

# Korespondenční Seminář z Programování

28. ročník

KSP

Květen 2016

## Milí řešitelé a řešitelky!


Poslední letošní série se vám právě dostává do rukou. Už se určitě řešíte na to, jak brzy začnou příznamy a budete si moct dát od školy pauzu, ale přesto si sdotovkyte ještě pár chvílí i pro řešení úloh z tohoto letáku. Vždyť vás za vyřešení úloh a získání dostatečného počtu bodů můžeme **pozvat na Podzimní soustředění**, a to se vyplatí!

Navíc připomínáme, že každému řešiteli, který v tomto ročníku z každé série dostane alespoň 5 bodů, darujeme propisku, blok, tužku, a možná i něco navíc. Tak si to poslední sérii nechte.

**Termín série: Pondělí 13. června 2016 v 8:00 SELČ** (CoLTEx má termín stejný)

**Oddevzávání:** Přes web na adrese <https://ksp.mff.cuni.cz/submit/>

**Odměna série: Sladkou odměnu pošleme každému, kdo získá z alespoň šesti úloh alespoň dva body.**



řešitel	škola	ročník	série	celkem
56.-59. David Blažek	SPSÚžabPH	3	1	8,0
Luce Kubíčková	GFXSaldyLI	2	1	8,0
Antonín Praml	G Strakon	3	1	8,0
Zuzana Svobodová	G PvdlnOS	4	2	8,0
60. Eliška Viěnská	GHadnov	1	1	7,7
Kristýna Moudrá	GÚstavaPH	3	1	6,9
Adam Husník	GArabskáPH	2	1	6,0
61. Lukáš Mřčan	GČeskáČB	2	1	6,0
62. Lukáš Mřčan	GČeskáČB	2	1	5,8
63. Lukáš Beneda	GČeskáČB	2	1	5,0
64.-65. Ama Šebestíková	GČeskáČB	1	1	5,0
Petra Štefaníková	GOLgHavl	4	1	4,8
66. Michael Bausano	GTršš	4	1	4,5
67. Jarkub Matěna	GČeskolPH	4	4	4,0
68. Martin Zoula	GNaдкаPH	4	4	3,7
69. Ondřej Borysek	GJaroslBO	3	2	3,3
70. Jiří Müller	G.Rondnice	3	1	3,0
71. David Nápravník	GLiomařPH	3	1	2,5
72. Peter Matra	G KošiceS	4	1	2,2
73.				1,0

## Pátá série dvacátého osmého ročníku KSP

Tento příběh zavřete příběhy uplynulých sérií. Pokud vám něco nebude dávat smysl, přečtete si minulé úhly :-)

\*\*\*\*

Will Knight, vedoucí výzkumné časoprostorové výzkumné se utvornuté sebnl se země a oprášil ze sebe suze. Ještě než k němu skrz zalehlé uši dolehlo houkání strážní, ušel, jak všedno kolem zběsle bláka. To nebude dobře, pomyslel si.


„Will, jsi v pohodě? Willie?!” ozval se neodbytné hlas z mlčkomu. Will hrbl po tlačítku a přitom se rozbížel okolo. To, co si v dalších minutách poskládal ze svých zápisků, ze stavu okolí a z toho, co mu řekli z druhé strany spojení, nebylo vůbec dobré.

Table měl být první experiment, kdy časem posloužou človek, konkrétně Willa. Zatím vysílá jen několik automatických sond. Ale asi selhal časoprostorový generátor a jádro generátoru, ve kterém se teď Will nacházel, se už vůbec nenačítalo ve stejném čase jako zbytek jeho týmu. Nikdo vlastně nevěděl, kde (a kdy) se ocitlo. Jediné, co měl k dispozici, byly údaje z několika časových můstků ve stěnách generátoru a spojení přes časoprostorový interkom.

### 28-5-1 Zaměřování místnosti 9 bodů

Výzkumný tým získává souřadnice od časoprostorových májků instalovaných v jejích stěnách. Místnosti posumné v čase. Bolnužel přijímají více sad údajů a potřebují rychle odlišit, které sady souřadnic jsou chybné a které by skutočné mohl označovat místnost.

Výzkumníci ví, že místnost má obdélníkový tvar a májky jsou instalovány v jejích stěnách. Od vás by potřebovali pomoc s tím, jak rychle určit, jestli všechny dané body leží na nějakém (jakkoliv otočeném) obdélníku, nebo ne. Souřadnice bodů jsou libovolná reálná čísla, zokrouhlená nejméně. Například pro body [4, 4], [2, 3], [3, 1], [0, 5], [1] a [4, 1, 5] na levém obrázku takový obdélník nalezneme, pro body [0, 2], [1, 1], [4, 1], [1, 3], [3, 4] a [5, 3] napravo ne.



Výzkumníkům se sice povedlo zjistit, že je místnost je-


nom fázové posunutá a leží na okraji otevřeného časového nitru, ale v zachráně Willa se nedostali o nic dál. Navíc skomínající generátor už dlouho časový vln pod kontrolou udržel a nikdo nevěděl, jak velké škody v čase by jeho vypuknutí se kontrole mohlo způsobit.

Umlukající chladící kapalina z generátoru hvostila stále silnější a silnější ledový pontak na jádře z jeho části a kryształ dříhla v jádru byl nebezpečně popraskaný. Na opravu by stacel jakýkoliv dostatečně velký dříhový kryształ, problém kvěl v tom, že k Willovi nemohl nic dostat. Ale jeden z výzkumníků dostal skvělý nápad – Willovi tak skvělý nepřipadal – a to, aby si Will obstaral potřebné věci v minulosti.

A tak se stalo, že se Will znovu postavil na plošinu ve středě generátoru, zadoufal, že kryształ table jednu cestu ještě zvládne, a stiskl tlačítko ovládaní na své levé ruce.

\*\*\*\*

Se zbledkem se zjevil na nějaké louce. Byla mu nepřijemná zima a nechtěl, kde se ocitl. Kus vedle ale žongloval nějaký človek s pohobněná a Will se rozbíhl, že si nějakou upříči. Vyhledal si jednu opuštěnou a rozbíhl se pro ni. Ale zrovna v tu chvíli se chlapek otočil a začal ji brát do ruky. Will ho v rozběhu odstrčil, pochopení popadl a nabral to směrem k nejbližšímu lesu.



Chlapek se za ním rozbíhl a byl asi lepší běžec než Will. Pomalu ho začal dohánět, a tak Will za běhu hrbl po mánipulaci na ruce. Šlok časem dělat nechěl, ale několika minutám přerušit by ho šelstát mohl. Stejně je chěl použít k prozkoumání většího území.

KSP pro vás připravují studenti Matematicko-fyzikální fakulty Univerzity Karlovy.

### Webové stránky:

<https://ksp.mff.cuni.cz/>

### E-mail:

[ksp@mff.cuni.cz](mailto:ksp@mff.cuni.cz)

### Diskusní fórum:

<https://ksp.mff.cuni.cz/forum/>

Chcete-li s námi komunikovat bezpečně, můžete si ověřit náš HTTPS certifikát – jeho SHA1 fingerprint je: E9:DB:EE:C6:62:BC:14:DE:09:E4:E8:97:DC:36:0E:87:B3:50:B0:01.




matfyz

## 28-5-2 Místní přesuny 11 bodů

S pomocí lokálního transportéru se může Will přemísťovat mezi libovolnými dvěma body, které ho zajímají. Při průniku okolí by rád navštívil  $N$  bodů na mapě nacházejících se v konkrétní poloze – to jsou takové body, které můžeme všechny umístit na obvod nějakého konvexního mnohoúhelníku, neboli napnout kolem nich gumičku tak, aby všechny body obepjala zvenku.

Na přesunu mezi dvěma body spotřebuje Will kolik energie, jak jsouň body od sebe na mapě daleko (počítáme vzdálenost vzdálenost čarou). Chce-li začít v libovolném bodě, navštívit všechny ostatní body a spojitěovat přitom co nejméně energie.

Vynasřete algoritmus, který mu pomůže najít výše popsanou cestu. Niže můžete vidět ukázkou bodů v konvexní poloze a nejlepší nalezené cesty mezi nimi (plná čára značí cestu, čárkovaná napnutou gumičku).



*Po seřazení chlapíka učelá Will ještě pár skoků po okolí, než zaměřil svoji časoprostorovou pozici, a poslédním skokem se ocitl v nějakém dimenzí sklápě.*

„Dílna, švečel!“ zamumlal se počítu a šel se podívat, jestli by se mu něco nabídklo. Cestou si všiml tlamě klace u temném rohu, ale neměňoval jí pozornost. Našel kladičko, brnsné nůžky na pléč a chěl už odčítat, když mu ale něco nedalo, otočil se a pozorněji se podíval na klac. Umrít byl muž, k smrti vystrašený muž!

Will vyskočil na nějakou klac, z narámkového počítace vytáhl žhavou bryčelci jehlu a začal zpracovávat nřže. Nakonec za ně tlu a vyprtl je.

V tom zaskchl na schodech kroky a rozhádl se rychle zmát. Otočil se k muži v klac, řekl jenom „Učel!“ a sám se rychle vyhádl s pochodití v ruce ke schodům, zadávaje přitom sekvenci k časovému přesunu na minipočítaci.

Těsně, než došel ke dveřím, vyšel z nich druhý muž. Teď už se přesunu nedalo zabránit a Will muži nechtěl ublížit, tak se ho pokusil odstrčit do bezpečné vzdálenosti a vyběhnout z domu. V plíce schovali po něm muž natáhl ruku, ale přenesl se tu chvíli se obouhy nabíly a okolo Willa vyposřla modrá koule...

\*\*\*

Ojceul se v nějaké jesykní, ale přesunem neprošel sám. Před něj dopadla na zem zutehřatelá lidská ruka. „Sakra!“ zablcl a pak si všiml, že v jesykní je ještě nějaký římský voják pohřbený, s pohřbanou zbrojí a bez zbraně.

Potom ale jeho zájem přičákl geologický senzor za pasem, který se rozbíkl. V okolí se nachází velký lithologický křystál, přesně to, co hledal! Začal obíházet okoli zdi, než objevil pořádně velký kus. Ten s vřezostaným rozmachem kladička vykoppl, sroval ho, hodil ještě jeden pohled po skoprněm Římanovi a s šáskem náruvovotého tladička se přesunul zpět ke generátoru.

\*\*\*

S pomocí pochopné rozmrazí zamrzlé potraví, můžkami na plech se mu povedlo uvolnit vzpřícené kusy kovu nad

nonozojm veniklem a tím pak zastavil únik chladící kapuliny. Nakonec vygněnil křystál v jádru, ten původní už byl skoro rozpadlý na prach, a spojil se interkomem s ostatními.

Williovo nadšení bylo ale vzápětí zchlazeno – zbylek týmu mezitím zjistil, co způsobilo celou havarií. Křicová část generátoru se sama přenesla do minulosti, spádlu svry třídnouj obal a vybuchu, což pomázlo celý časoprostor. Se strojem času se půjde přenést do okamžiku těsně předtím, než dojde k vybuchu, ale je potřeba nové třídum k zastavení reakce.

\*\*\*


A tak se stalo, že se Will ocitl v podzemí nějaké banky 20. století před velkým seřsem, ve kterém měl být dostatečně velký kus čistého třídla získaný po dopadu nějakého meteoritu. Jenže trezor měl dost propovracovaný alam.

## 28-5-3 Trezor s alarmem 10 bodů

Alarm v trezoru je soustava řízně propojených obvodů, kterými teče stejnosměrný elektrický proud. Do jednoho místa soustavy je připojen záporný pól a od něj teče proud elektroni říznými cestami ke kladnému pólu připojenému také na jedno místo v soustavě. Pokud se tok proudu přeruší, alarm vyhlásí poplach.

Jednotlivé dráty jsou pospojovány v uzlech a pro každý drát víme, kterým směrem v něm teče proud. Opakřím směrem tečí nemůže a v zapojení nejsou žádné orientované cykly.

Zapojení alarmu může vypadat jako na obrázku níže. Najděte ve schématu zapojení všechny uzly, kterých se za zádných okolností nesmí dočkat (neboli takové, jeřichž přerušení by přerušilo všechny cesty od záporného ke kladnému pólu). V příkladu níže jsou takové uzly vyznačeny černě.



Willoni se povedlo alam rychle obeřít, byla to celkem zastaralá technologie, i když na svoji dobu docela špička. V trezoru nřkým nepozorovan vzal trezorovou schránku, kcl podle jeho zánamů mělo být třídum, otevřel jí a vyndal kus našedlého kovu. Pak ho schoval do kapsy kombinězy, schránku zase vrtil na místo a vyšel z trezoru ven.

Něž se dostal do domyng banky, zjistil, že je banka přepadena. No aspoň to lupiči budou mít o něco lečší, řekl si při pomyšlení na odlokovaný trezor a vyřazený alam u něm. Ale to už sdíal zrovnu po svém minipočítaci a skočil časem i s třídum v kapse dřívce, než si toho mohli kdokoli všimnout.

\*\*\*

Tentokrát se Will zjevil v nějakém skladu plněm zásoh jídla a hrozajm lomozem přitom shodl několik polk. Narazil si u toho nohu a zaklel: „Co to sakra? Vřídly jsem se měl vrátit zpátky!“

Teď o tom ovšem nebyl čas přemýšlet dál. Dveře do skladu byly vzpřícené, ale vykopnutí je otevřelo a jemu se nasypkl pohled na kuchyni. Současně s tím jeho minipočítacé zapípá, když v místnosti zaletekval pokrkný časový vřr. Jakoby vycházel z pláne visící na zdi. „Tohle si vezmu,“ zamumlal a pánece sundal z hřebku.

