1. Velká myšlenka — Vnímání

Klíčové poznatky
Počítače vnímají svět pomocí senzorů.
Vnímání není pasivní proces, ale interpretace smyslových vjemů na základě zkušeností a znalostí.
Transformace od signálu k významu probíhá ve fázích, přičemž v každé fázi se uplatňují stále abstraktnější prvky a znalosti vyšší úrovně.

Úroveň ↦	1. stupeň základní školy		2. stupeň základní školy	Střední škola
Ročník ↦	2. ročník	3.—5. ročník	6.—9. ročník	
Koncept ↧				
Vnímání (živé bytosti) 1-A-I	**VC** Rozpoznat lidské smysly a smyslové orgány. **TP** Lidé vnímají svět zrakem, sluchem, hmatem, chutí a čichem.	**VC** Porovnat vnímání člověka a zvířete. **TP** Některá zvířata vnímají svět jinak než lidé. **Doplnění** Netopýři a delfíni používají sonar. Včely vidí ultrafialové záření. Krysy nemají barevné vidění, psi jsou červeno-zeleně barvoslepí. Psi a krysy slyší vyšší frekvence než lidé.	**VC** Uvést příklady toho, jak lidé kombinují informace z více smyslů (modalit). **TP** Lidé mohou využívat korelací mezi smysly, jako je zrak a zvuk, aby pochopili nejednoznačné signály. **Doplnění** V hlučném prostředí je řeč srozumitelnější, když jsou řečníkovi vidět ústa. Lidé se naučí zvuky spojené s různými činnostmi (např. upuštění předmětu) a dokáží rozpoznat, když zvuk neodpovídá jejich očekávání.	**Nepoužije se** — pro účely AI bylo toto téma již dostatečně zpracováno v nižších třídách. V jiných předmětech, například v biologii nebo volitelném předmětu psychologie smyslů, by mohla být podrobněji probrána témata jako chuť, čich, propriocepce a vestibulární orgány. **Možný navazující materiál** optické klamy jako Muller-Lyerův klam nebo Kanizsaův trojúhelník — zeptejte se, kterým z nich podléhají i systémy počítačového vidění.
Vnímání (počítačové senzory) 1-A-II	**VC** Najít a identifikovat senzory (kamera, mikrofon) na počítačích, telefonech, robotech a dalších zařízeních. **TP** Počítače „vidí“ prostřednictvím videokamer a „slyší“ prostřednictvím mikrofonů.	**VC** Ukázat, jak se počítačové vnímání liší od toho lidského. **TP** Většina počítačů nemá chuť, čich ani hmat, ale dokáže vnímat některé věci, které člověk nevnímá, například infračervené záření, extrémně nízké nebo vysoké frekvence zvuků nebo magnetismus.	**VC** Uvést příklady toho, jak inteligentní systémy kombinují informace z více senzorů. **TP** Samořiditelná auta kombinují počítačové vidění s daty z radaru nebo lidaru, GPS měření a údaje z akcelerometru, aby vytvořily podrobnou reprezentaci prostředí a toho, jak se v něm pohybují.	**VC** Popsat omezení a výhody různých typů počítačových senzorů. **TP** Senzory jsou zařízení, která snímají fyzikální jevy, jako je světlo, zvuk, teplota nebo tlak. **Doplnění** Fotoaparáty mají omezené rozlišení, dynamický rozsah a spektrální citlivost. Mikrofony mají omezenou citlivost a frekvenční odezvu. Signály mohou být znehodnoceny šumem, například mikrofonem v hlučném prostředí. Některé senzory mohou detekovat věci, které lidé nedokážou, například infračervené záření, ultrafialové světlo nebo ultrazvukové vlny.
