 kategorie a $x_i=2 \Rightarrow (0, 1, 0, 0, 0)$

- člověk hodnotí - klasifikace \Rightarrow kategorie \uparrow

regrese \Rightarrow člověk hodnotí


Def: Softmax: x_1, \dots, x_n : $x_i \mapsto \frac{e^{x_i}}{\sum_i e^{x_i}} \in (0, 1)$, součet = 1
 ↳ ten nejvíce nejmí nejvíce pravděpodobnosti

→ loss funkce je fak crossentropy

↳ chci aby se ta nejvíc roklasifikovala do správné kategorie

$$\Rightarrow y = (0, 0, 1, 0)$$

$$p = (0.1, 0.3, 0.5, 0.2) \Rightarrow \text{loss} = -\ln(0.5) = -\sum_i y_i \ln(p_i)$$



Perceptron




focita' nejpre aktivaci $\xi := b + \sum_i x_i w_i$

\Rightarrow funkce aplikuje aktivaci f $f: \mathbb{R} \rightarrow \mathbb{R}$

f máže byt třífa $x \mapsto \begin{cases} 0, & x \leq 0 \\ 1, & x > 0 \end{cases}$

\rightarrow Aby dělal separaci dat může využít prostor \mathbb{R}^m



$$n=3: ax_1 + bx_2 + cx_3 + \text{bias} = 0$$

$f(\dots) = 0 \Rightarrow \text{mod}$


$f(\dots) = 1 \Rightarrow \text{fud}$

účem: $w_i \leftarrow w_i + r \cdot (y - y_0) x_i$... $(y - y_0) = \begin{cases} 0 & \dots \text{spina} \\ 1 & \dots \xi \text{ je malo} \\ -1 & \dots \xi \text{ je moc} \end{cases}$

p. účem \downarrow label \downarrow co myslí

upravit

Dvojité neur. síť = neverbalní perceptron = MLP




aktivaci fci:

$$\bullet \text{relu}(x) = \max(0, x)$$

$$\bullet \text{sigmoid}(x) = \frac{1}{1 + e^{-\lambda x}}$$

$$\bullet \tanh(x)$$



Gradient descent - zdeřívají loss fci $L(\vec{x}, \vec{y}, \vec{w})$ podle ruky

"backpropagation" a jde ve směru ráfneho gradientu \Rightarrow do minima

$$\Rightarrow w_i \leftarrow w_i - \lambda \cdot \frac{\partial \text{loss}}{\partial w_i}$$

$$\Rightarrow \text{příklad MSE: } L = \frac{1}{2} \sum_i (y_i - t_i)^2$$

Co zdeřívají podle ruky moci / poslední sloužit na výstupu / výstupu vlastnosti

$$\frac{\partial L}{\partial w_{je}} = \frac{\partial L}{\partial y_e} \cdot \frac{\partial y_e}{\partial \xi_e} \cdot \frac{\partial \xi_e}{\partial w_{je}} = (y_e - t_e) \cdot \frac{\partial f(\xi_e)}{\partial \xi_e} \cdot x_j$$

\hookrightarrow ráfci na f

\Rightarrow pro skryté vrstvy existují nějaké rekurentní vzorce

RBF sítě - Radial Basis Functions

MLP ... neuron focička $f(\sum_i w_i x_i)$

RBF ... $\rho(\|\vec{x} - \vec{c}\|)$ a aktivace $\rho(x) = e^{-\beta x^2}$



Kernel vstup

RBF

střed neuronu, $\|\cdot\|$ je norma ... třeba Eukl.

MLP

Gaussian



\rightarrow c_i jsou ideálně "výjde" středy clusterů

\rightarrow je to robustnější než klasická kmenová vzdálenost

\rightarrow Trénování:

1) K-means pro nastavení středů a parametru β

\hookrightarrow když máme data rozdělena do clusterů

\hookrightarrow pro k neuron (střed) $\beta_i := \frac{1}{2\tilde{\sigma}_i}$, kde $\tilde{\sigma}_i$ = průměrná vzdálenost dat v daném shluhu od středu c_i

2) Trénování výstupního vztahu

\rightarrow Jen 1 vztah a focička něco lineárního \Rightarrow staci lineární regrese

Algoritmus K-means - něčí bez větve

\rightarrow hledá clustery v datech ... pro jeden neuron cluster \mathcal{S}

1. náhodné vyber k bodů jako středy

2. while not happy:

3. přiřadit k data point k nejbližšímu středu

4. pofočíš středy (střed = průměr dos & něma přiřazených)

\rightarrow máme 10 RBF funkcií $\Rightarrow k=10$, $\tilde{\sigma}_i$ = průměrná vzdálenost dat přiřazených ke středu c_i od něj