Nějaký kuchar se mu pokusil pánece vyřhnout z ruky, ale Will ho odstrčel a se slovy „Na tohle nemám čas,“ vyběhl

## Výsledková listina čtvrté série dvacátého osmého ročníku KSP

0.	řezitel	škola	ročník	serií	4-1	4-2	4-3	4-4	4-5	4-6	4-7	4-8	serie	celkem
1.	Jakub Pelc	G UherBrod	2	4	9	8	10	12	11	9	11	20	64,0	242,0
2.	Richard Hladik	GVOAMHanz	3	19	7	10	12	9	8	9	8	20	58,7	199,4
3.	Jiří Seljora	GVoďeraz	4	7	8	10	12	9	11	20	60,3	196,0	62,0	196,0
4.	Pavel Threk	GTomkovaOL	3	4	8	8	10	12	5	11	19	19	46,1	182,6
5.	Václav Volhejn	GKčepelaraPH	3	18									0,0	178,0
6.	Jan Bourček	GKčepelaraPH	3	8									27,7	169,0
7.	Stanislav Lukš	GPSnaukaPH	3	10									19,0	100,2
8.	Jonáš Fiala	GJungmannUT	3	4	3	1	0	12					97,5	97,5
9.	Daniel Herman	GŠKO	3	3	6	6	10	4	4	1	10	12	52,2	96,8
10.	Michal Třopler	G DřepEKMB	3	9									11,6	84,1
11.	Leonard Mentzl	GRič	3	2									0,0	76,9
12.	Petr Chmel	G Kralupy	3	4	2	8							24,1	8
13.	Josef Gařiček	SŠKRAMPar	3	3									0,0	71,1
14.	Václav Pavlíček	ZS Zřezec nD	0	4	3	4							16,0	67,8
15.	Jakub Třeták	Dolar Ac	2	9									19,0	63,0
16.	Lukáš Lukš	GPlakPL	4	2									0,0	62,9
17.	Lukáš Rozsypal	GÚstevanyPH	4	2	2	8	5						29,3	59,6
18.	Pavel Turinský	G Brandýs	3	8	7	8							15,2	51,5
19.	Přemysl Štastný	GZamberk	3	11	3	8	10	0					20,5	50,5
20.	Lukáš Vlček	GMBrušáPL	2	3									0,0	48,9
21.	Jiří Löffelmann	GLitomePH	2	2	3	8	10	0	2				26,6	46,6
22.	Václav Štrajer	GČeskotřPH	3	8									10,0	42,9
23.	Jakub Dobý	GMBrušáPL	2	3									0,0	41,5
24.	Jiří Vozar	G UherBrod	4	8	4								15,4	40,6
25.	Miroslav Hrabal	GTomkovaOL	2	2	2								0,0	40,2
26.	Viktor Fufala	GKčepelaraPH	-1	1	2	3,5	6						39,0	30,0
27.	Ján Čunýř	GŽilina	4	1	3	8	10	3					0,0	38,5
28.	David Žáček	GZbrovanyPH	4	1									26,4	36,4
29.	Ondřej Pudš	GŽilina	4	1									0,0	35,0
30.	Michal Kodad	ZŠilovaPH	0	4	4								5,6	31,1
31.-33.	Vladimír Bartovic	G AM Třava	4	2									0,0	29,2
	Vanda Hendrychová	GHEřovPH	4	1									0,0	29,2
	Jakub Lukš	GNAleřPH	3	4									0,0	29,2
34.	Jakub Suchánek	GOPavlovPHA	2	1	6								27,5	27,5
35.	Roman Beňo	GJHroncvaBA	3	2									0,0	25,6
36.	Vojtěch Hudec	GCTřebová	2	1	1	1	9	0	3	0,5	2		23,6	23,6
37.	Zdenko Čepan	GPartizams	3	2									0,0	22,6
38.	Michal Jřes	GGRNK	1	1									0,0	22,5
39.	David Uhláč	ednSOS PA	1	2									0,0	21,9
40.	Marco Souza de Joode	GNaStřoPH	3	1									0,0	20,8
41.	Sam Fritclauder	GKčepelaraPH	-1	1	2								0,0	20,3
42.	František Kmječ	G Brandýs	0	2									11,8	19,8
43.	Jan Pokorný	G Brucovny	4	8									0,0	17,7
44.	Filip Geib	GMMH LM	4	2									0,0	17,1
45.	Alexej Popovíc	SlovanyGOL	4	2									0,0	16,1
46.	Alena Tesarová	GVIDenskoBO	4	2									0,0	15,5
47.	Jan Kaitler	GČesBrod	0	2									0,0	13,4
48.	Josef Pospíšil	GÚstevanyPH	2	1	1								12,6	12,6
49.	Petr Gebauer	GMMěnik	2	1									0,0	10,6
50.-53.	Jan Goonik	GJŠkodýPR	4	4									0,0	10,0
	Martin Křicera	GGenerator	4	1									0,0	10,0
	Jan Přesnitz	GJanosěBO	3	1									0,0	10,0
	Filip Šohajek	GUVHradčičě	-1	1									0,0	10,0
54.	Jan Neumann	GNAleřPH	2	1									0,0	9,7
55.	Michal Rickwood	GCTřebová	2	2									6,0	8,3

Jako vystupní třídu vrátíme tu, která bude mít tuto podmíněnou pravděpodobnost nejvyšší.

Podmíněná pravděpodobnost jevu  $X$  za předpokladu jevu  $Y$  je definována jako pravděpodobnost, že se stane jev  $X$  i jev  $Y$ , lomeno pravděpodobnost, že se stane jev  $Y$ :

$$P[X|Y] = \frac{P[X, Y]}{P[Y]}$$

Dále použijeme *Bayesovu větu*, která říká:

$$P[X|Y] = \frac{P[Y|X] \cdot P[X]}{P[Y]}$$


V našem případě, kde  $X$  je  $C = s$  a  $Y$  je jev  $P_s = 1, P_s = -1, P_g = 1, P_g = -1, P_o = 1, P_o = -1, P_v = 1, P_v = -1$ , rozepíšeme podmíněnou pravděpodobnost následovně:

$$\begin{aligned} P[C = s|P_s = 1, P_s = -1, P_g = 1] &= \\ &= \frac{P[P_s = 1, P_s = -1, P_g = 1|C = s] \cdot P[C = s]}{P[P_s = 1, P_s = -1, P_g = 1]} \end{aligned}$$

Protože perceptorny jsou nahřetované nezávisle na sobě, budeme předpokládat, že  $P_{s1}, P_{s-1}, P_{g1}, P_{g-1}$  jsou *nezavisle náhodné proměnné*. To znamená dvě věci, jednak:

$$\begin{aligned} P[P_s = 1, P_s = -1, P_g = 1] &= \\ &= P[P_s = 1] \cdot P[P_s = -1] \cdot P[P_g = 1] \\ &= P[P_s = 1|C = s] \cdot P[P_s = -1|C = s] \cdot P[P_g = 1|C = s] \end{aligned}$$

$$P[P_s = 1, P_s = -1, P_g = 1|C = s] = P[P_s = 1|C = s] \cdot P[P_s = -1|C = s] \cdot P[P_g = 1|C = s]$$



Celá podmíněná pravděpodobnost, že daný kosatec je setosa, tedy bude vypadat takhle:

$$\begin{aligned} P[C = s|P_s = 1, P_s = -1, P_g = 1] &= \\ &= P[C = s] \cdot \frac{P[P_s = 1|C = s] \cdot P[P_s = -1|C = s]}{P[P_s = 1] \cdot P[P_s = -1]} \cdot \frac{P[P_g = 1|C = s]}{P[P_g = 1]} \end{aligned}$$

$P[C = s]$  je pravděpodobnost, že náhodně vybraný kosatec je setosa. Dataset obsahuje 50 kosatců setosa, 50 kosatců vericolor a 50 kosatců virginica, takže v našem případě  $P[C = s] = P[C = v] = P[C = g] = 1/3$ .

Tedy potřebujeme pro každý z perceptorů zjistit pravděpodobnost, že dá na náhodném kosatci výstup 1, resp. -1. Také potřebujeme všechny podmíněné pravděpodobnosti typu  $P[P_s = 1|C = s]$  (to je pravděpodobnost, že pokud náhodně vybereme kosatec typu setosa, perceptor na rozpoznávání typu setosa na něm vrátí 1).

Rozdělíme si dataset na trénovací, kalibrační a testovací množiny. Na trénovací množině nahraňujeme perceptor. Potom použijeme kalibrační množinu na určení pravděpodobnosti typu  $P[P_s = 1]$  a  $P[P_s = 1|C = s]$ .

Budeme si budovat třízvrstvé pole  $A$ . Jako první index bude *skutečná třída kosatec*, druhý index bude označení perceptoru, třetí index bude označovač, jestli perceptor vrátil 1, nebo -1. Pole nejdříve naplníme nulami, a pak pojedeme přes každý kosatec v kalibrační množině. Každý kosatec strčíme do všech perceptorů a podíváme se na jejich výstupy. Pro každý perceptor připočteme jedničku do příslušného místa v poli. Například, když uvidíme kosatec typu virginica, na kterém perceptor vrátil  $P_s = 1, P_s = -1, P_g = 1$ , tak připočteme jedničku k buňkám pole  $A[v][s][1], A[v][v][1], A[v][g][1]$ .

Takle pole použijeme k odhadnutí chybějících pravděpodobností. Konkrétně:

$$P[P_s = 1|C = s] \approx \frac{A[s][s][1]}{A[s][s][1] + A[s][s][-1]}$$

$P[P_s = 1] = P[P_s = 1|C = s] + P[P_s = 1|C = v] + P[P_s = 1|C = g]$   
Zbývá jenom jeden problém. Představme si, že na kalibrační množině se všechny perceptorny nahodou chovají stejně, tedy vrátí 1 na svém druhu -1 na ostatních kosatcích z kalibrační množiny. Potom bude naše kalibrace odhadovat, že například  $P[P_s = 1|C = s] = 0$ , protože v kalibrační množině nikdy nedával perceptor pro virginicu výsledek 1 zatímco kosatec byl ve skutečnosti setosa. Stejně tak  $P[P_s = 1|C = v] = 0$  a  $P[P_s = 1|C = g] = 0$ .

Zkusme potom do takhle zkalibrovaného modelu strčit kosatec, na kterém perceptorny dají výsledek  $P_s = 1, P_s = -1, P_g = -1$ . Když počítáme podmíněnou pravděpodobnost  $P[C = s|P_s = 1, P_s = -1, P_g = -1]$ , tak jeden ze členů, kterými náhoře násobíme, je  $P[P_s = 1|C = s]$ , což je 0, takže i celá podmíněná pravděpodobnost vyjde 0. Podobně se nám na mlu zvedají i pravděpodobnost  $P[C = v|P_s = 1, P_s = -1, P_g = -1]$  a  $P[C = g|P_s = 1, P_s = -1, P_g = -1]$ . Všechny podmíněné pravděpodobnosti odhadneme na 0 a nevíme nic. To je problém ze dvou důvodů: jednak by součet pravděpodobností měl vyjít 1 (protože přece ten kosatec musí nějak skutečně patřit), a druhak přece i takhle máme nějakou informaci, kterou bychom mohli nějak využít:  $P_g = -1$ , takže v virginica spíš nebude, než bude.

Naš program tedy používá takzvaný *old-one smoothing*. Je to jednoduché: místo toho, abydom začali s polem  $P$  plným nul, naplníme ho místo toho jedničkami. Tím zajistíme, že z modelu nikdy nevypadne pravděpodobnost nula, a to i když uvidí nějakou situaci, jaká není v kalibrační množině.

Program (Python 3):  
`http://ksp.mff.cuni.cz/viz/28-4-8-5.py`

Michal Pokorný

na ulici a zmlzel v temné boční uličce. Tam začal skomnat, proč ho pánev přitáhla na tohle místo.

Znapovul, že mimo pánev existuje ještě několik dalších časových vln, které se asi při výbuchu časové generátoru náhodně rozšířily po časoprostoru a hoří teď jakási časoprostorové mosty. Willa by zajímalo, co se bude při jejich odstranění s časoprostorem dít.

## 28-5-4 Časoprostorové mosty 10 bodů

Will zjistil, že různé časy a místa jsou náhodně svázaný časoprostorovými mosty. Každé místo v sobě nese jistý náboj energie a na počátku jsou všechna spojena tak, že tvoří souvislý graf.

Will si vymyslel pořadí, v jakém chce časoprostorové mosty odstranit, což povede k tomu, že původně souvislý graf bude rozpojit na menší a menší souvislé komponenty. Potéboval by zjistit, jak se bude množství energie v jednotlivých komponentách chovat vzhledem k odstranění mostů – vždy nás bude zajímat součet energie v rámci jednotlivých komponent.

Dostanete zadání, kolik energie je v každém místě, a pak pořadí časoprostorových mostů, ve kterém je chce Will odstranit. Pro každé operaci byste měli vypsat, co se stalo – buď nic (operace nerozpojila žádné dvě komponenty), nebo že došlo k rozpojení komponenty na dvě s takovou a takovou energií.

**Příklad:** Pokud budeme mít místa  $A, B, C$  a  $D$  s energiemi po řadě 1, 2, 3 a 4 a tato místa budou spojena do čtverce  $ABCD$ , tak následující posloupnost operací provede toto:

- Zrušení  $A - D$ : Nic.
- Zrušení  $B - C$ : Rozpojení na 2 části s energiemi 3 a 7.
- Zrušení  $A - B$ : Rozpojení na 2 části s energiemi 1 a 2.
- Zrušení  $C - D$ : Rozpojení na 2 části s energiemi 3 a 4.

Pro naplnování tabulky pořadí rušení časoprostorových mostů přišla řada na realizaci. Will pečlivě navořil, na jaké místo a čas se chce dostat, spustil přesunu...

... a ocitl se na místě, kde určitě nechtil být, v nějakém třmáském stanu. Potřásl hlavou a rozsořil si soňánu na ruce. Všiml si na posteli ležícího přeházeného Rimana. Naroomné se podobal tomu, kterého poklal v jaskyni. Tedy se začal zvedat, a tak si Will přiložil prst na ústa v prudkém gestu pro mlčení.

Pač si všiml vyhazeného stolu s množstvím kladiv, kleští a dalších věcí. Rozhodl se, že si pánev trochu vyčistí, urazil z ní aržadlo a chvilu ji upravenou, aby ji později mohl použít k rozčizení trída na menší kusy. Pač si sbalil věci a chystal se k odchodu, tentokrát jen aby udělal místní přesun.

Ale ještě než zmizel, ohlédl se po Rimanu. Ujistil se, že je to ten z jaskyne, z veškeru velké jeho postele popadl zbroj, šitá a zbratí a přesunul se.  
Přesun to nebyldalejší, chtěl jenom vyprat, jak hluboko v minulosti se ocitl a jak by měl nakalibrovat svůj minipocítač, aby už dělal časové přesuny přesně.

## 28-5-5 Kalibrace 7 bodů

Willby souhlasil např. v panství uložení seznam časoprostorových smířadnic upořádaných původně podle času. Ale vypadá to, že se vlivem nějaké poruchy seznam o něco zrotoval, a Will by rád zjistil, o kolik pozice.