Snímání (digitální reprezentace) 1-A-III	**Nepoužije se**	**VC** Vysvětlit, jak jsou obrázky digitálně reprezentovány v počítači. **TP** Obrázky jsou kódovány jako 2D pole pixelů, kde každý pixel je číslo udávající jas dané části obrazu nebo hodnota RGB udávající jas červené, zelené a modré složky dané části.	**VC** Vysvětlit, jak jsou zvuky digitálně reprezentovány v počítači. **TP** Zvuky jsou digitálně reprezentovány vzorkováním tvaru vlny v diskrétních bodech (obvykle několik tisíc vzorků za sekundu), čímž se získá řada čísel. *Pozn. překl: Při digitalizaci zvuku, což je proces převodu analogového zvukového signálu na digitální formát, je zvuková vlna „vzorkována“ nebo „snímána“ v pravidelných intervalech. Každý vzorek představuje hodnotu amplitudy zvukové vlny v daném okamžiku. Tyto vzorky jsou pak převedeny na digitální data ve formě číselných hodnot. Četnost, s jakou jsou tyto vzorky pořizovány, se nazývá vzorkovací frekvence a je vyjádřena v hertzech (Hz).*	**VC** Vysvětlit, jak jsou reprezentovány údaje z radaru, lidaru, GPS a akcelerometru. **TP** Radar a lidar zobrazují hloubku: každý pixel představuje hodnotu hloubky. GPS trianguluje polohu pomocí satelitních signálů a udává polohu jako zeměpisnou délku a šířku. Akcelerometry měří akceleraci ve 3 ortogonálních rozměrech. **Doplnění** Radar a lidar měří vzdálenost jako dobu, za kterou se odražený signál vrátí k vysílači. GPS určuje polohu triangulací přesně časovaných signálů ze tří nebo více satelitů. Akcelerometry používají ortogonálně orientované tenzometry k měření zrychlení ve třech rozměrech.
Vnímání vs. zpracování 1-B-I	**VZ** Uvést příklady inteligentních a neinteligentních strojů a diskutovat o tom, co dělá stroj inteligentním. **TP** Mnoho strojů používá senzory, ale ne všechny je používají inteligentně. Neinteligentní stroje se omezují na jednoduché snímání. Inteligentní stroje vykazují vnímání. **Doplnění** Fotoaparáty a telefony mohou zaznamenávat a přehrávat obraz a zvuk, ale extrakce významu z těchto signálů vyžaduje zpracování pomocí umělé inteligence.	**VC** Použít softwarový nástroj, jako je přepis řeči nebo ukázka vizuálního rozpoznávání objektů, k demonstraci počítačového vnímání a vysvětlit, proč se jedná o vnímání, a nikoli o pouhé snímání. **TP** Vnímání je získávání významu ze smyslových signálů. **Doplnění** Rozpoznávání řeči a detekce obličeje jsou příklady vnímání. Automatické dveře aktivované tlakovou podložkou nebo ultrazvukovým senzorem nevykazují vnímání, protože pouze reagují na surový signál, nikoliv využívají znalosti k získání významu ze signálu.	**VC** Uvést příklady různých typů počítačového vnímání, které dokáže extrahovat význam ze sensorických signálů. **TP** Existuje mnoho specializovaných algoritmů pro percepční úlohy, jako je detekce obličeje, rozpoznávání výrazu tváře, rozpoznávání objektů, detekce překážek, rozpoznávání řeči, měření hlasového napětí, rozpoznávání hudby atd.	**VC** Vysvětlit algoritmy zpracování zvuku a obrazu a jejich využití v reálných aplikacích. **TP** Čtečky registračních značek, čtečky poštovních směrovacích čísel, biometrické odemykání telefonů, označování lidí v příspěvcích na Facebooku, identifikace objektů na fotografiích (např. Google Lens) nebo hlasoví asistenti.