Recurrentní neuronové sítě

→ někde v tom grafu je cyklus

Vstup: nějaký posloupnost x_1, x_2, x_3, \dots

→ mezi nimi délkou - méní se

→ křížka slouží k user inputu



konec = nějaký ukončovací token

ve věci řečka.

výstup téhož neuronu dostane jeho vstup z dřívšího kroku

Trenování:

→ rozvinutá síť → case a dlejším gradient descent \Rightarrow backprop. through time

! problém: při gradient descent se gradient \rightarrow fiedchoví vstupy nasobi' vahou

$w_2 < 1 \dots$ vanishing gradient

$w_2 > 1 \dots$ exploding gradient

řešení: nebudu ho včítat -- ESN

mashupem na 1 a násleďně jinak ... LSTM

Echo State Networks - ESN

Vstup: vektor délky n

→ má vnitřní stav = vektor délky m

$$\begin{matrix} m \\ m \end{matrix} \cdot \begin{matrix} m \\ m \end{matrix} = \begin{matrix} m \\ m \end{matrix}$$

\Rightarrow náhodně vygenerované matice $(m+n) \times m$

školení se nevzdělávají

\Rightarrow na začátku málo délky vnitřní stav

Využití: se vstupem přidán vnitřní stav, vynásoben maticí

\Rightarrow dostanu nový vnitřní stav

\rightarrow potom ještě MLP vstava jeho n RDF síti $\times \boxed{\text{matice}} \rightarrow y$

\Rightarrow vlastní transformace vstup délky n na vektor délky $m \dots n > m$

Trenování: matice se nevzdělávají

MLP lineární regresi nebo gradient descent

Long Short Term Memory Networks - LSTM

- mísíto neuronů LSTM bude → pamatují si nejaky stav
- bude dít:


\vec{C}_{t-1} ... předchozí stav

\vec{h}_{t-1} ... reurentní výstupy s předchozího kroku

x_t ... vstupní token

↳ siříce se vždy vstupy na sebe: $[h_{t-1}, x_t]$

- novic má možnost s vahami → mísitelní po složkách



$$\vec{f}_t = \sigma(W_f \cdot [h_{t-1}, x_t] + \vec{b}_f) \quad \dots \text{forget}$$

$$\vec{i}_t = \sigma(W_i \cdot [h_{t-1}, x_t] + \vec{b}_i) \quad \dots \text{input}$$

$$\vec{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + \vec{b}_c) \quad \dots \text{kandidát na nový stav}$$

$$\Rightarrow \vec{C}_t = \vec{f}_t \circledast \vec{C}_{t-1} + \vec{i}_t \circledast \vec{C}_t \quad \dots \text{nový mísitelný stav}$$

$$\vec{O}_t = \sigma(W_o \cdot [h_{t-1}, x_t] + \vec{b}_o) \quad \dots \text{output}$$

$$\Rightarrow \vec{h}_t = \vec{O}_t \circledast \tanh(\vec{C}_t) \quad \dots \text{výstup záležitě output a stav}$$

→ W_f, W_i, W_c, W_o jsou matice s parametry




→ b_f, b_i, b_c, b_o jsou bias vstupy

→ \circledast je pro složkách, obdobně σ (sigmoida) a \tanh

→ trénování: rozbahem nebo gradient descent

↳ mísitelný stav není milde působivá vaha

⇒ nové problém s vanishing/exploding gradient

- Konvoluční sítě - spracování obrázků
 - Konvoluční vrstva → jediný písek obrázek filtrem ... $m \times n$ možností
 ↳ 3×3 filtr má jen $3 \cdot 3 + 1$ parametrů
 - $R \cdot 8 \times 8$ obrázku vytvoří 6×6 obrázek
 ↳ následně se dělá padding
 - v jedné vrstvě máme nás. mít filtry
 ⇒ $\#$ je rovnou výškou následujícího
 - RGB ... 3 barevné kanály
 - Grayscale ... 1 kanál
 - Grayscale, který projdé conv2D vrstvou s 16 filtary ⇒ 16 kanálů
 - když do conv2D vrstvy jde obrázek s k kanály, } $k=3 \Rightarrow 3 \cdot 3 \cdot 4 + 1$
 tak 1 filtr je $m \times n \times k$ senzor
 - 
 ⇒ násobek razy srovnává i hmotnost
 ReLU (signálový funkční blok a sekce)
 - pooling vrstva - změnuje rozměry obrázků
 - 
 ↳ Max Pooling = násobek maximum
 - násobení 2×2 filtrov, kdežto s jehož se fórováním = stride
 se stride = 2
 - 
 → používá se maxpooling a zmenšuje dimenze obrázků a zvýší $\#$ kanálů
 - násobek 10 násobitou a spracování písek dense vrstvy