Víme, že všechny časy jsou navzájem různě a že mimo zrotování se nic jiného nestalo. Z původní posloupnosti

1, 3, 4, 7, 9, 12, 13, 14, 15

tak mohla vzniknout třeba tato (zrotováním doprava o tři):

13, 14, 15, 1, 3, 4, 7, 9, 12

Buňžel jediné, co může Will dělat, je podívat se na nějaký index v posloupnosti, přesunout se časem na tyto souřadnice a určit, jakam odpovídá čas. Rád by zjistil, o kolik se posloupnost souřadnic přesně zrotovala, ale chce při tom vykonat co možná nejméně cest časem (neboli podívat se na co nejméně pozice v seznamu). Vašim úkolem je navrhnout mu nejlepší postup, tedy postup s řádově co nejméně nutnými přesuny časem.

Pro provedení několika pokusů, při kterých se živil s měčem v ruce před nějakým domem, pak ve sklepe Běého domu a nakonec v Dánskéjandlu, se Willovi konečně povedlo nakalibrovat správné minipočítač.

Tedy už mohl přesně zaměřit místo a čas, kde mělo dojít k výbuchu části časového generátoru, který se přenesla do minulosti. Nastavil s velkou přesností stejné místo a čas o pět minut předtím. Iridium pomocí kladiva a pánev přeměnil na druhnější kousky, které pánuoval nacpat do jádra, aby zastavil reakci. A potom zmáčkl tlačítko.

\*\*\*

Objevil se v docela běžném panáčkovaném obyčejném pokojí. Tedy byl by běžný, kdyby v půlce záti mentel podivný třmáctový kovový válec, který se materializoval uprostřed železkonovotného pomálu, jedním koncem v telezici. Válec vyžadoval hluboký pulzující zvuk, který se začal zrychlovat. Will odklopil brýle na bobu a doslova ho strazilo na zem teplo, které se vyzářilo ven. Bylo to velké, že skoro okamžitě chytl plamenem blížící záclony.

Will si zastínil obličej rukou a přiblížil se k vltá. Po otevření brny se ven vysunuly reguláční slohy, do kterých by se mělo umístit iridium, ale nepsunuly se všechny (a Will stejně neměl tolik kousků trída, aby je umístit do všech).

## 28-5-6 Slohy na iridium 11 bodů

Máme k dispozici  $K$  kousků trída a  $S$  slohů, do kterých se dá iridium umístit. Slohů je alespoň tolik, kolik je trída ( $K \leq S$ ), ale nejsou rozmístěny rovnoměrně. Všechny slohy leží na obvodu kruhu, ale jsou různě daleko od sebe. Iridium do nich potřebujeme rozmístit co možná nejvíce rovnoměrně. Za co nejvíce rovnoměrně rozmístění budeme považovat takové, které umístit každý kousek trída do jiného slohu a obsazené slohy budou co nejvíce od sebe – minimum ze vzdáleností mezi obsazenými slohy bude největší možné. Vzdálenost počítáme po obvodu kruhu (a to i přes začátek kruhu).

Slohy mají celočíslné souřadnice (mohly by to být třeba stupně) a našim úkolem je z nich rychle vybrat ty, které

použijeme. Pokud bude možných, několik stejně výhodných kombinací, můžeme použít libovolnou z nich.

Toto je praktická open-data úloha. V odezvádacím systému si necháte vygenerovat vstupny a odevzdaté příslušné výstupy. Zadejte jen na vás, jak výstupy vytvoříte.


**Formální vstupny:** Na prvním řádku vstupny budou tři čísla: obvod kruhu  $O$ , počet slotů  $S$  a počet kousků hrudka  $k$  umístění  $K$ . Na druhém řádku vstupny pak bude  $S$  celých čísel  $s_i$  označujících pozice slotů na kruhu z rozsahu  $0 \leq s_i < O$ . Všechna čísla budou oddělena mezerami a pozice budou seřazene od nejmenší.

**Formální výstupny:** Na jediný řádek výstupny vypíšete  $K$  mezerou oddělených indexů označujících sloty, které budou použity. Indexujeme od 0.

**Ukázkový vstupny:**  
36 10 4  
0 2 4 8 12 20 22 24 30 35

**Ukázkový výstupny:**  
1 4 5 8

Ukázkový vstupny a výstupny si můžeme přiblížit obrázkem níže. Použití sloty jsou označeny plným puntíkem, minimální vzdálenosti mezi použitými sloty je 8 a větší vzdálenosti dosáhnout nelze.



Co nejrychlejší uložte kousky hrudka do slotů a udělejte do označeného tláčka. Sloty se zasnuly a Will sebou pro jistotu praštil o zem. Umrtěť další bouřivé reakci a ven ujděte rozhovorné jiskry, které zaplily blízké okolí. Ještě že kombinací fasované u institutu byly nehořlavé! Po pár sekundách ale začala reakce ustávat, vřídum zdujgungovdu jako regulátor.

Will se uprostřed hořícího bytu postavil, podíval se na nypit už neškodný volec a abstrahoval u něm malou autole-strukční nálož. Pak s modrým zablasknutím z hořícího bytu rychle zmizel, dole už totiž zasklechl houkání střev.

\*\*\*

Z modré koule se vyloupl opět u místnosti s reaktorem, teď navíc s krátkým efektem slahných plánů, které utíhal s sebou. Uškábl se nad tím a spojil se s ostatními.

„Tak časově havarčí jsme snad zabránili, zamezili jsem vřubuchů!“ oznamil.

„Skvělé, tak teď tě už jenom dostat zpátky,“ přišla mu odpověď.

Aby vrátili místnost s reaktorem (a Willem) zpátky do normální fáze, museli omezit vzniklý časový útr. K tomu ale bylo potřeba provést velmi rychlých časoprotorových výpočtů u krátkém čase – když už se operace zabývá, nejdle přerušit ani pozastavit. Proto se rozhodli si něco předpočítat předem.

## 28-5-7 Tajemná operace 12 bodů

Máme počítat počítařské tajemnou operaci  $\otimes$ , o které víme jenom to, že je binární a asociativní (tedy že je to operace mezi dvěma prvky  $a$  a  $b$  nezáleží na uzavorkování operací ve výrazu). Co si pod tím představíte? Může to být například obyčejné násobení nebo sčítání, nebo třeba násobení modulu  $10^9$  (všimněte si, že se rozdíli od běžného násobení k tomuto neexistuje inverzní operace – není tedy možné dělit).

Běh programu se bude skládat ze dvou částí. V první části si můžeme program u nějakém rozumném čase předpočítat, co bude chřtít, a pak bude ve druhé (ostré) části běhu dostávat dotazy. Problémem je, že výpočet tajemné operace  $\otimes$  je náročný a během ostrého běhu zavádíme počítač v čase každého dotazu použít operaci  $\otimes$  pouze jedinkrát.

Na začátku běhu dostane program povně daná čísla  $a_i$  až  $a_n$ , na nichž si můžeme spočítat, co bude chřtít, a při ostrém běhu pak bude dostávat mnoho dotazů typu

$$a_i \otimes a_{i+1} \otimes \dots \otimes a_{j-1} \otimes a_j$$

neboli dotazů na výpočet operace  $\otimes$  na nějakém intervalu mezi  $i$  a  $j$  (kde  $i \leq j$ ).

Chceti bychom si tedy vybudovat nějakou datovou strukturu, která nám při ostrém běhu umožní odpovídat na takové dotazy pouze s jedním zavoláním funkce  $\otimes$ . Ale výpočet takové struktury by taky měl být co možná nejrychlejší.

Tato úloha je praktická a řeší se ve vyhodnocovacím systému CodeEx.<sup>1</sup> Přesný formát vstupny a výstupny, povolené jazyky a další technické informace jsou uvedeny v CodeExu přímo u úlohy.

Výpočty byly dokončeny, místnost s generátorem vrctěna do správné fáze a Will už se chystal k tomu, že si po návratem tři přijde dát horkou sprchu. V tom jeho pohled padl na žíněné vrtné a meč, které přivlel a položil s otláčenou pántu do koule. Chvilku přemýšlel, pak to už vzal do náruče a do interkomu oznamil: „Ještě moment, mám nějakou nevyřízenou práci...“

\*\*\*

Než se Gaius stihl vzpamatovat a pořádně nadechnout, zalesklo se podruhé a cizince se vrátil. Teď tam však místo pochopné sídi s pántů v jedné ruce a centurionskou zbrojí ve druhé. Rákl něco dalšího nezrozumitelného a hořil zbrojí i s mečem Gaiovi k nohám. Pak ho rukou pobáhl, aby se do ní naučil.

Gaius dlouze nechtěl a cizince poslechl. Jakmile na sebe zbroj načeští, podíval se na cizince, co řek. Ten se nahnul, hořil něco nadeno do lesa, na prstech odpočítal od tří do jedné a silně strčil Gaiu do zad. Ten ujděhl současně s tím, co se zlevo z lesa začaly ozývat tlivé zrnky...

Přáhej pro vás doupravíte!

Jirka Semčička

vání do šířky ze startu  $S$  a políčka s  $K < D$  považovat na nepřehlední. Pokud bychom během průchodu nenarazili na žádnou nemocnici, cesta přes vrcholy s  $K \geq D$  neexistuje. Můžeme postupně získávat všechna možná  $D$  přes hodnoty  $R + S, R + S - 1, R + S - 2, \dots$  dokud nenarazíme na nemocnici. Ve chvíli, kdy jsme našli nemocnici, máme určit optimální cestu (pokud by existovala lepší, našli bychom ji už v nějakém předchozím průchodu). Protože  $K$  je maximálně  $O(R + S)$ , dostáváme kvadratický algoritmus vůči počtu políček.

Zamysleme-li se nad průchodem algoritmu, zjistíme, že zbytečně prochází opakovaně části mapy. Pak si všimneme, že  $K$  dvon souseďných políček se může lišit maximálně o jedna, tedy políčka, která jsou při nějakém průchodu objevili jako nedostupná, budou hned v příštím průchodu dostupná. Navíc, políčka, která jsou aktuálně prošli, již znovu procházet nemusíme, protože víme, že na zátkem z nich určitě není nemocnic (jinak bychom skončili). Pořítíme si tedy pomocnou frontu a při průchodu do ní budeme vkládat vyprázdněna objevená nedostupná políčka. Ve chvíli, kdy předchozí  $D$  o 1 a zpřístupní tak políčka v pomocné frontě. Prohodíme obě fronty a pokračujeme v průchodu.

Takto postupně procházíme cesty s čím dál tím nižšími  $D$ . První hodnota, kterou vyzkoušíme, je  $K$  startovního políčka (vyšší hodnoty nemá smysl zkoušet).

Každé políčko vložíme maximálně jednou do jedné z front a jednou jej vyjme. Protože každé políčko má maximálně čtyři sousedky, máme algoritmus běžící v čase  $O(RS)$  s pamětovou složitostí  $O(RS)$ , což už jistě zlepšit nepůjde.

Program (C++):

<http://ksp.mff.cuni.cz/viz/28-4-7-bfs.cpp>

Martin „Machůč“ Mareš & Horza Knížek

## 28-4-8 Strojové učení

### Náhodné rozdělení datasetu

Přal jsem se vás, proč je potřeba dataset rozdělovat na trénovací a testovací množiny náhodně. Na našem příkladu to není těžké ukázat: v datasetu  $D$  máme nějakých 100 značek „stop“, pak 100 značek „dej přednost v jízdě“ a nakonec 100 značek „sleďp ulice“.

Kdybychom například prvních 90 % datasetu použili na trénování a posledních 10 % na testování, testovací množina by obsahovala jenom značky „sleďp ulice“ a tudíž by měření výkonu na testovací množině jenom měřilo, jak dobře poznáváme tahle jediný druh značek: místo toho, aby obsahovala rovnoměrný vzorek.

S dostatečně malým štestím se může rozbit ještě jedna věc. Af rozpozítáme 50 druhů značek a od každé máme 100 vzorků. Kdybychom je měli v datasetu postupně za sebou a vybrali bychom prvních 90 % na natrénování, model by uměl rozpoznat prvních 45 druhů značek. Na posledních 5 druhích by ale samozřejmě neměl nic, protože by neměl poznávat žádné jiné jediný druh značek: místo toho, aby obsahovala rovnoměrný vzorek.

### Hlavné učení

Af zkusíme do všech složek vektoru  $\beta$  dosadit všechny hodnoty od  $-100$  do  $100$  s krokem  $0.1$ , kterých je 2001. Vektor  $\beta$  má  $P$  složek, takže budeme testovat 2001 <sup>$P$</sup>  různých modelů. Ohodnocení jednoho modelu trvá čas  $\Theta(|S|)$ . Dohromady by tohle „trváhání učení“ trvalo čas  $\Theta(|S| \cdot 2001^P)$ , neboli, odborně řečeno, dlouho.

## Společná benzinn

Na lineární regresi nic nebylo a všem, kdo se o ni pokusili, se povedla. Stačí naimplementovat algoritmus podle našeho návodu.

Program (Python 3):

<http://ksp.mff.cuni.cz/viz/28-4-8-3.py>

### Kvalita vlna

Opět stačilo následovat návod. Klíčové bylo použít trénovací set jako data pro modely, vybrat model s největším  $R$  podle nejmenší kvadratické chyby a nakonec odhadnout skutečnou accuracy nejlepšího modelu s pomocí testovací množiny.

Na trénovací množině bude nejmenší chyba pro  $K = 1$ , protože pak bude kvalita každého vlna  $X$  v trénovací množině předpovězena podle jednoho nejbližšího souseda v trénovací množině, tedy podle  $X$ . Proto z delšího bude chyba na trénovací množině pro  $K = 1$  rovna nule. Se zvyšujícím se  $K$  se bude chyba zvyšovat.

Na validaci množině je nejmenší chyba pro  $K$  „někde uprostřed“. Pro menší  $K$  se nechá model více ověřovat lokálním šumem a pro větší  $K$  naopak přiměřuje tak moc blízkých vzorků, že si nevíme lokálních vlastností datasetu a čím dál tím víc jenom počítá průměr ze všech vln.

To, které konkrétní  $K$  dá nejmenší chybu na validaci množině, záleží na náhodě ( $\beta$ ) na rozdělení datasetu). Nám například vyšlo  $K = 15$ , které mělo na validaci množině střední kvadratickou chybu 0.6343.

Program (Python 3):

<http://ksp.mff.cuni.cz/viz/28-4-8-4.py>

### Kosatce

Naše autorské řešení funguje tak, že si natrénujeme tři perceptrony, jeden pro každý druh kosatce. Úkolem perceptronů je říct 1 na kosatcích jejich druhu a -1 na všech ostatních. V následním světě bychom doufali, že výstup perceptronů bude  $[1; -1; -1]$ ,  $[-1; 1; -1]$ , nebo  $[-1; -1; 1]$ , a jako výstupní třídu bychom zvolili tu, jejíž perceptron řekl „1“.