Zpracování (extrakce příznaků) 1-B-II	**VC** Uvést příklady příznaků (v orig. features), které bychom hledali, kdybychom chtěli rozpoznat určitou třídu objektů (např. kočky) na obrázku. **TP** Vizuální vlastnosti objektu zahrnují jeho dílčí části, textury a barvy. **Doplnění** K rozpoznání koček je třeba hledat uši, tlapky, fousky, kočičí nos a ocas, textury připomínající srst a vzory zbarvení typické pro kočky.	**VC** Ukázat, jak funguje detekce obličeje pomocí extrakce příznaků v obličeji. **TP** Detektory obličeje používají speciální algoritmy pro hledání očí, nosů, úst a čelistí. **Doplnění** Rozpoznávání obličeje jde ještě o krok dál a snaží se určit, čí obličej byl rozpoznán. Rozpoznávání je založeno na kvantifikovatelných vlastnostech, jako je vzdálenost mezi očima nebo tvar linie čelisti.	**VC** Ilustrovat koncept extrakce příznaků z obrázků pomocí simulace detektoru hran. **TP** Umístění a orientace hran v obraze jsou vlastnosti, které lze zjistit hledáním specifického uspořádání světlých a tmavých pixelů v malé (lokální) oblasti.	**VC** Vysvětlit, jak se ze zvukových vln a obrázků získávají vzory. **TP** Spektrogram řeči ukazuje, kolik energie se nachází ve zvukových vlnách v různých oblastech frekvencí. Formanty, důležité frekvence v těchto zvukových spektrech, pomáhají rozpoznat samohlásky ve mluveném slově. Když analyzujeme obrazy, začínáme hledáním změn v jasnosti nebo „hran“ v různých velikostech, což nám pomáhá rozpoznat vzory. **Doplnění** Různé formanty odpovídají různým zvukům v řeči, jako jsou různé samohlásky a souhlásky.
Zpracování (úrovně abstrakce: jazyk) 1-B-III	**VC** Popsat různé hlásky, které tvoří mluvený jazyk, a ke každé hlásce uvést slovo, které ji obsahuje. **TP** Aby počítač rozuměl řeči, musí být schopen rozpoznat zvuky, ze kterých jsou slova složena. **Doplnění** V češtině rozlišujeme jednoduché samohlásky: i, í, e, é, a, á, o, ó, u, ú a dvojhlásky: ou, eu, au.	**VC** Ukázat, jak lze z posloupnosti zvuků správně určit slova, i když jsou některé zvuky nejasné. **TP** Přechod od zvuků ke slovům je jedním z kroků v abstrakci při porozumění řeči. **Doplnění** Zkuste hádat čtyřpísmenné slovo, máte-li pouze částečné informace o hláskách na jednotlivých pozicích, např. první hláska je buď „f“, nebo „d“ a druhá hláska je buď „l“, nebo „n“. Znalost omezení mezi sousedními hláskami ve slově lze použít k zúžení možností.	**VC** Ukázat, jak lze rozpoznat sekvence slov jako fráze, i když jsou některá slova nejasná, tím, že se podíváme, jak na sebe slova navazují (kontext). **TP** Informace na vyšších úrovních reprezentace lze použít k řešení nejasností na nižších úrovních jazykové abstrakce. **Doplnění** Pokud první slovo ve tříslovné frázi může být „Jdu“, „Viděl“ nebo „Má“, druhé slovo může být „do“, „na“ nebo „s“ a třetí slovo může být „kino“, „písek“ nebo „program“, pak nejpravděpodobnější fráze je „Jdu do kina“, protože je gramaticky správná a běžně používaná.	**VC** Znázornit hierarchii abstrakce v porozumění řeči od zvuků po věty, a ukázat, jak se porozumění na každé úrovni využívá k řešení nejasností na dalších úrovních. **TP** Hierarchie mluveného jazyka je následující: vlny → artikulační gesta → zvuky → morfémy → slova → fráze → věty. **Doplnění** Přechod od nejasných a nejednoznačných signálů k významu vyžaduje rozpoznání struktury a použití doménových znalostí na více úrovních abstrakce. Klasický příklad: věty „Nesmí do lesa.“ a „Nese mýdlo do lesa.“ jsou na úrovni vlnových průběhů velmi podobné.