Motiváciu vizu - FGSM = Fast Gradient Sign Method

- mám obrázek a sič' ho přiřadí do kategorie
- spočítám gradient loss pro každý pixel v obrázku
 - ↳ tedy pro 256×256 a RGB (3 kanály) je $256 \cdot 256 \cdot 3$ pramejch
- pro udělání zmeněn v obrázku a nerobím řádky
 - $\rightarrow R=0 \vee 255, G=0 \vee 255, B=0 \vee 255$
 - ↳ 3 kanály & 2 zmeněn → 8 barev pro řádky
- de 4 kanálu píšu zmeněné gradienty v daném pixelu
- \Rightarrow obrázek + $\frac{1}{128} \cdot \text{řádky}$ = motiváciu obrázek \rightarrow maximizuj loss
↳ malé E , pro kterého se vypada stejně

Přenos uměleckého stylu

- mám foto, chci aby byla ve stylu Picasso
- učíme se, že určitě sič'
- aktivace ve vnitřních vrstvách ~ obsah
 - korelace mezi aktivacemi ~ styl
- optimalizační problém - chci vytvořit obrázek, který
 - má při průchodu sičí aktivace jako na fotce
 - má korelace mezi aktivacemi jako obrázky s daným stylem

Generative Adversarial Networks

- mají dvě sítě
- Generátor: generuje obrázky, snáší se maximizovat chybou diskriminátorem

- Diskriminátor: snáší se rozhodnut, zda obrázek má vstupu faktički drženou hodnotu, mělo je od generátoru
 \Rightarrow 2 kategorie \Rightarrow loss = crossentropy

NEUROEVOLUCE

→ výrobíme / řešíme neurony pomocí evolučních alg.

Evoluce sítí

- máme sítě s fixní topologií ... vlastní sponzor optimizace
- pro něm s mísiteli je gradient-descent superior
- specifikace něm

- problém je rychlosť postřelu (nová dlnba)

→ evoluční alg. se snadno paraleluje $\Rightarrow \# \text{jedinců} = k \cdot \# \text{jader}$

postřelu s různými odnětami

- odnět dostane až na konci, ne přebírá

↳ v něm se bude trénovat moc dlouho

↳ hodnota algoritmu se bude propogovat formou

- evolučním algoritmu nedá, že odněta je na konci

↳ fitness stejně počítá až při výrobě nové populace

NEAT = Neuro-evolution of Augmented Architectures

- jedinec = neuronová síť s dalším funktem vytváření a výstupu

↳ formuje si vely a brany

↳ (odhad, kód, výběr, výběr, inovation nro.)

mutace:

1) upravení sítě - pomocí evoluce sítí

globalní ID

2) přidání brany - spojí 2 nespojené vely

3) přidání vely - rozdělí mezi oba brany:



4) disable brany

krížení - používá innovací čísla

$f_1: 123456$ $f_2: 1234567910$ \rightarrow kromě je pod sebe

$\Rightarrow f_1: 12345 | 6$ $f_2: 12345 | 67910$ $\xrightarrow{\text{málo hodnot}}$ $f_1(f_2) > f_1(f_1)$

málo hodnot
vyberu z obou

→ výběru z obou s některou fitness

chrání inovaci


→ když vznikne nová brana, když se k nějž nerozbije → mění fitness

→ jedinci jsou rozděleni do PRUTŮ podle podobnosti

→ fitness jedince se dělí velikostí jeho druhu


⇒ po krížení a mutacích vyberu z druhu nějakých reprezentantů a po tom přidám

• Hyper NEAT



→ máme „substrát“ neuronů rozšířených
 v $\{0, 1\}^2$... hinspace

→ nabíráme formou NEATu sítě, která
 dostane souřadnice dobové hodnoty a dále rámu



⇒ v 1 iteraci vytvoříme

hrany s ráhami podle meri všech drobném mluv
 ↳ malé ráhy zahrádím nízku

⇒ loss této sítě \approx fitness té NEAT sítě - chci ji minimalizovat

• Deep NEAT

- jednouž nejsou určeny hrany ale celé vrstvy

↪ formou evoluce třídy hyperparameterů seich vrstev

• Co Deep NEAT

- formou Deep NEATu vytvoříme moduly

- následně formou NEATu vytvoříme blueprints pro sítě

⇒ pak dle blueprintu nstruktuříme moduly, což samy mají

- ↳ abecedně několikrát, první loss funkce pro
 nabírávání je moje fitness

• Novelty Search

- náš cíl je, aby se evoluční jedince rozbudoval podle fitness +
 noveltu novelty = jak moc nové je to jeho řešení