To se ale bohně nepovede. Někdy se nám stane, že třeba dostaneme výstup  $[1; 1; -1]$ . Kterou třídu zvolíme potom? V autorském řešení jsme k rozesknutí těchto sporůch případů použili pár pravděpodobnostních tříků. V této úloze nebyly nutné potřebné. Uvádneme je spíše pro zajímavost, protože podobný princip se používá například na bayesovské rozpoznávání spanu, které jste mohli vidět na Janim soustředění na přednášce o strojovém učení.

Nechť nám přijde ke klasifikaci nový kosatec. Jeho skutečnou třídu si označme jako  $C$ . Budeme se na ni dívat jako na náhodnou proměnnou, která má jednu ze tří hodnot:  $s$  jako setosa,  $v$  jako versicolor, nebo  $g$  jako virginea.

Parametry kosatce vložíme do tří natrénovaných perceptronů a jejich výstupy, které jsou rovny 1 nebo -1, si označme jako  $P_s, P_v, P_g$ . Výstupy perceptronů použijeme jako signály, podle kterých spočítáme pravděpodobnosti, že  $C = s, C = v$  a  $C = g$ .

Když na kosatci dostaneme výstupy  $P_s = 1, P_v = -1$  a  $P_g = 1$ , zajímají nás *podmíněné pravděpodobnosti*, že při takovýdho výstupu perceptronů je kosatec skutečně setosa, versicolor, nebo virginea. Podmíněna pravděpodobnost, že za našich podmínek je kosatec setosa, se zapisuje:

$$P[C = s | P_s = 1, P_v = -1, P_g = 1]$$

<sup>1</sup> <http://ksp.mff.cuni.cz/viz/codex>




## 28-4-6 Mediánové třídění

Jak užít mediánový blackbox na třídění, není na první pohled úplně jasné. Proto se musíme tahání krabíčka z klohouku pokusíme nastavit postup, jakým se na řešení dalo vlastně přilít.

Když známe medián  $m$  (fxních)  $K$  čísel, krabíčka nám říká, že  $v$  ni je právě  $\frac{K-1}{2}$  menších čísel než medián. (A stejný počet větších.) Kdybych tedy chtěl zjistit, které číslo v krabici je o jedno větší než medián, stačí do krabíčky rovní vložit nějaké hodné velké číslo, větší než všechna čísla v krabici. Tím z krabíčky vyhodíme ... první prvek, který jsme do ní vložili.

Chceti bytchom vyhodit ten nejmenší. Tak si  $K$  o pár prvků zvětšíme a nejdříve do krabíčky vložíme nějaká hodná malá čísla (menší než všechna v krabici). Tím si zajistíme, že vyhozený prvek bude určité menší než medián.



Rysujte se nám tedy základ algoritmu.

1. Necht  $K = V + N$ .
2. Vlož do krabíčky  $V$  malých čísel
3. Vlož do krabíčky celou vstupní posloupnost ( $N$  čísel).
4. V-krát:
5. Vypiš medián z krabíčky.
6. Vlož do krabíčky velké číslo (tím vypadne jedno malé, které jsme vložili na začátku).
7. Vypiš medián z krabíčky.

Tím jsme právě vypsal seřazenou posloupnost  $V+1$  čísel v okolí mediánu. Můžeme tedy zvolit  $V = N - 1$  a výše uvedený algoritmus nám vydá seřazenou posloupnost  $N$  čísel, což je přesně seřazená vstupní posloupnost.

Například pokud dostaneme k seřazení posloupnost 4, 2, 3, 1, nastavíme  $V = 3$  a  $K = 7$ . Vývoj obsahu krabíčky je popsán v následující tabulce. Medián je tučně zvýrazněn v posledním sloupci,  $-\infty$  a  $\infty$  značí ona hodné malá/velká čísla.

Krok	Obsah krabíčky	Seřazený obsah
7	$-\infty, -\infty, -\infty, 4, 2, 3, 1$	$-\infty, -\infty, -\infty, 1, 2, 3, 4$
8	$-\infty, -\infty, -\infty, 4, 2, 3, 1, \infty$	$-\infty, -\infty, 1, 2, 3, 4, \infty$
9	$-\infty, 4, 2, 3, 1, \infty, \infty$	$-\infty, 1, 2, 3, 4, \infty, \infty$
10	$4, 2, 3, 1, \infty, \infty, \infty$	$1, 2, 3, 4, \infty, \infty, \infty$

Dostaneme postupně mediány 1, 2, 3, 4, tedy přesně seřazenou posloupnost. A máme téměř vyřešeno.

Potřebujeme ještě vymyslet, jak najít dostatečně malá a dostatečně velká čísla na posouvání mediánu v krabici. Jednotě: Najdeme minimum a maximum ze vstupu a to použijeme.

Finální algoritmus tedy vypadá takto:

1. Necht  $K = 2N - 1$ .
2. Projdi celý vstup, spočítej z něj minimum (označme  $m$ ) a maximum (označme  $M$ ) v čase  $O(N)$ .
3. Vlož do krabíčky  $(N - 1)$ -krát  $m$  v celkovém čase  $O(N)$ .
4. Vlož do krabíčky vstupní posloupnost v celkovém čase  $O(N)$ .
5.  $(N - 1)$ -krát:
6. Vypiš medián z krabíčky.
7. Vlož do krabíčky  $M$ .
8. Vypiš medián z krabíčky.

Na závěr bytchom rádi uvedli na pravou míru, proč jsme vlastně takovouto na první pohled podivnou úlohu zadávali. Představte si, že bytchom mediánovou krabíčku nedostali jako konželnou skříňku, ale chtěli si ji poctivě implementovat. To jsme po vás chtěli například v úloze 27-2-1,<sup>6</sup> kde autorské řešení zvládlo jednu operaci (přidání prvku a výpsání mediánu) zpracovat v čase  $O(\log N)$ . Nemohlo by to jít lépe?

Nemohlo. Označme si složitost jedné operace  $T(k)$ . Z řešení naší úlohy víme, že s pomocí takového krabíčky dokážeme seřadit  $N$  čísel v čase  $N \cdot T(N)$ . Z toho tedy plyne, že  $T(N)$  nemůže být lepší než  $\Omega(\log N)$ , protože kdyby byla, uměli bychom třdit rychleji než v čase  $\Omega(N \log N)$ . A je všeobecně známo, že to (za určitých předpokladů) není možné. Předstí si o tom můžete například v naší kuchařce o třídění.<sup>7</sup>

Jan „Moskylor“ Matějka

## 28-4-7 Jízda sanitkou

Pro každé políčko určité budeme potřebovat umět rychle zjistit vzdálenost od nejbližšího místa opravy (označme si toto číslo  $K$ ). Pokud bytchom měli jen jedno místo opravy, stačí z tohoto políčka pusit pohledávání do šířky a u každého políčka si poznamenávat vzdálenost. Pokud máme místo opravy více, všimneme si, že stačí na začátku přidat do fronty všechna místa opravy a použít stejný algoritmus. Postupně faktó navštívíme políčka s  $K = 1, 2, 3, \dots$

Máme mapu, pro každé políčko známe jeho  $K$  a chceme najít takovou cestu ze startovního políčka do libovolné nemocnice, aby nejmenší  $K$  na této cestě bylo co největší. Přímokaré řešení využívá Dijkstraův algoritmus, jen delší cesty budeme počítat jako minimum z aktuální délky cesty a  $K$  nového políčka. Dijkstraův algoritmus postupně hledá cesty s největším ohodnocením (v našem případě je ohodnocení cesty rovno nejmenšímu  $K$  na této cestě) do všech vrcholů. Postupně vybírá vrcholy, do kterých aktuálně známe nejlepší cestu, a aktualizuje sousedy těchto vrcholů tak, že přes každého souseda zkusíme, jestli do něj nevede lepší cesta přes aktuální vrchol. Pro přesný popis algoritmu viz řešení úlohy 28-2-1,<sup>8</sup> kde místo maximalizace minimálního  $K$  minimalizujeme maximum  $K$ . Stačí tedy jen prohodit maximum a minimum. Algoritmus běží v čase  $O(RS \log(RS))$ , kde  $R$  a  $S$  jsou rozměry mapy. Ide to ale rychleji, pojďme se podívat, jak.

Pokud bytchom dopředu znali minimální  $K$  optimální cesty (označme toto optimum  $D$ ), mohli bytchom pusit probléda-

## 28-5-8 Neurotové sítě

### 14 bodů


V minulém dílu seriálu jsme se zabývali modelem biolo-gického neuronu – perceptronem. Ukázali jsme si, jak takový model „naučit“ a použít k jednoduché klasifikaci, tedy rozřídění vstupů do několika skupin. V zadané úloze jste nakonec bojovali s tím, že jeden perceptron dokáže klasifikovat jen do dvou skupin.

Dnes se podíváme na strukturu z umělých neuronů složené, neuronové sítě, jejichž schopnosti jsou mnohem širší. Použijeme se k obecné klasifikaci, rozpoznávání zapamatovaných vzorů, organizaci dat do skupin podle podobnosti nebo třeba k řešení optimalizačních úloh.

### Dopředné vrstevnaté neuronové sítě

Nejoblíbenější způsob, jak zapojit neurony do sítě, je rozdělit je do vrstev 1, 2, ...,  $N$ . Mezi vrstvami napojíme vstup každého neuronu z vrstvy  $k$  na vstup každého neuronu z vrstvy  $k+1$ . Každý z těchto vstupů má svoji váhu a každý z neuronů má svůj práh – stejně jako u jednoduchého perceptronu.

První vrstvě říkáme *vstupní*. Je trochu speciální, protože nepřijímá signály od jiných neuronů, ale přímo vstupní data a ta bez úpravy předává dál. Podobně poslední vrstva se nazývá *výstupní*, protože z ní čteme výstup sítě. Ostatní vrstvy jsou pro okolní svět *skryté*.



Tuto neuronovou síť bytchom teď rádi naučili něco užitečného, tedy našli nastavení vah, které by zajistilo, že pro vstupů z trénovacích dat bude výstup sítě co nejpodobnější požadovanému výstupu. Tuto podobnost měříme pomocí chybové funkce neuronové sítě:

$$E = \frac{1}{2} \sum_i^{\text{data}} \sum_j^{\text{výstup}} (y_{j,i} - d_{j,i})^2$$


Kde  $y_{j,i}$  je výstup  $j$ -tého neuronu při  $i$ -tém vstupu sítě a  $d_{j,i}$  je požadovaný výstup ve stejném případě. Na předpisu této funkce je zajímavé, že chybá (nebo také odchylka) každého neuronu je umocněna na druhou, aby se zdůraznilo velké chyby a zanedbaly malé. Suny pak sečtou chyby ze všech neuronů pro všechna trénovací data. Polovina je v tomto vztlahu jen proto, aby lépe vyšla jeho derivace – to zde ale dělat nebudeme.

Abý učící algoritmus mohl postupně snižovat chybu úpravou vahy neuronů, hodilo by se nám, aby aktivizační funkce neuronu postupně a spojitě rostla s rostoucím potenciálem neuronu. Miso skobové funkce sigmoidu z minulého dílu tedy v našem seriálu použijeme sigmoidu:

$$f(x) = \frac{1}{1 + e^{-x}}$$

$\lambda$  je v této funkci konstanta, jejíž nastavením můžeme měnit strmost funkce. K jejím vlivu na učení se ještě dostaneme. Písmenkem  $\xi$  (*kš*) značíme potenciál,  $e$  možná už znáte jako Eulerovo číslo.

Níže můžete vidět průběh sigmoidu pro  $\lambda = 4$ :



### Výpočet výstupu sítě

Algoritmus pro výpočet výstupu sítě vychází přímo ze vzta-hů platících pro perceptron. Postupně počítá výstupy jednotlivých vrstev počínaje první skrytou (která vstupní vsta-va data nijak neupravováá). K výpočtu potenciálu  $\xi_j$  pod-le výstupu předchozí  $j$ -té vrstvy používá vzta-h z minulého dílu:  $\xi_j = \sum_i w_{ij} u_i$ . Potenciál se pak dosadí do aktivizační funkce, v našem případě sigmoidu.

Nikoho, kdo čelí předchozí dílu, by teď nemělo překvapit, že zvlášť nepočítáme s prahem (anglicky *bias*). Ten je totiž schovaný v přídaném neuronu s konstantní hodnotou  $-1$ , ze kterého vede vstupní hrana s vahou odpovídající velikosti prahu.

Pro implementaci se může hodit si všimnout, že výpočet potenciálu je skalární součin dvou vektorů. Pokud vás programovací jazyk tedy vektory (v matematickém smyslu) a operace s nimi podporuje, můžete si jejich použitím občasně ušetřit trochu práce. Kromě toho můžete zjednodušit kód ušetřit práci i členů, což je v programování často ještě důležitější princip.

**Úkol 1 [2b]:** Vymyslete mit dva vstupy a jeden výstup funkci XOR. Síť bude mít dva vstupy a jeden výstup. Počet vrstev a skrytých neuronů je na vás, ale snažte se o minimum. Pošlete nám kresbu sítě včetně vah a vysvětlení, proč je vaše síť nejmenší možná.

### Zpětné propágece

K učení, tedy minimalizaci chybové funkce  $E$ , se používá mnoho různých algoritmů. My se podíváme na nejzákladnější z nich, *zpětnou propágeci*. Nejdříve si popíšeme její myšlenku.

Na počátku náhodně nastavíme všechny váhy. Účím pak problá tak, že náhodně vybíráme z trénovacích dat, pro každý vstup nechalme síť vypočítat výstup a porovnáme ho s požadovaným výstupem z trénovacích dat. Na základě tohoto porovnání upravíme váhy sítě tak, aby se snížila chyba sítě – výstup se přiblížil k požadovanému.

Postupně procházíme vrstvami od výstupní k vstupní a upravujeme váhy každé vrstvy tak, abytdom snížili chybu té následující směrem k vstupu.

Prevést tuto myšlenku do řeči matematicky vyžaduje trochu matematické analýzy, takže na to pro účely seriálu půjdeme trochu od lesa. Nejdříve vám ukážeme vzorec, které zpětná propágece na úpravu vah používá, a poté trochu objasníme její částí.