Zpracování (úrovně abstrakce: vidění) 1-B-IV	**VC** Předvést oddělení postavy a pozadí určením postav v popředí a pozadí obrázku. **TP** Vizuální scény mají strukturu, která zahrnuje pozadí a popředí, přičemž objekty popředí částečně zakrývají pozadí (okluze). **Doplnění** Pochopení toho, že scény mají svou strukturu, představuje způsob, jak přistupovat k úloze počítačového vidění. Počítače musí provést oddělení popředí a pozadí, aby mohly vybrat objekty na obrázku.	**VC** Ukázat, jak se obrysy částečně zakrytých objektů v obraze liší od skutečných tvarů objektů. **TP** Při rozpoznávání objektů je třeba brát v úvahu vliv okluze (tj. blokaci zorného pole kamery nebo senzoru, když objekt překrývá jiný objekt). **Doplnění** Uvažujte například o dvou krabicích od cereálií, z nichž jedna stojí před druhou a částečně ji zakrývá. Žáci mohou být požádáni, aby nakreslili obrysy jednotlivých políček tak, jak jsou zobrazeny na obrázku. Zakrývající políčko bude obdélník, ale zakryté políčko bude konkávní mnohoúhelník. Studenti pak mohou být požádáni, aby nakreslili skutečný obrys krabice jako tečkovanou čáru v původním obrázku. Měli by si uvědomit, že odvozují skutečný obrys; krabice může být vadná a mít jiný tvar v oblasti, kterou nevidí.	**VC** Popsat, jak lze z detektorů hran vytvořit složitější detektory prvků, např. písmen nebo tvarů. **TP** Postup od signálu k významu probíhá v několika fázích, přičemž v každé fázi jsou extrahovány stále složitější prvky. **Doplnění** Příklad: detekce písmene „A“ hledáním kombinace tří orientovaných hran. Hrany se detekují pohledem na pixely.	**VC** Prokázat, jak vnímání na vyšší úrovni abstrakce vychází z předchozích, nižších úrovní abstrakce. **TP** Scény se skládají z objektů, které jsou tvořeny povrchy a hranicemi. Hranice jsou vyznačeny obrysy, které se skládají z hran, jež jsou tvořeny pixely. Vztahy mezi objekty ve scéně, jako například že jeden objekt zakrývá druhý, jsou odvozeny z uspořádání jejich povrchů a hranic.
Doménové znalosti a jejich druhy 1-C-I	**VC** Popsat některé věci, které musí inteligentní systém „znát“, aby mohl odpovědět na otázku. **TP** Aby počítače rozuměly mluveným požadavkům, musí znát naši slovní zásobu a výslovnostní zvyklosti a musí být schopny rozlišit otázku od příkazu. **Doplnění** „Bude dnes pršet?“ vyžaduje všechny výše uvedené znalosti.	**VC** Ukázat, jak systém převodu textu na řeč dokáže řešit nejednoznačnost na základě kontextu a jak se zvyšuje jeho chybovost, pokud jsou zadány negramatické nebo nesmyslné vstupy. **TP** Systémy rozpoznávání řeči jsou vycvičeny na milionech výroků, což jim umožňuje rozlišit běžné a neobvyklé sekvence slov, což jim pomáhá vybrat nejpravděpodobnější interpretaci vstupu. **Doplnění** Srovnejte přepis „Být sám za dubem.“ a „Bít sám na buben“. Nebo si vyzkoušejte systém „Naolejuje-li Julie ty koleje.“ nebo „Šil švec sešlý se šlí sesli.“	**VC** Klasifikovat daný obrázek (např. „dopravní scéna“, „přírodní scéna“, „společenské setkání“ atd.) a poté popsat, jaké znalosti by počítač potřeboval, aby porozuměl scénám tohoto typu. **TP** V počítačovém vidění se za doménové znalosti považuje například to, jaké druhy objektů se pravděpodobněji objeví ve scéně, kde se nacházejí jiné objekty. A také to, jak částečné zakrytí nebo osvětlení objektů změnit jejich vzhled. **Doplnění** V dopravní scéně se na silnicích pravděpodobněji objevují více auta, než chodci. Některé dopravní značky se objevují podél silnic, jiné nad silnicí. Chodci se objevují na chodnících, přechodech, ale občas také na silnicích. V přírodní scéně bude v horní části snímku pravděpodobněji modrá obloha a v dolní části snímku spíše zelená tráva nebo stromy.	**VC** Analyzovat jeden nebo více obrazových datasetů a popsat, jaké informace poskytují a jak je lze využít k získání doménové znalosti a jejich druhy pro systém počítačového vidění. **TP** Doménové znalosti jsou v AI systémech často odvozeny ze statistik shromážděných z milionů vět nebo obrázků. **Doplnění** Ukázkové datasety: » ImageNet nebo » Coco. Automatické návrhy dalších slov při psaní textů nebo e-mailů jsou příkladem použití statistického předpovídání. Analýza rozsáhlých obrázkových datasetů umožňuje například lépe odhadnout, co se na daném obrázku vlastně nachází.