→ blíže... řešení na nové místo \Rightarrow vysoká novelty

→ je dobré shránit novelty a fitness \rightarrow explorace \times exploitation

↪ novelty mě dajíme různouho optima

↪ fitness řídí náš aktuální optimum

PŘÍRODNÍ ALGORITMY

Particle Swarm Optimization - PSO

→ inspirováno pohybem hmyzu plávání ryb

částice = 2 rektory $\in \mathbb{R}^n$... folha \vec{x} a rychlosť, \vec{v}

↳ novic si pamatuje nejlepší místní pozici \vec{p}_b

↳ globálne mám užívam globálnu nejlepší pozici \vec{g}_b

→ hľadám pozici mienej mŕtvej fitness $f: \mathbb{R}^n \rightarrow \mathbb{R}$

→ částice sa hýbe v prostredí a je pristupována k nim obýva miestami

$$\vec{v} \leftarrow \omega \cdot \vec{v} + \varphi_p \cdot r_p (\vec{p}_b - \vec{x}) + \varphi_g \cdot r_g (\vec{g}_b - \vec{x})$$

• $\omega, \varphi_p, \varphi_g$... parametry

• r_p, r_g ... random $\in (0, 1)$

smer

↳ môže mať i \vec{r}_p = random $\in (0, 1)^n$

↳ pre násobok f složiek

$$\vec{x} += \vec{v}$$

Topologie - jde spolu částice komunikovať

• globálny - vkládám si globálne nejlepšiu riešenie \vec{g}_b

• geometrické - komunikuj spolu částice, cez jučšie o sebe

• socialny - píšem je vieno, ktoré částice sa komunikujú

→ hodne rýchle konverguje, ale nedostane sa k lokálneho optimu

Ant Colony Optimization - ACO

metafora

- mravenci prokrmávají postředí a překlýdají feromon
- ↳ když mají mnoho řidíků ⇒ bohaté feromony
- ostatní mravenci sledují a mají tendenci jít tam, kde je bohaté feromony
- typicky se formují na hledání cest v grafu - obchodní cestující

jedna iterace:

Hamiltonovu kružnici

1) Mravec vytváří nějaké řešení

1. záčne v náhodném vrcholu → rozboduje se, kam dal

→ pravděpodobnost přechodu $x \rightarrow y$ je úměra

$$(F_{x,y})^\alpha \cdot (V_{x,y})^\beta \quad \dots \alpha, \beta \text{ jsou konstanty nákladnosti}$$

$F_{x,y}$ = feromon na bránu $x-y$

$V_{x,y}$ = vzdále za bránu $x-y$ → $\frac{1}{\text{doba}(x,y)}$

2) aktualizace feromonus

$$U_{x,y} \leftarrow Q \cdot \sum_k \frac{1}{L_k} \quad \dots k \text{ je mravec co prošel přes bránu } x-y$$

$F \leftarrow (1-S) \cdot F + U$ $L_k = \underline{\text{Evolutivé řešení}} \dots \text{dilu nejlepší cesty}$

Q je konstanta $S = \underline{\text{míra = lepší}}$
vypátrání feromonus ... $S = 5\%$

⇒ Mravenci mohou aktualizovat feromony, lepší řešení ⇒ více feromonus

ARTIFICIAL LIFE

- soft → simulace
- hard → roboti
- wet → v laborce re skumava

• Cellular Automata


- politko má jednu z k barev a frandla na svém bočním

Game of life

frandla: mrtvá & #sousedů = 3 \Rightarrow obživé
živa & #sousedů $\notin \{2, 3\}$ \Rightarrow umírá

1D-automaty

→ fórum maríky proje frandla s konceptem 1:



$$\Rightarrow 2^2 = 2^8 = 256 \text{ možných 1D automátů}$$

→ existuje Turing complete automat

Langton's ant

→ černobílý nekompl. grid, na kterém běhá mravec

- černá \Rightarrow flip color, turn left, step
- bílá \Rightarrow flip color, turn right, step

→ mravec nyní, že běhá náhodně

→ conjecture: mravec vždy rázne pravou polohu pravou, která rysovi „dálnici“ a mravec už se do něj nevede

→ Stále je Turing complete

Simulace kroku-Tierra

- jedinec ~ program (pravou pravou instrukci) + paměti

- jedinec ~ program (pravou pravou instrukci) + paměti

\Rightarrow 32 instrukcí - aritmetika, hodiny, slovy, NOP0, NOP1

\hookrightarrow jump je následující forma: NOPi \rightarrow hledá vždy complement

jump \rightarrow hledá | \rightarrow jedinec může iště hledat jiného jedinece, ale ne může
NOP0 NOP1 | \rightarrow na rázne jedinec, co se přiřadí k jinému
NOP0 NOP1 | \rightarrow malá řádka, že se nějaká instrukce změnila
NOP1 NOP0 | \rightarrow je tam smysl co robí jiné jedinece
NOP0 NOP1 | \rightarrow rozdělí „porakisi“, cofací různé hodnoty jiných jedinců?

JUMP