Chceme určit novou váhu  $w_{ij}(t+1)$  spoje z neuronu  $i$  do neuronu  $j$  v kroku  $t+1$ . Změna této váhy bude záviset na chybě neuronu  $j$  a výstupu neuronu  $i$ :

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_j y_i$$


kde  $\delta_j$  je chyba neuronu  $j$ . Ta se dá přímo spočítat pro výstupní vrstvy:

$$\delta_j = (d_j - y_j)\lambda y_j(1 - y_j)$$

Pro skryté vrstvy je ale třeba ji odvodit na základě chyby, kterou už máme spočítanou pro sousední vrstvy směřem k výstupi:

$$\delta_j = \left( \sum_k \delta_k w_{jk} \right) \lambda y_j(1 - y_j)$$

Kdy učení skončit a prohlásit síť za naučenou nebo naopak nepoučitelnou? Jedna z možností je sledovat chybu sítě. Pokud se průměrná chyba testovacích výstupů dlouho nesnižuje, lepší už to asi nebude.



Lepší možností je vyzkoušet síť na vstupy, které v trénovacích datech nejsou. Takovým vstupům se říká testovací data, protože na nich testujeme naučenou síť. Proč je lepší oddělit testovací a trénovací data? Představte si, že chcete neuronovou síť naučit třeba rozpoznat sunda od lichéty čísel.

I pokud síť rozpozná naše trénovací čísla bez chyby, je možné, že se naučila jen seznam všech směrůch nebo lichých čísel a jiná čísla může dál rozpoznávat špatně. Takovému stavu, kdy se síť příliš zaměřila na trénovací data, se říká *přeučení*. Naopak schopnosti sítě zobecnit řešení říkáme *generalizace*. Dlouze testovacími daty umíme tyto dva jevy rozlišit.

Pokud nám neuronová síť dává dobře výsledky na trénovacích i testovacích datech, znamená to že bude mít takto malou chybu i na dalších vstupech? Ani to ne! Učení totiž nastavujeme právě tehdy, když budou tyto chyby malé. Pokud chceme odhadnout chybu, se kterou bude síť pracovat pro další data, je dobré ji znovu znehtit pro oddělenou sadu dat, *validační data*.

Uff, dat už potřebujeme pětkrát víc než ty, které je ale vzít? To je společně s výpočtemi náročnosti jednou z největších výzev strojového učení. Stroje svoji neobratnost v učení kompenzují velkým množstvím trénovacích dat. Zatímco dítěti stačí vidět pár čísel, aby se naučil rozlišovat sunda a liché, stroje jich potřebují řádově víc.

Mnoho současných technologických společností je schopno vytvářet „inteligentní“ řešení právě díky tomu, že mají od uživateli svých služeb sesbírané obrovské množství dat. Nám budou muset stačit veřejně *datazeby* dostupné na internetu. Jak je rozdělit na trénovací, testovací a validační části? Náhodně, přičemž většína se obvykle používá na trénování.

### Předpracování dat

Narozdí od perceptronu, neuronové sítě obvykle pracují s čísly v rozsahu  $[0; 1]$ , a i naše aktivční funkce má obor hodnot v tomto rozsahu. To pro nás znamená, že bychom si data pro neuronovou síť měli předpracovat, aby byly v tomto rozsahu. Tímto technikám předpracování se říká

*normalizace* a my ji budeme provádět stejně jako v minulém díle seriálu.

Pokud například chceme, aby neuronová síť pracovala s výškami dospělých člověka, které se v našich datech pohybují od 140 po 200 cm, přepočítáme tyto výšky tak, aby 140 odpovídalo nule, 200 odpovídalo jedné a vzájemné poměry výšek zůstaly stejné.


Pokud síť používáme ke klasifikaci do  $k$  skupin, často můžeme dosáhnout lepšího výsledku, když místo jednoho výstupu sítě, který by udával číslo skupiny  $1, \dots, k$ , použijeme  $k$  výstupních neuronů.  $i$ -tá skupina se pak reprezentuje tak, že  $i$ -tý neuron má hodnotu 1 a ostatní 0 (nebo v blízkosti těchto hodnot).

### Počáteční parametry

Chování zpětné propagace ovlivňuje několik parametrů a způsob generování počátečních vah. Parametry mají vliv hlavně na rychlost učení. Pokud učení nastavíte příliš rychle, může algoritmus úplně ztratit schopnost chybné sítě zlepšovat a učení nebude fungovat. Konkrétní volba parametrů závisí na řešením problému a často se s ní experimentuje.

Parametr  $\lambda$  nastavuje strmost aktivční funkce, v našem případě  $f(x) = \frac{1}{1+e^{-\lambda x}}$ . Jak si můžete sami vyzkoušet dosazováním, větší  $\lambda$  znamená strmější funkci. Strná funkce pak zrychluje učení, protože menší potenciál (a tedy menší rozdíl vah) stačí k tomu, aby neuron vydal výstup blízko 1. Učení tedy pro velkou  $\lambda$  nemusi vahy měnit o tolik, což jej zrychluje.

Parametr  $\alpha$  nastavuje rychlost změny vah v každém kroku učení. Jak je vidět ve vztahu pro aktualizaci vah:  $w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_j y_j$ , větší  $\alpha$  způsobí větší změny vah. Obvykle používáme  $\lambda \in [0.5; 4]$  a  $\alpha \in [0.2; 1]$ .




Zbývá vyřešit volbu počátečních vah. Ty bychom chtěli nastavit tak, aby průměrný neuron reagoval na vstupy v rozsahu  $[0; 1]$  opět potenciálem v rozsahu  $[0; 1]$ .

Nechceme tedy například, aby neuron s většími počty vstupů generovaly potenciály (v absolutní hodnotě) mimo zmiňovaný rozsah. Proto by takové neurony měly mít menší vahy svých vstupů. Doporučujeme volit počáteční vahy v rozsahu  $\pm \frac{1}{\sqrt{N}}$ , kde  $N$  je počet vstupů neuronu. K přesnému odvození tohoto vztahu je potřeba smíchat trochu matematické statistiky a integrálního počtu, takže jej zde zatajíme.

## 28-4-5 Hra kriket

Zase po nějaké době musíme zavít autorové řešení omhrou: až nad šesti příjatyými pracemi nám došlo, že jsme pořádně nespochfbovali zadání. O co konkrétně šlo?

Chceti jsme na co nejmenší vzdálenosti projet všechny branky v předepsaném směru. Sportovní bodem ale byla definice toho, co přesně znamená *projekt branky*. Stačí do ní tlačit míčkem z jedné strany a ihned se vrátit, nebo se musíme dostat i na druhou stranu? Následující rása míčku by v prvním případě byla korektní, v tom druhém ne:




Pro itčely našeho řešení uvažme, že úsečka tvořící branku (respektive přímlka, na které leží) dělí celé hřiště na dvě poloviny. Projekt branky pak znamená, že míček se nejprve nachází v první a pak, skrz úsečku, přejde do druhé poloviny. V obou stavech se míček alespoň na chvíli musí nacházet ostře, tedy ne na přímlce, která rovny dělí.


Jak v takovém případě vyřešit situaci z obrázku? Značeny tah naše podmininy nespínuje. Někteří řešitelé si snažili pomoci tím, že při přímlku s brankou popojeli nahoru a dolů o nejmíši možnou vzdálenost – tím ji skutečně prošli v obou směrech. Klasická eukleidovská rovina, v níž hrn hraje, ale takový posun nemožnost. Stačí uvážít, že pokud uděláte jakkoliv malý krok, můžete jej zkrátit tím, že jeho délku vydehíte dvěma. K jakékoliv trase míčku pak dokážete najít kraši řešení: minimum tedy neexistuje a tiolha řešení nemá. Podobným argumentem můžete ukázat nespávnytní i postup, kdy míčkem „objíždíme“ koncovou tyčku – ani zde nexistuje minimální délka.

A teď už k popisu našeho algoritmu. Nejprve jedno pozorování: při naší definici nejkratší cesta skrz branky vytvoří postloupnost rovnyých čar, lánající se jen v tyčkách (krajních bodech) branky. Exaktní důkaz by byl trochu složitéjší. Zkusme si alespoň představit, že ke startu přivázete provázek a ten pak vedete všemi brankami podle pořadí až do cíle, a následně ho napnete. Kde se bude olýbat?

Považujme teď startovní a cílový bod za branky mlouvé dělky. Algoritmus projde všechny tyčky branky a pro každou z nich zjistí, odkud k ní může přímým vřhem (tedy bez olýbání) přiletět míček. Mějme tyčku  $T$ , která leží n  $K$ -té branky. Vezměme obě tyčky u branky  $K - 1$  a vedme jím z  $T$  polopřímky. Výšce mezi nimi odpovídá prostoru, ve kterém můžeme do  $T$  odpálit míček letící skrz branku  $K - 1$ :



Pokračujme u branky  $K - 2$  a dalších. Vždy určíme polopřímky vedoucí z  $T$  do tyček, čímž vznikne další výšec. Uděláme prmlk s prostorem, který jsme dostali v předěšlém kroku. Ve výsledné výšeci se můžeme dostat do  $T$  přes mezilehlé branky:



Pokračujeme tak dlouho, dokud nedojdeme do startu, nebo nedostaneme přízdnou výšec. Navíc musíme kontrolovat povolený směr příchodu brankou: Jíz na začátku se podle něj omezuje na jednu z polovin určitých brankou n  $T$ . Pro branku  $K - 1$  a další ovříme, že skrze správný směr by míček směřoval do části výšeci, kde se nachází  $T$ . Jinak přichod ukončíme.

Čeho jsme tím dosáhli? Dokážeme pro dvě libovolné tyčky (vedne startu a cíle) určit, zda mezi nimi může přímo prolelet míček. Proto si založíme graf, jehož vrcholy odpovídají tyčkám, a hrana mezi nimi povede, pokud se z jedné tyčky do druhé můžeme dostat „na jedno tlaknutí“. Hrany budou obdohocené vzdáleností tyček. Pak už jen stačí zaméstnat Dijkstraův algoritmus a najít nejkratší cestu ze startovní do cílové tyčky. (Rozmyslete si, že v případě odporádajícím prvním obrázku se žadáá cesta nenaalje.)

Při  $N$  brankách tedy máme  $2N + 2 = O(N)$  tyček, prohledání n každé z nich zabere  $O(N)$ , takže dohranady  $O(N^2)$ . Složitost Dijkstra je stejná (máme nevyšce  $O(N^2)$  hran). Celková časová složitost algoritmu je tedy  $O(N^3)$ , stejně tak paměťová složitost (tu navysítuje graf).

Pár poznámek k implementaci: výšeci je možné v programu reprezentovat prostě vrchodem a dvojicí tlh. Vzhledem k tomu, že nás nezajímá, jak přesně jsou tyto tlhy velké, ale stačí nám je jen umět porovnávat, můžeme místo tlhů pracovat se *směrnice*.<sup>4</sup> Tím si usetříme počítání s goniometrickými funkcemi. Pro určení toho, ve které polovině od dané branky leží nějaký bod, můžeme použít techniky popsané v naší geometrické knačarce.<sup>5</sup> Podrobněji ve vzorovém programu.


Program (Python 3):  
<http://ksp.mff.cuni.cz/viz/28-4-5.py>

A na závěr doplnit k naší omůvce. Pokud by u jakékoliv tlhy vypadal, že vás nutíme používat podobné chlhpate postupy, jako nekonečné malé koučky, raději se zeptejte na fóru. Ogrové síce často jsou docela osobiti tlké, ale takové slámosti schválně nezadávaří (případně si je nechávaří v záloze na soustředění).


Krda Maroušek

<sup>4</sup> <https://en.wikipedia.org/wiki/Slope>  
<sup>5</sup> <http://ksp.mff.cuni.cz/viz/krucharky/geomtrie>

To ořezání nemusí platit pro počáteční vrchol tahu (který je zároveň koncovým). Pokud má tah lichou délku (v grafu je lichý počet hran), vrátíme se do počátečního vrcholu hranou stejné barvy, jako jsme z něj vyšli. V případě, že do tohoto vrcholu nevedou žádné jiné hrany (má stupeň 2), výsledné obarvení není správné:



Ovšem pokud má větší stupeň, navštívit jej tah nejen na začátku a konci, ale alespoň jednou jej projde „skrz“ a v tu chvíli korektně vystřídá barvy. Pokud tedy graf obsahuje vrchol stupně většího než 2, stačí začít obarvovat z tohoto vrcholu a najdeme správné obarvení:



Pokud takový vrchol v grafu není (všechny stupně jsou 2), graf musí být kružnice. Má-li sudou délku, obarvíme ji střídavě a máme vyhráno. Má-li lichou délku, snadno si rozmyslíte, že správné obarvení neexistuje.

### Liché stupně

Nyní se vrátíme na těžší variantu. Nejprve jednoduché pozorování: listy (vrcholy stupně 1) nikdy nemohou být dobré, graf který obsahuje list, tedy nejde obarvit. Dále budeme uvažovat jen grafy bez listů.

Když graf obsahuje vrcholy lichého stupně, eulerovský tah neexistuje. Asi by se hodilo nějak graf upravit, aby měl opět všechny stupně sudé.

Lidi v takovém situacii často napadá zkonštruovat vrcholy lichého stupně uzavřít, obarvit zbytek a pak je tam nějakým způsobem vracet. Ale to je slepá ulička. Například proto, že graf může mít kličné *všechny* stupně liché...

My si poradíme jinak. Do grafu přidáme nový vrchol  $\omega$  a spojíme s ním všechny vrcholy, které měly pňvodně lichý stupeň. Tím se jejích stupňů změní na sudý. Ale nemůže se stát, že by nový vrchol  $\omega$  měl lichý stupeň?

Nikoliv, neboť v každém grafu platí, že součet stupňů všech vrcholů je sudý. Pokud bychom každou hranu pomyšlně rozdělili uprostřed na dvě poloviny, snadno nahlédnete, že součet stupňů je rovný počtu pňhran. A ten je určitě sudý. Proto *žádný* graf nemůže mít právě jeden vrchol lichého stupně.

Upravíme graf má tedy všechny stupně sudé a můžeme v něm najít eulerovský tah. Opět budeme barvit podél tahu střídavě, ale tentokrát začneme z vrcholu  $\omega$ . Tím se zbavíme speciálního ošetřování počátečního vrcholu, protože  $\omega$  nemusi splňovat podmínky na obarvení. Zbývá si rozmyslet, že takto získáme správné obarvení.