Doménové znalosti (inkluzivita) 1-C-II	**VC** Vysvětlit, proč inteligentní systémy musí být schopni porozumět jiným jazykům než angličtině. **TP** Systémy rozpoznávání řeči musí být přizpůsobeny různým jazykům, protože je bude používat mnoho různých lidí. **Doplnění** Hlasový asistent Alexa umožňuje nastavení několika dialektů angličtiny (americký, britský, kanadský, indický) a mnoha evropských a asijských jazyků.	**VC** Vysvětlit, proč doménvé znalosti musí být dostatečně široké, aby zahrnovaly všechny skupiny, kterým má aplikace sloužit. **TP** Systémy rozpoznávání řeči musí umožňovat různé přízvuky a alternativní výslovnosti. Systémy pro rozpoznávání hudby musí znát různé hudební žánry.	**VC** Popsat, jak může systém počítačového vidění vykazovat kulturní předsudky, pokud postrádá znalost objektů, které se nevyskytují v kultuře lidí, kteří jej vytvořili (předpojatost). **TP** Aplikace využívající umělou inteligenci musí být založena na datech, která pokrývají všechny možnosti, způsoby a kontexty jejího použití. **Doplnění** Samořiditelné auto, které zná pouze americké dopravní značky, nebude schopno rozpoznat dopravní značky v Evropě nebo Asii.	**VC** Popsat některé technické obtíže spojené s dobrým fungováním počítačových systémů vnímání pro různé skupiny. **TP** Tmavé nebo málo kontrastní rysy obličeje jsou hůře rozpoznatelné než světlé, vysoce kontrastní rysy. Výška hlasu u dětí je vyšší a méně zřetelně artikulovaná než řeč dospělých.

VC (vzdělávací cíl) — co by žáci/studenti měli umět. **TP** (trvalé porozumění) — co by žáci/studenti měli znát.

2. Velká myšlenka — Reprezentace dat a usuzování

Klíčové poznatky	Vysvětlení
Reprezentace jsou datové struktury, metody usuzování jsou algoritmy.	Umělá inteligence využívá informatické nástroje: datové struktury a algoritmy.
Data reprezentujeme proto, abychom s nimi mohli pracovat. Při návrhu algoritmů vycházíme ze zvolené datové reprezentace problému.	Reprezentace a usuzování jsou vzájemně závislé.
Dva hlavní typy reprezentace znalostí jsou: symbolické a číselné.	Usuzování na základě symbolických reprezentací se provádí pomocí logických odvozovacích pravidel, zatímco usuzování na základě číselných reprezentací využívá složitých matematických funkcí, například neuronových sítí.
Znalost znamená nejen schopnost reprezentace dat, ale také usuzování.	Knihy a videa mohou představovat znalosti, ale „nevědí“ věci, protože tyto znalosti nedokáží využít.
AI systémy jsou považovány za inteligentní, pokud používají netriviální cyklus vnímání—rozhodování—jednání k dosažení svých cílů.	Aby bylo možné tyto systémy považovat za inteligentní, musí alespoň jedna ze složek vnímání, rozhodování (usuzování) nebo jednání, vyžadovat systémovou komplexitu či značný výpočetní výkon. Automatické otevírání garážových vrat není inteligentní systém, protože je triviální.

Úroveň ↦	1. stupeň základní školy		2. stupeň základní školy	Střední škola
Ročník ↦	2. ročník	3.—5. ročník	6.—9. ročník	
Koncept ↧				
Reprezentace (abstrakce) 2-A-I	**VC** Vytvořit plánek domu, školy nebo mapku okolí. **TP** Mapa není území. Mapa je vizuální reprezentace území.	**VC** Ukázat, jak různé typy map reprezentují odlišné aspekty světa. **TP** Mapy mohou být geograficky přesné nebo jen ukazují, která místa jsou dosažitelná z jiných míst (topologie). Mohou obsahovat mnoho typů informací, například názvy a velikosti měst a obcí nebo typy silnic, které je spojují. **Doplnění** Samořiditelná auta se při plánování tras spoléhají na silniční mapy. Mapy tras metra, vlaků a autobusů mohou být geografické nebo topologické.	**VC** Slovy popsat herní plán, např. piškvorky, hadi a žebříky, Monopoly nebo šachy. **TP** Zásadní informace o herním plánu jsou: soubor políček, která desku tvoří, vztahy mezi nimi a pozice figurek. **Doplnění** Programy pro hraní her pracují s abstraktními reprezentacemi plánů. Šachový program zná pozice a soubory všech 64 polí, ale nepředstavuje vlastnosti fyzické šachovnice, jako jsou její rozměry nebo materiál, ze kterého je vyrobena.	**VC** Slovy popsat, jak reprezentovat koncept jako schéma. **TP** Schéma popisuje koncept výčtem jeho nadkonceptů a definováním jeho vlastností, z nichž některé mohou být zděděny od nadkonceptů. Příklady lze nalézt na webu » schema.org. **Doplnění** Miliony webových stránek používají schémata, aby byly informace srozumitelné pro programy umělé inteligence (jako jsou vyhledávače a doporučovací systémy), které využívají » znalostní grafy.
Reprezentace (symbolické reprezentace) 2-A-II	**VC** Uvést příklady symbolů, se kterými se setkáváme v každodenním životě. **TP** Koncepty lze znázornit pomocí symbolů namísto slov. **Doplnění** Příklady symbolů: emotikony; kříže, káry, srdce a piky v balíčku karet; znak dolaru a centu; dopravní značka STOP... Programy umělé inteligence používají symboly stejně jako lidé.	**VC** Uvést příklady stromových struktur, které lidé běžně používají, a vysvětlit vztahy mezi jednotlivými uzly (body). **TP** Mnoho typů informací má hierarchickou strukturu, kterou lze vizualizovat jako strom. **Doplnění** Rodokmeny, taxonomie, obsah (např. v knize), stromy hierarchie organizace a jednoduché formy » myšlenkových map mají stejnou hierarchickou strukturu: každý uzel je propojen s nadřazeným uzlem, který se v hierarchii nachází výše. Taxonomické informace jsou důležitou součástí znalostních grafů používaných systémy umělé inteligence a obvykle tvoří stromovou strukturu v rámci většího grafu.	**VC** Znázornit strukturu, jako je herní plán, geografická nebo myšlenková mapa do znalostního grafu a vysvětlit propojení jednotlivých složek. **TP** Jednotlivé uzly (body) znalostního grafu představují věci (objekty), které jsou mezi sebou propojené. Třídy (entity) spolu s atributy poskytují doplňující informace o vzájemném propojení a významu mezi uzly. **Příklady** Ve hře typu „hadi a žebříky“ jsou políčka reprezentována jako uzly ve znalostním grafu. Sousední políčka jsou propojena. A některá políčka, která nesousedí, jsou propojena žebříky nebo hady. V silniční mapě jsou města uzly a silnice je propojují. Mohou být označeny typem silnice nebo hodnotou kilometrů (atributy). Myšlenkové mapy jsou druhem neformálního znalostního grafu, který používají lidé, nikoli počítače.	