Nejprve však trochu názvosloví: nové přidáním vrcholům a hranám budeme říkat *virtuální*, pňvodním *skutečné*. *Skutečný stupeň* vrcholu  $v$  je stupeň, který měl  $v$  ve vstupním grafu. Vrchol je dobrý, když se dočtyřka *skutečných* hran obou barv.

Vrcholy se sudým skutečným stupněm jsou určité dobré, protože jsme do nich museli přijít i opustit je po skutečné hraně (žádné virtuální hrany nemají). A tyto hrany mají opačnou barvu.


U vrcholů s lichým skutečným stupněm je to složitější, protože do nich můžeme přijít či z nich odejít po virtuální hraně. Ale protože původní graf neobsahoval listy, všechny mají skutečný stupeň alespoň 3, tedy v upraveném grafu stupeň alespoň 4. Každým takovým vrcholem musí tah projít alespoň dvakrát.

A pouze jednoho z těchto přiběhů se může účastnit virtuální hrana (každý vrchol má nejvýše jednu virtuální hranu). Při tom druhém tedy přijdeme i odejdeme po skutečné hraně, a tyto hrany mají opačnou barvu. Tedy i všechny vrcholy s lichým skutečným stupněm jsou dobře a naše obarvení je korektní.

Například následující graf:



obarvíme takto:




Na závěr shrňme celý algoritmus:

1. Najdeme komponenty souvislosti  $G$ .
2. Pro každou komponentu  $C$ :
3. Pokud  $C$  je lichá kružnice nebo obsahuje listy, vypíšeme „řešení neexistuje“ a skončíme.
4. Pokud  $C$  obsahuje vrcholy lichého stupně, všechny je spojíme s nově vytvořeným vrcholem  $\omega$ .
5. Určíme výchozí vrchol  $z$  jako:
  6.  $\omega$ , pokud jsme tento vrchol přidávali;
  7. jinak libovolný vrchol stupně alespoň čtyři, pokud takový existuje;
8. jinak zcela libovolný vrchol ( $C$  je kružnice).
9. Najdeme uzavřený eulerovský tah  $t$  ze  $z$  do  $z$ .
10. Projdeme hrany v pořadí určeném  $t$  a barvíme je střídavě.

Program (C):

<http://ksp.mff.cuni.cz/viz/28-4-4.c>


*Přip Štědronský*



**Úkol 2** [8b]: Podíváme se znovu na dataset o kosatečích ze stránky seriálu. Zkusíme klasifikovat kosatec pomocí neuronové sítě a porovnat přesnost s řešením pomocí perceptronu. Nezapomínejte na předzpracování dat. Pňvodní autorské řešení, které mělo z 60 trénovacích vzorů na zbytek datasetu 93.42% přesnost, byste měli bez problémů překonat. Zkusíte si pohrát s architekturoou sítě (počtem neuronů a vrstev) a parametry a do řešení přijítte, na co jste pňšli. V odevzdaném řešení rozdělte dataset v poměru 50:25:25% pro trénovací, testovací a validační část.

Pokud jste úlohu z minulé série řešili, stáhněte si prosím dataset znovu, opravili jsme v něm dvě drobné chyby. Odminula také připomínáme, že každý řádek datasetu reprezentuje vlastnosti jednoho kosatece.

První řádek popisuje význam sloupečků: první dva jsou délky a šířky kalíšních listků, další dva jsou délky a šířky okvětních listků. Máme za úkol předpovědět poslední sloupec – konkrétní druh kosatece: *setosa*, *versicolor*, nebo *virginica*.



**Úkol 3** [4b]: Nakonec se podíváme na úlohu, která je pro nás „mimální mozek“: těžká: rozpoznání srdce. Mějme neuronovou síť se dvěma vstupny, jednou skrytou vrstvou s  $N$  neurony a jedním výstupem.

Síť bude na vstupu přijímat souřadnice  $x$  a  $y$  bodu v rovině a její výstup se bude blížít 1, pokud bod leží uvnitř srdce, a 0 v opačném případě. Srdce budeme pro naše účely znázorňovat známým piktoogramem tvořeným čtvercem a dvěma pňlkružnicemi umístěnými nad jeho dvěma sousedními stranami.

Zvolte si počet skrytých neuronů  $N$  (alespoň 6) a najděte nastavení vah této sítě. Rozměry a souřadnice srdce si zvolte libovolně. Úlohu můžete vyřešit jak pomocí zpětné propagace, tak pomocí tužky a papíru.

*Jan Škoda*

## Recepty z programátorské kuchyně: Rekursivní funkce a dynamické programování

Rekursivní funkce je taková funkce, která při svém běhu volá sama sebe, často i více než jednou. To typicky vede na exponenciální časovou složitost algoritmu.

Dynamické programování je technika, kterou lze z pomalého rekursivního algoritmu vytvořit pákry polynomiální, tedy až na výjiměné případy. Ale nepřehledněme, nejdříve se podíváme na jednoduchý příklad rekurze.

### Fibonacciho čísla


Budeme počítat  $n$ -té číslo Fibonacciho posloupnosti. To je posloupnost, jejímiž prvými dvěma členy jsou jednotky ( $F_1 = 1, F_2 = 1$ ) a každý další člen je součtem dvou předchozích ( $F_n = F_{n-1} + F_{n-2}$  pro  $n > 2$ ). Začíná takto:

1 1 2 3 5 8 13 21 34 55 89 ...

Pro nalezení  $n$ -tého členu (ten budeme značit  $F_n$ ) si napíšeme rekursivní funkci `Fibonacci(n)`, která bude postupovat přesně podle definice – zeptá se sama sebe rekursivně, jaká jsou dvě předchozí čísla, a pak je sečte. Možná více řečne program:

```
def fibonacci(n):
    if n <= 2:
        return 1
    else:
        return fibonacci(n-1) + fibonacci(n-2)
```

To, jak funkce volá sama sebe, si můžeme snadno nakreslit třeba pro výpočet čísla  $F_5$ :



Vidíme, že se program rozvětřuje, což tvoří strom volání. V každém vrcholu tohoto stromu trávíme konstantní čas, takže časová složitost celého algoritmu je až na konstantu rovna počtu vrcholů tohoto stromu. Kořik to je, spočítáme jednoduchou úvahu.

Každý vrchol stromu vračí hodnotu, která je součtem hodnot v jeho smech. Proto je hodnota v kořeni rovna součtu hodnot v listech. V listech jsou ovšem jednotky ( $F_1$  a  $F_2$ ), takže listů musí být právě  $F_n$  a všech vrcholů dohromady aspoň  $F_n$ .

Proto na spočítání  $n$ -tého Fibonacciho čísla spotřebujeme čas alespoň takový, kolik je ono číslo samo. Ale jak velké takové  $F_n$  vlastně je? Můžeme třeba využít toho, že

$$F_n = F_{n-1} + F_{n-2} \geq 2 \cdot F_{n-2}$$

z čehož indukci dokážeme

$$F_n \geq 2^{n/2} \quad \text{pro } n \geq 6.$$

Funkce `Fibonacci` má tedy alespoň exponenciální časovou složitost což není nic vítaného.

Jak najít efektivnější algoritmus? Všimneme si, že některé podstrony jsou sbloudě. Zřejmě to budou ty části, které reprezentují výpočet stejného Fibonacciho čísla – v našem

příkladě třeba třetího. Tyto výpočty opakujeme stále dokola.

Nemáží se proto nic snažit, než si jejich výsledky uložít a pak je kdykoliv vyváhnout jako pověstného králíka z klobouku s minimem námahy.

*První zále je změna o králíček přibodná.*

*Legendu o Fibonacciho číslích upřesní, že k jejich objevu došlo při výzkumu rozmnožování králíků.*


*Leonardo Pisánský (zvaný též jako Fibonacci)*

*tolik pěstoval králíky. První dva měsíce měl 1 pář, další měsíc měl 2 páry, pak 3, pak 5, ...*

Bude nám k tomu stačit jednoduché pole  $P$  o  $n$  prvcích, na počátku inicializované nulami. Kdykoliv budeme chtít spočítat některý člen, nejdříve se podíváme do pole, zda jsme ho již jednou nespočetli. A naopak jakmile hodnotu spočítáme, hned si ji do pole poznamenanáme:

```
P = [0] * (n+1)
def fibonacci(n):
    if P[n] == 0:
        if n <= 2:
            P[n] = 1
        else:
            P[n] = fibonacci(n-1) + fibonacci(n-2)
    return P[n]
```

Podíváme se, jak vypadá strom volání nyní:



Na každý člen posloupnosti se tentokrát přáme maximálně dvakrát – k výpočtu ho potřebují dva následující členy. To ale znamená, že funkci `Fibonacci` zavolaíme maximálně  $2n$ -krát, čímž jsme touto jednoduchou úpravou zlepšili exponenciální složitost na lineární.

Zdálo by se, že abychom získali čas, museli jsme obětovat paměť, ale to není tak úplně pravda. V první příkladu jsme nepoužívalme žádné pole, ale při volání funkce si musíme zapamatovat některé údaje, jako je třeba návratová adresa, parametry funkce a její lokální proměnné, a na to samozřejmě potřebujeme určitě paměť lineární s hloubkou vnoření, v našem případě tedy lineární s  $n$ .

Učtíte vás už také napadlo, že  $n$ -té Fibonacciho číslo se dá snadno spočítat i bez rekurze. Stačí prvky našeho pole  $P$  plnit od začátku – kdykoli známe  $P[1..k]$  ( $k = F_{1..k}$  všech) my prvky pole na pozicích od 1 do  $k$ , dokážeme snadno spočítat  $P[k+1] = F_{k+1}$ :

```
P = [0] * (n+1)
def fibonacci(n):
    P[1] = 1
    P[2] = 1
    for i in range(3, n):
        P[i] = P[i-1] + P[i-2]
    return P[n]
```

vycházet z předchozích výsledků, stačí od času posledního podpisu pod druhou sadou odečíst dobu, kterou tento první člen strávil podepisováním.

To ale nemusí být jediná změna. Do skupiny lidí podepisujících druhou sadu může několik lidí přitřít. To se může stát tím, že druhá sada se nyní k posledněmu člověku dostane dřív a tedy se může stihnout předat ještě následujícím lidem v křtu. Zkusíme tedy postupně takové lidi přesouvat do naší skupiny a přibližně upravovat čas.

Kdy se zastaví? Všimneme si, že tímto přesouváním se čas podepisování druhé sady zvyšuje, zatímco v první sadě se snižuje. Rozdíl těchto časů se tedy bude postupně snižovat dokud čas podepisování druhé sady nebudle větší než čas podepisování první sady, poté se bude tento rozdíl jen zvyšovat. Stačí se tedy zastavit v okamžiku, kdy doba podepisování druhé sady překročí dobu podepisování první sady.

Rozmyslete si, že jedno ze dvou posledních řešení (1) to první kdy doba podepisování druhé sady je větší než doba podepisování první sady, nebo to poslední, kdy tomu tak ještě není) je nejpřesnější řešení, a popisuje tedy i skutečnou dobu, kterou by dokumenty kolovaly, pokud bychom je rozdělili zvolené startovní dvojici.

Takto budeme postupně zkoušet všechny startovní dvojice. Stačí z nich pak vybrat to celkové nejrychlejší a to nám říká, které dvojici máme dokumenty dát.

V celém řešení vlastně postupně posouváme místo, kde dokumenty rozdáváme a místo kde se sady dokumentů opět střechou. Všimněte si, že místo střetnutí nikdy nepřekročí místo rozdělení dokumentů. A jelikož zkoušíme každé výchozí místo jen jednou, tak místo střetnutí udělá nanejvýš jeden okruh. Čas trávíme pouze při posouvání některých z těchto míst (a hledání pro první dvojici, které zvládneme lineárně) a těchto posunů je lineárně, celková časová složitost tedy bude  $O(N)$ .

Program (Python 3):  
<http://ksp.mf.cuni.cz/viz/28-4-2.py>

*Janka Bálárová & Dominik Smrč*

### 28-4-3 Řazení životních hodnot

Úkolem v této úloze bylo seřadit životní hodnoty rezentované čísky tak, aby zapadly do zadáních relací „menší než“ a „větší než“. Díky tomu, že číselné hodnoty byly různé, nebyla úloha příliš složité na vyřešení a mnoho z vás se s ní úspěšně popralo.

Pokud je mezi třemi pozicemi relace  $a > b < c$ , víme, že na pozici  $b$  nemůžeme umístit největší číslo ze vstupů, protože potřebujeme alespoň dvě větší čísla pro umístění na pozice  $a$  a  $c$ . Naopak pro pozice  $a$  a  $c$  žádné takové omezení nemá, a je nám dokonce jedno, v jakém vzáihu budou čísla na těchto dvou místech – stačí, že obě budou větší, než číslo na  $b$ .


Po zvolení čísla na pozici  $b$  se nám dokonce na tomto místě rozpádnou zbylé nerovnosti na levou a pravou část, které můžeme řešit samostatně – nevádi nám, pokud budou všechna čísla v levé polovině menší, než v pravé (nebo naopak větší, či nějak promícháná). Zkusme z toho vymyslet algoritmus.

Mohli bychom vždy nalézt nějakou pozici, která není ničím zdoila omezená, na tuto pozici umístít nejmenší zatím nepoužité číslo ze vstupů a tento postup opakovat pro zbylé

levou a pravou část. Tím dostaneme rozmištění čísel, které respektuje všechny nerovnosti.

Abychom nemuseli pokazdité hledat, která pozice je zrovna zdoila neomezená, můžeme si pozice zkusit očíslovat v pořadí, v jakém budou přidržovat za sebou. Největší pozici přidáme číslo 0 a každé další pak číslo o jedna větší (pokud zde byla relace  $<$ ), nebo o jedna menší (pokud zde byla relace  $>$ ), než měla pozice předchozí. Například pokud na vstupní dostaneme relace  $< > > >$ , očíslování bude: 0, 1, 0, -1, 0, -1.

Toto očíslování má jednu důležitou vlastnost: kdykoli nějaká relace předepisuje, že číslo na  $i$ -té pozici má být větší než na  $j$ -té, bude očíslování  $i$  větší než očíslování  $j$ . To přímo plyne z toho, jak očíslování vytváříme, ale možná lépe je to vidět na následujícím obrázku:



Všechny relace jsou orientované „větším koncem nahoru“. Kdykoli nějaká relace předepisuje nerovnost dvou pozic, ta větší bude v obrázku výš, neboli bude mít větší očíslování. Když si pak pozice seřadíme podle tohoto očíslování od nejmenšího, tak víme, že každé pozici, která přijde na řadu, můžeme dát nejmenší zatím nepoužitý číslo ze vstupů. Všechny prvky, které měly vymcené menší číslo než ona, už své číslo dostaly, a zbylé pozice mají vymcené číslo větší, nebo s ní ve vztahu vůbec nejsou.