**VC** Přeložit premisy deduktivního usuzování (sylogismus) vyjádřeného v češtině do logického zápisu a správně sylogismus doplnit. (vzít dvě výchozí tvrzení (premisy) sylogismu a převést je do formálního logického zápisu) **TP** Sylogismy představují výroky o kategoriích a případech způsobem, který umožňuje počítačům odvozovat nové znalosti z existujících znalostí podle jednoduchých pravidel odvozování. Součásti sylogismu jsou hlavní premisa, vedlejší premisa a závěr. **Doplnění** Myšlení lidí je bohaté a složité a neexistuje komplexní popis toho, jak funguje. Zvláštním případem je sylogistické usuzování, které je natolik jednoduché, že můžeme napsat přesná pravidla, jak ho provádět. Sylogistické usuzování je typ deduktivního usuzování, který je běžně používaný systémy umělé inteligence (těmi, co pracují s taxonomickými informacemi). **Příklad** Všichni lidé jsou savci, všichni savci jsou živé bytosti, proto jsou všichni lidé živé bytosti. Pro sylogismy lze použít různé zápisy. Zde je jeden založený na predikátové logice: ∀X [Člověk(X) → Savec(X)] ∀X [Savec(X) → Živá věc(X)] ∀X [Člověk(X) → Živá věc(X)]
Reprezentace (datové struktury) 2-A-III	**VC** Nakreslit strom a každou jeho větev opakovaně dělit na další větve, na jejichž konce (listy) budou zaznamenána data. **TP** Strom je způsob uspořádání informací. **Doplnění** Na konci větve mohou být umístěny různé typy dat. V případě rozhodovacího stromu by těmito daty mohly být otázky a odpovědi. U rodokmenu by byly větve „matka“ a „otec“. Pro taxonomický strom by existovaly taxony s rostoucí specifičností, např. živočichové a rostliny, savci a plazi, primáti a hlodavci.	**VC** Popsat části stromu a jejich vzájemný vztah. **TP** Strom je soubor uzlů (bodů), z nichž každý (kromě kořenového) odkazuje na nadřazený uzel, který je v hierarchii nad ním. Uzly bez potomků se nazývají listy nebo terminální uzly; uzly s potomky jsou neterminální uzly.	**VC** Popsat dílčí části znalostního grafu a jejich vzájemný vztah. **TP** Znalostní graf je soubor označených uzlů propojených vazbami. Každá vazba má zdrojový a cílový uzel; každý uzel má množinu navazujících vazeb (mimo terminálního uzlu). Stromy jsou speciálním případem grafů. **Doplnění** Znalostní grafy se v umělé inteligenci používají k reprezentaci například silničních map (kde města jsou uzlu a silnice je propojují) nebo bludišť. Znalostní graf může reprezentovat osoby, místa a věci a vztahy mezi nimi. Myšlenkové mapy jsou většinou stromy, ale k jednomu uzlu může vést více cest, čímž se mapa stává grafem. Každý uzel je objekt a vazby mohou být označeny vztahy mezi pojmy, nebo mohou být neoznačené.	**VC** Popsat, jak se schémata používají ke strukturování informací o lidech, místech nebo věcech ve znalostních grafech. **TP** Schéma specifikuje atributy popisovaného konceptu a jeho vztahy k jiným konceptům, např. entita *Restaurace* dědí příznaky z entity *Potravinářská zařízení*. **Doplnění** Znalostní graf kóduje informace o věcech a vztazích mezi nimi. Vyhledávače jako Google se spoléhají na znalostní grafy při vytváření znalostních panelů ve výsledcích vyhledávání. Schémata jako *Restaurace* a *Potravinářská zařízení* jsou definována na webu » schema.org.