Celý algoritmus tedy spočítá v tom si očíslovat pozice podle relací, seřadit pozice podle tohoto očíslování, seřadit vstupní čísla od nejmenšího a pak je postupně přiřazovat.

Na celém řešení je nejpomalejší třídění, které zabere čas  $O(N \log N)$ , paměti spotřebujeme  $O(N)$ . Na zorození implementaci z Codefame, že na úlohu se lze dívat i grafově.

Pro každou pozici si vytvoříme jeden vrchol a mezi sousedními vrcholy porvede hrana orientovaná „od menšího konce relace k většímu“. Vyše popsané očíslování pak není nic jiného než topologické uspořádání na tomto grafu.

Program (C):  
<http://ksp.mf.cuni.cz/viz/28-4-3.c>

*Jirka Smetka*

### 28-4-4 Podivuhodný obraz

Jako první si všimneme, že obarvení v jednohlých konponentách souvislosti můžeme volit nezávisle: pokud najdeme správné obarvení pro každou komponentu zvlášť a dáme je dohromady, získáme korektní obarvení celého grafu. Ve zbytku řešení se budeme zabývat tím, jak obarvit jednu komponentu, můžeme tedy předpokládat, že barvení graf je souvislý.

Nejprve vytvoříme jednodušší variantu. Označme úlohy jako kuchařkové nabádá k tomu najít eulerovský tah – což v souvislém grafu se sudými stupni můžeme udelat. Nyní stačí projít hrany v pořadí určeném eulerovským tahem a obarvovat je střídavě (červená, černá, červená, ...). Jako doba budeme označovat vrcholy dočyřující se hranu obou barev. Lihovuhý vrchol uvnitř tahu bude dobrý, protože jsme z něj odjdelme po hraně opakně barvy, než jsme do něj přišli.



### 28-4-1 Sledování telefonů

*Pokrytí honory* budeme říkat libovolnému seznamu honorů, který při posílání přes spoje odpovídá vstupním datům. *Minimální pokrytí* pak bude takové, které mezi všemi pokrytími má minimální počet honorů. Uloha po nás dce najít libovolné minimální pokrytí. Pro zjednodušení uzavříme, že před prvním a za posledním domnem je imaginární spoj, přes který neproběhl žádný hovor.

Podíváme se teď na libovolné pokrytí, a vezmeme nějaký dům.  $N$  něj vede dolava  $l$  a doprava  $p$  honorů. Pokud  $l = p$ , tímto domem můžou všechny honory jenom procházet. Pokud ale  $l < p$ , pak doprava vede více honorů, tedy zde alespoň  $p - l$  musí začít (vešit od tohoto domu nějakou dopravu). Naopak, pokud  $l > p$ , pak zde alespoň  $l - p$  honorů musí končit.

Na chvíli si představme, že počty honorů přes spoje jsou nadmořské výšky. Pokud zakrneme vlevo v mlu, přijdeme stejně metrů do kopce jako z kopce, protože na konci zase skloníme v mlu. Z toho vidíme, že začítka je stejně jako konci. Navíc, budeme-li zleva dopravu průběžně počítat počet začítka a konci, počet začítka bude v každou chvíli alespoň tak velký jako počet konci.

V libovolném pokrytí musí každý hovor někde začítat. Posčítáme-li tedy nutné začátky, dostaneme odhad na minimální počet honorů  $H$ . Pokud by se nám podařilo sestrojiti pokrytí, které je složené z  $H$  honorů, víme, že je minimální.

Nyní si ukážeme algoritmus, který právě takové pokrytí sestrojí. Půjdeme přes domy zleva doprava, a každý začátek si poznamenejme jako nevyřešený. Jakmile narazíme na nějaký konec, přidáme ho libovolným z nevyřešených začátků.

Pokud za „libovolný“ prohlásíme ten první, můžeme nevyřešené začátky udržovat ve frontě, ale stejně dobře bude fungovat třeba zásobník. Jak už jsme si všimli, nevyřešených začátků bude vždy dostatek a na konci vyřešíme všechny. Tím jsme sestrojili pokrytí právě  $H$  honorů, tedy to musí být minimální pokrytí.

Řešení projde přes  $N$  domů, a k tomu  $H$ -krát vloží číslo na zásobník. Časová složitost tedy bude  $\mathcal{O}(N + H)$ , stejně tak paměťová.

Některý z vás si v tuto chvíli řekne, že to je nejlepší možné, protože  $\mathcal{O}(N)$  nám sebere čtení vstupu, a  $\mathcal{O}(H)$  vypisování vstupu. V tom případě jste si ale špatně zvolili formát vstupu, který byl na vás :)

Mý si jako formát vstupu zvolime seznam trojic  $(A, B, x)$ . Každá třída, že z  $A$  do  $B$  bylo provedeno  $x$  honorů. Součet všech  $x$  bude  $H$ , ale ukážeme, že máme vygenerované pokrytí lze popsat pomocí nejvýše  $2N$  trojic.

Nevyřešené začátky si budeme ukládat do fronty, ale místo toho, abychom si do ní vkládali každý zvlášť, můžeme si tam dvojitě  $(A, a)$  vyjadřující, že z  $A$  máme ještě  $a$  nevyřešených začátků.

Jak potom postupujeme, když nalezneme vrchol  $Z$ , kde končí nějaké honory? V každém takovém vrcholu je  $l - p = z$  konci, které je potřeba propojit se začátky. Tyto začátky poskládáme z toho, co najdeme na začátku fronty.

Podíváme se na první  $(A, a)$  ve frontě. Pokud  $a \leq z$ , všech-

ny nevyřešené začátky z  $A$  spojíme s  $Z$ , vyřšíme  $(A, Z, a)$  a odstraníme z fronty  $(A, a)$ . Navíc snížíme  $z$  o  $a$ . Toto opakujeme, dokud neodstraníme všechny začátky, které dokážeme vyřešit celé.

Až poslední začátek, kdy  $a > z$ , nedokážeme vyřešit natolik, abychom ho mohli vyhodit z fronty. V tu chvíli  $a$  ve frontě snížme o  $z$ , a napsledy vyřšíme  $(A, Z, z)$ . Tím jsme vyřešili všechny konce v domě  $Z$ .

Všimněte si, že částicevých snížení ve frontě bude nejvýše tolik, kolik je vrcholů s konci, tedy nejvýše  $N$ . Zároveň, odstranění z fronty konkrétní dům lze jen jednou, a do fronty jsme vložíli každý dům nejvýše jednou. Dohromady tedy vyřšíme nejvýše  $2N$  tříd. A protože jsme si tím zároveň omezili velikost fronty na  $N$ , takto upravený algoritmus už má časovou i paměťovou složitost  $\mathcal{O}(N)$ .

Program (Python 3):

`http://ksp.mff.cuni.cz/viz/28-4-1.py`

*Ondra Hlavatý*

### 28-4-2 Podepisování dokumentů

Na začátek zvolme jednoduchý přístup. Vybereme si dvojici a dáme ji dokumenty. Potom se podepíše na to, jak dlouho by podepisování trvalo. Takto to zkusíme pro každou spouštěcí dvojici a vybereme z nich tu nejlepší.

A jak zjišťovat celkovou dobu podepisování dokumentu pro danou startovací dvojici? Nejjednodušší je krokovat po minutě. Rychlejší přístup rovnou skáče na ty minuty, kdy se nějaký člověk dokončí svou podpis.

Mějme tedy dvě čísla (každé pro jednu sadu dokumentů). Tato čísla nám udávají, ve které minutě přibude další podpis pod danou sadu dokumentů. Pokaždé vybereme menší z těchto čísel, v takovém čase se sada posune k dalšímu člověku. Dokument tedy pošleme dalšímu člověku a čas příštího podpisu aktualizujeme (přičteme dobu podepisování tímto člověkem). Toto opakujeme, dokud se nepodepíší všichni.

Jeden průběh dokumentu jsme schopni zpracovat v lineárním čase a musíme vyzkoušet  $N$  dvojic. Dostáváme tedy časovou složitost  $\mathcal{O}(N^2)$ .

#### Zrychlujeme

Pojdme se podívat na rychlejší řešení. Budeme využívat již spocítané příklady, čímž si ušetříme jejich opětovné počítání (této technice se říká dynamické programování).<sup>3</sup>

Nejprve si stejně jako v předchozím případě, vybereme libovolnou dvojici a pro ni si algoritmem z předchozí části spočítáme celkovou dobu podepisování. Navíc si ale zapamatujeme, kde dokumenty skončí a kdy přibyl poslední podpis pod první sadu a druhou sadu.

Nyní si představme, že bychom dokumenty dali o jednu pozici vedle tak, že první člověk, co podepsoval druhou sadu, bude nyní první, který bude podepsovat první sadu. Ukážeme si, že tato situace se v určitém smyslu příliš neliší od té předchozí, kterou již máme spocítanou.

Podíváme se na skupinu lidí, která podepíše druhou sadu. Tato skupina oproti předchozímu řešení přišla o svého prvního člena, který nyní podepíše první sadu. Budeme-li tedy

Zopakujeme si, co jsme postupně utvářeli – nejprve jsme vy-mysleli ponalou rekurzivní funkci, kterou jsme zrychlili zapamatovávatům si mezivýsledků.

Nakonec jsme ale celou rekurzi „obrátili naruby“ a mezivýsledky počítali od nejmenšího k největšímu, aniž bychom se starali o to, jak se na ně přivodí rekurze přela.

V případě Fibonacciho čísel je samozřejmě snadné přijít rovnou na nerekurzivní řešení a dokonce si všimnout, že si stačí pamatovat jen poslední dvě hodnoty, a paměťovou složitost také zredukovat na konstantní.

Zmíněný obecný postup zrychlování rekurze nebo rovnou řešení úlohy od nejmenších podproblémů k těm největším funguje i pro řadu složitějších úloh. Obvykle se mu říká *dynamické programování*.

#### Problém batohu

Je dáno  $N$  předmětů o hmotnostech  $m_1, \dots, m_N$  (celočíslových) a také číslo  $M$  (nosnost batohu). Úkolem je vybrat některé z předmětů tak, aby součet jejich hmotností byl co největší, ale přitom nepřekročil  $M$ . Předvedeme si algoritmus, který tento problém řeší v čase  $\mathcal{O}(MN)$ .

Náš algoritmus bude používat pomocné pole  $A[0 \dots M]$  a jeho čímsní bude rozkláena do  $N$  kroků. Na konci  $k$ -tého kroku bude prvek  $A[i]$  nemulová právě tehdy, jestliže z prvních  $k$  předmětů lze vybrat předměty, jejichž součet hmotností je přesně  $i$ .

Před prvním krokem (po nulém kroku) jsou všechny hodnoty  $A[i]$  pro  $i > 0$  nulové a  $A[0]$  má nějakou nemulovou hodnotu, řekněme  $-1$ .

Všimněme si, jak kroky algoritmu odpovídají podílům, které řešíme – v prvním kroku vyřešíme podílům tvořenou jen prvním předmětem, ve druhém kroku prvními dvěma předměty, pak prvními třemi předměty atd.

Popíšeme si nyní  $k$ -tý krok algoritmu. Pole  $A$  budeme pro-cházet od konce, tj. od  $i = M$ . Pokud je hodnota  $A[i]$  stále nulová, ale hodnota  $A[i - m_k]$  je nemulová, znamáme hodnotu tu užčenou v  $A[i]$  na  $k$  (později si vysvětlíme, proč zrovna na  $k$ ).

Nyní si rozmyslíme, že po provedení  $k$ -tého kroku odpovídá nemulové hodnoty v poli  $A$  hmotnostem podmnožin z prvních  $k$  předmětů (*podmnožina* je v podstatě jen výběr nějaké části předmětů).

Pokud je hodnota  $A[i]$  nemulová, pak buď byla nemulová před  $k$ -tým krokem (a v tom případě odpovídá hmotnosti nějaké podmnožiny prvních  $k - 1$  předmětů) anebo se stala nemulou v  $k$ -tém kroku.

Potom ale hodnota  $A[i - m_k]$  byla před  $k$ -tým krokem nemulová, a tedy existuje podmnožina prvních  $k - 1$  předmětů, jejíž hmotnost je  $i - m_k$ . Přidáním  $k$ -tého předmětu k této podmnožině vytvoříme podmnožinu předmětů hmotnosti přesně  $i$ .

Naopak, pokud lze vytvořit podmnožinu  $X$  hmotnosti  $i$  z prvních  $k$  předmětů, pak takovou podmnožinu  $X$  lze buď vytvořit jen z prvních  $k - 1$  předmětů, a tedy hodnota  $A[i]$  je nemulová již před  $k$ -tým krokem, anebo  $k$ -tý předmět je obsazen v takové množině  $X$ .

Potom ale hodnota  $A[i - m_k]$  je nemulová před  $k$ -tým krokem (hmotnosti podmnožiny  $X$  bez  $k$ -tého prvku je  $i - m_k$ ) a hodnota  $A[i]$  se stane nemulou v  $k$ -tém kroku.

Po provedení všech  $N$  kroků odpovídají nemulové hodnoty  $A[i]$  přesně hmotnostem podmnožin ze všech předmětů, co máme k dispozici. Speciálně největší index  $i_0$  takový, že hodnota  $A[i_0]$  je nemulová, odpovídá hmotnosti největší podmnožiny předmětů, která nepřekročí hmotnosti  $M$ .

Nalezt jednu množinu této hmotnosti také není obtížné: v  $k$ -tém kroku jsme měli nulové hodnoty v poli  $A$  na hodnotu  $k$ , takže v  $A[i_0]$  je uloženo číslo jednoho z předmětů nějaké takové množiny, v  $A[i_0 - m_{i_0}]$  číslo dalšího předmětu atd. Zdrojový kód tohoto algoritmu lze nalézt na další stránce.

Časová složitost algoritmu je  $\mathcal{O}(NM)$ , neboť se skládá z  $N$  kroků, z nichž každý vyžaduje čas  $\mathcal{O}(M)$ . Paměťová složitost čími  $\mathcal{O}(N + M)$ , což představuje paměť potřebnou pro uložení pomocného pole  $A$  a hmotností daných předmětů.

```
# Jiz existující proměnné:
# N - počet předmětů
# M - hmotnostní omezení
# hmotnosti - pole van jednorčlívých předmětů
A = [0] * M
```

```
A[0] = -1
for k in range(N):
    for i in range(M, hmotnost[k]-1, -1):
        if (A[i]-hmotnost[k]) i = 0) and (A[i] == 0):
            A[i] = k
            i = M
            while A[i] == 0:
```

```
                i -= 1
                print("Maximální hmotnost: {}".format(i))
                print("Předměty v množině: ", end="")
                while A[i] i = -1:
                    print(" {}".format(A[i]), end="")
                    i = i - hmotnost[A[i]]
```

#### Cvičení a poznámky

- Proč pole  $A$  procházíme pozadu a ne popředí?
- Složitost algoritmu vypadá jako polynomiální, ale to je trochu podvod. Závisí totiž na hodnotě  $M$ . Pokud toto hodnotu na vstupu zapíšeme obvyklým způsobem, tedy v desítkové nebo dvojkové soustavě, použijeme řádové  $\log M$  cífer.

Náš  $M$  proto bude vzhledem k délce vstupu až exponenciálně velké. To je typický příklad takzvaného *pseudopolynomiálního* algoritmu – tedy takového, jenz je vzhledem k hodnotám na vstupu polynomiální, ale k délce vstupu exponenciální. Podobnosti si můžete přestřít v kuchařce o řekých úlohách.<sup>2</sup>

#### Nejkratší cest z Floydův-Warshallův algoritmus

Náš další příklad bude z oblasti grafových algoritimů, ale zkusíme si jej nejdříve říct bez grafů:

Bylo-nelyo-je  $N$  měst. Mezi některými dvojitými měst ve-dou obousměrné silnice, jejichž (nezáporné) délky jsou dány na vstupu. Předpokládáme, že silnice se jinde než ve městech nepokřakávají (pokud se kříží, tak mimotovornově).

Úkolem je spočítat nejkratší vzdálenosti mezi všemi dvojitými měst, tj. délky nejkratších cest mezi všemi dvojitými měst.

Cestou rozumíme posloupnost měst takovou, že každá dvě

<sup>3</sup> Viz kuchařku na straně 8 tohoto teákta.

<sup>2</sup> `http://ksp.mff.cuni.cz/viz/kucharcky/tezke-problemy`

po sobě následující města jsou spojené silnicí, a délka cesty je součet délek silnic, které tato města spojují.

V grafové terminologii tedy máme daný ohodnocený neorientovaný graf a chceme zjistit délky nejkratších cest mezi všemi dvojicemi jeho vrcholů.

Přijďme na to následovně – vzdálenosti mezi městy jsou na začátku algoritmu uloženy ve dvoumnožiněm poli  $D$ , tj.  $D[i][j]$  je vzdálenost z města  $i$  do města  $j$ . Pokud mezi městy  $i$  a  $j$  nevede žádná silnice, bude  $D[i][j] = \infty$  (v programu bude tato hodnota rovna nějakému dostatečně velkému číslu).

V průběhu výpočtu si budeme na pozici  $D[i][j]$  udržovat délku nejkratší dosud nalezené cesty mezi městy  $i$  a  $j$ .

Algoritmus se skládá z  $N$  fází. Na konci  $k$ -té fáze bude v  $D[i][j]$  uložena délka nejkratší cesty mezi městy  $i$  a  $j$ , která může procházet skrz libovolná z měst  $1, \dots, k$ .

V průběhu  $k$ -té fáze tedy stačí vyzkoušet, zda je mezi městy  $i$  a  $j$  kratší stávající cesta přes města  $1, \dots, k-1$ , jejíž délka je uložena v  $D[i][j]$ , nebo nová cesta přes město  $k$ .

Pokud nejkratší cesta prochází přes město  $k$ , můžeme si ji rozdělit na nejkratší cestu z  $i$  do  $k$  a nejkratší cestu z  $k$  do  $j$ . Délka takové cesty je tedy rovna  $D[i][k] + D[k][j]$ .


Takže pokud je součet  $D[i][k] + D[k][j]$  menší než stávající hodnota  $D[i][j]$ , nahradíme hodnotu na pozici  $D[i][j]$  tímto součtem, jinak ji ponecháme.

Z popisu algoritmu přímo plyne, že po  $N$ -té fázi je na pozici  $D[i][j]$  uložena délka nejkratší cesty z města  $i$  do města  $j$ .

Protože v každé z  $N$  fází algoritmu musíme vyzkoušet všechny dvojice  $i$  a  $j$ , vyžaduje každá fáze čas  $O(N^2)$ . Celková časová složitost našeho algoritmu tedy je  $O(N^3)$ . Co se pámeť týče, vystačíme si s polem  $D$  a to má velikost  $O(N^2)$ .

Program bude vypadat následovně:

```
for k in range(N):
    for i in range(N):
        for j in range(N):
            if d[i][k] + d[k][j] < d[i][j]:
                d[i][j] = d[i][k] + d[k][j]
```



Popíšme si ještě, jak bychom postavovali, kdybychom kromě vzdáleností mezi městy měli také uloženy nejkratší cesty mezi nimi.

To lze jednoduše vyřešit například tak, že si navíc budeme udržovat pomocné pole  $E[i][j]$  a do něj při změně hodnoty  $D[i][j]$  uložíme nejvyšší číslo města na cestě z  $i$  do  $j$  délky  $D[i][j]$  (při změně v  $k$ -té fázi je to číslo  $k$ ).

Máme-li pak vypsat nejkratší cestu z  $i$  do  $j$ , vypíšeme nejprve cestu z  $i$  do  $E[i][j]$  a pak cestu z  $E[i][j]$  do  $j$ . Tyto cesty nalezneme stejným (rekurzivním) postupem.

### Poznámky

- Popis algoritmu vyslovené sváží k „rejnouti“: Jak víme, že spojením dvou cest, které provádíme, vznikne zase cesta (tj. že se na ní nemohou nějaké vrcholy opakovat)?

To samozřejmě nevíme, ale všimneme si, že kdykoliv by to cesta nebyla, tak si ji nevybereme, protože původní cesta bez vrcholů  $k$  bude vždy kratší nebo alespoň stejně dlouhá... tedy dokud se v naší zemi nevystrytule cyklus záporné délky. To bychom měli přičkat do předpokladů našeho algoritmu, kdybychom byli pedanti.

- Pozor na pořadí cyklů – program vyslovené sváží k tomu, abychom psali cyklus pro k jako vnitřní... Ještě pak samozřejmě nebude fungovat.

### Cvičení

- Jak by algoritmus fungoval, kdyby silnice byly jedno- směrné?
- Na první pohled nejpřirozenější hodnota, kterou bychom mohli použít pro  $\infty$ , je **maxint**. To ovšem nebude fungovat, protože  $\infty + \infty$  přetече. Stačí **maxint div 2**?
- Hodnoty v poli si přepisujeme pod rukama, takže by se nám mohly poplést hodnoty z předchozí fáze s těmi z fáze současně. Ale zachrání nás to, že čísla, o která jde, vyjdou v obou fázích stejně. Proč?

### Nejdelší společná podposloupnost

Poslední příklad dynamického programování, který si předvedeme, se bude týkat posloupností. Mějme dvě posloupnosti čísel  $A$  a  $B$ .

```
A = 2 3 3 1 2 3 2 2 3 1 1 2
B = 3 2 2 1 3 1 2 2 3 3 1 2 2 3
```

Chceme najít jejich nejdelší společnou podposloupnost, tedy takovou posloupnost, kterou můžeme získat z  $A$  i  $B$  odstraněním některých prvků. Například pro posloupnosti

```
C = 2 3 1 2 2 3 1 2
```

Jakým způsobem můžeme takovou podposloupnost najít? Nejdříve nás asi napadne vygenerovat všechny podposloupnosti a ty pak porovnat.

Jakmile si ale spočítáme, že všech podposloupností posloupnosti o délce  $n$  je  $2^n$  (každý prvek nezávisle na ostatních buď použijeme, nebo ne), najdeme raději nějaké rychlejší řešení.

Zkusme využít následující myšlenku: vyřešíme tento problém pouze pro první prvek posloupnosti  $A$ . Pak najdeme řešení pro první dva prvky  $A$ , přičemž využijeme předchozích výsledků. Takto pokračujeme pro první tři, čtyři, ... až  $n$  prvků.

Nejprve si rozmyslíme, co všechno si musíme v každém kroku pamatovat, abychom z toho dokázali spočítat krok následující. Uvěřit nám nebude stačit pamatovat si pouze nejdelší podposloupnost, jenže množina všech společných podposloupností je už zase moc velká.

Podíváme se tedy detailněji, jak se změnit tato množina při přidání dalšího prvku  $k$   $A$ : Všechny podposloupnosti, které v množině byly, tam zůstanou a navíc přibude několik nových, konkrétně právě přidáním prvku  $k$ .

Ovšem my si podposloupnosti pamatujeme proto, abychom je časem rozšířili na delší společnou podposloupnost.

Takže pokud známe nějaké dvě stejně dlouhé podposloupnosti  $P$  a  $Q$  končící nově přidaným prvkem v  $A$  a víme, že  $P$  končí v  $B$  dříve než  $Q$ , stačí si z nich pamatovat pouze  $P$ . V libovolném rozšíření  $Q$  třeba totiž zmizíme  $Q$  vyměnit za  $P$  a získat tím stejně dlouhou společnou podposloupnost.

Proto si stačí pro již zpracovaných  $a$  prvků posloupnosti  $A$  pamatovat pro každou délku  $l$  tu ze společných podposloupností  $|A[1..a]|$  a  $B$  délky  $l$ , která v  $B$  končí na nejdelším možném místě.

Dokonce nám bude stačit si místo celé podposloupnosti uložit jen pozici jejího konce v  $B$ . K tomu použijeme dvojrozměrné pole  $D[a][l]$ .

Jestli si dovolíme jedno malé pozorování: Koncové pozice uložené v poli  $D$  se zvětšují s rostoucí délkou podposloupnosti, čili  $D[a][l] < D[a][l+1]$ , protože podposloupnosti délky  $l+1$  nejsou ničím jiným než rozšířeními podposloupnosti délky  $l$  o 1 prvek.

Ted již výpočet samotný:

Pokud už známe celý  $a$ -tý řádek pole  $D$ , můžeme z něj získat  $(a+1)$ -ní řádek. Projďme postupně podposloupnost  $B$ . Když najdeme v  $B$  prvek  $A[a+1]$  (ten právě přidávaný do  $A$ ), můžeme rozšířit všechny podposloupnosti končící před aktuální pozicí v  $B$ .

Nás bude zajímat pouze ta nejdelší z nich, protože rozšířením všech kratších získáme posloupnost, jejíž koncová pozice je větší než koncová pozice některé posloupnosti, kterou již známe. Rozšíříme tedy tu nejdelší podposloupnost a uložíme jí místo původní podposloupnosti.

Toto provedeme pro každý výskyt nového prvku v posloupnosti  $B$ . Všimneme si, že nemusíme procházet pole s podposloupnostmi stále od začátku, ale můžeme se v něm posouvat od nejmenší délky k největší.

Ukážme si, jak vypadá zaplněné pole hodnotami při řešení problému s posloupnostmi z našeho příkladu. Řádky jsou pozice v  $A$ , sloupce délky podposloupnosti:

$D$	1	2	3	4	5	6	7	8	9	10	11	12
1	2	-	-	-	-	-	-	-	-	-	-	-
2	1	5	-	-	-	-	-	-	-	-	-	-
3	1	5	9	-	-	-	-	-	-	-	-	-
4	1	4	6	11	-	-	-	-	-	-	-	-
5	1	2	5	7	12	-	-	-	-	-	-	-
6	1	2	3	7	9	14	-	-	-	-	-	-
7	1	2	3	7	8	12	-	-	-	-	-	-
8	1	2	3	7	8	12	13	-	-	-	-	-
9	1	2	3	5	8	9	13	14	-	-	-	-
10	1	2	3	4	6	9	11	14	-	-	-	-
11	1	2	3	4	6	9	11	14	-	-	-	-
12	1	2	3	4	6	7	11	12	-	-	-	-

Zbyvá popsat, jak z těchto dat zvládneme rekonstruovat hledanou nejdelší společnou podposloupnost (NSP).

Ukážme si to na našem příkladu – jelikož poslední nenulové číslo na posledním řádku je v 8. sloupci, má hledaná NSP délku 8.

$D[12][8] = 12$  říká, že poslední písmeno NSP je na pozici 12 v posloupnosti  $B$ . Jeho pozici v posloupnosti  $A$  určuje nejvyšší řádek, ve kterém se tato hodnota také vyskytuje, v našem případě je to řádek 12. Druhé písmeno tedy budeme utvářet z  $D[10][7]$ , třetí z  $D[9][6]$ , atd.

Jednou z hledaných podposloupností je tedy:

```
posloupnost: 2 3 1 2 2 2 3 1 2
indexy v A: 1 2 4 5 7 9 10 12
indexy v B: 2 5 6 7 8 9 11 12
```

Již zbyvá jen odhadnout složitost algoritmu. Časové nejhorší byl vlastně výpočet hodnot v poli, který se skládá ze dvou hlavních cyklů o délce  $|A|$  a  $|B|$ , což jsou délky posloupnosti  $A$  a  $B$ .

Vnitřní cyklus while proběhne celkem maximálně  $|A| \cdot |B|$  a časovou složitost nám nezhorší. Můžeme tedy říct, že časová složitost je  $O(|A| \cdot |B|)$ .

Posloupnosti jsme si prohlédli tak, aby první byla ta kratší, protože pak je maximální délka společné podposloupnosti i počet kroků algoritmu roven délce kratší posloupnosti, a tedy i velikost pole s daty je kvadrát této délky.

Paměťovou složitost odhadneme  $O(N^2 + M)$ , kde  $N$  je délka kratší posloupnosti a  $M$  té delší.

```
...
if LA > LB:
    (C, A, B) = (A, B, C)
    (T, LA, LB) = (LA, LB, T)
for i in range(LA):
    d[0][i] = LB
    L = 0
    MaxL = 0
    for j in range(LA):
        for i in range(LA):
            d[i][j] = d[i-1][j]
        L = 0
        for j in range(LB):
            while (L == 0) or (d[i-1][L] < j):
                L += 1
            if d[i][L] >= j:
                d[i][L] = j
            if L > MaxL:
                MaxL = L
    LC = MaxL
    j = LA
    for i in range(LC, 0, -1):
        while d[j-1][i] == d[j][i]:
            j -= 1
        c[i-1] = A[j-1]
        j -= 1
...
Dnesní menu servírovali
Martin Mareš a Petr Skoča
```