Reprezentace (příznakové vektory) 2-A-IV	**VC** Určit příznaky, které činí každý objekt jedinečným, a vytvořit jejich tabulku pro uspořádání objektů. **TP** Předměty lze popsat pomocí příznaků (vlastností), které mají. **Doplnění** Může jít například o kostky lega, jejichž příznaky jsou různé tvary, velikosti či barvy. Nebo o příznaky, které odlišují různé druhy zvířat: kočky, psy, kuřata, zlaté rybky, tučňáky atd. — např. zda má srst, zda létá apod. Nebo také příznaky náležející emotikonům, které reprezentují různé emoční stavy.	**VC** Sestavit reprezentaci příznakových vektorů pro množinu objektů a ukázat, jak jsou si podobné objekty v prostoru blízké. **TP** Doporučovací systémy reprezentují věci, jako jsou filmy, knihy, spotřební zboží nebo příspěvky na sociálních sítích, pomocí příznakových vektorů. **Doplnění** Příznakové vektory reprezentují koncepty jako posloupnost čísel. Vzdálenost mezi dvěma příznakovými vektory lze měřit počítáním počtu pozic, ve kterých se neshodují, takže podobné objekty leží v prostoru blíže u sebe. Příznakové vektory lze sestavit ručně, ale také automaticky pomocí strojového učení. **Příklad** Žáci/studenti mohou vytvořit rozhodovací strom pro určování různých druhů těstovin. Otázky, které tvoří uzly (body) stromu, mohou poskytnout příznaky pro binární reprezentaci vektoru rysů typů těstovin.	**VC** Vysvětlit, jak vektorové reprezentace slov (v ang. word embeddings) reprezentují slova jako posloupnosti čísel. **TP** Vektorové reprezentace slov jsou klíčovou součástí neuronového zpracování přirozeného jazyka (NLP), včetně strojového překladu (např. Google Translate) a systémů pro generování textu (BERT, GPT-4 apod.). **Doplnění** Každé slovo (vektor) je uzlem v prostoru s mnoha dimenzemi, který je uspořádán tak, aby slova s podobným významem byla blízko sebe. Viz » Word2VecDemo.	**VC** Popsat, jak fungují neuronové sítě typu transformer. **TP** Transformery mapují posloupnosti vstupních slov na posloupnosti výstupních slov, kde jsou slova reprezentována jako příznakové vektory. **Doplnění** Zpracování přirozeného jazyka pomocí neuronových sítí, jako je strojový překlad nebo generování textu, fungují díky vektorovým reprezentacím slov (word embeddings), což jsou příznakové vektory.
Vyhledávání (prohledávání stavového prostoru) 2-B-I	**VC** Znázornit další možný stav ve hře piškvorky při daném výchozím stavu. **TP** Hru, jako jsou piškvorky, lze popsat jako posloupnost stavů, kde každý tah přechází ze stavu do stavu. **Doplnění** Každý stav by měl být zakreslen jako samostatný obrázek. Posloupnosti stavů se mohou lišit v závislosti na tom, jaký tah si žák zvolí. **Můžete vyzkoušet** » online piškvorky Elements of AI — » Vyhledávání a hry	**VC** Nakreslit lineární posloupnosti stavů (na základě tahů protihráče), jak by mohl počítač postupovat ve hře jako piškvorky nebo Nim. **TP** Počítače hrají hry a řeší hádanky tak, že vytvářejí stavový strom, v němž jednotlivé stavy (vrcholy stromu) reprezentují možné situace ve hře a přechody mezi nimi (hrany stromu) odpovídají všem možným tahům a v každém kroku používají algoritmus pro výběr toho dalšího. **Doplnění** V tomto případě se jedná o množinu všech stavů hrací plochy dosažitelných z výchozího stavu (» obrázek) a hrany jsou množiny proveditelných tahů (jsou hráčem proveditelné a odpovídají pravidlům hry). Konkrétní hra (lineární posloupnost pozic na šachovnici: » obrázek) je jednou z cest tímto stavovým prostorem.	**VC** Znázornit, jak může počítač projít bludištěm, najít trasu na mapě nebo vyvozovat z pojmů ve znalostním grafu, nakreslením vyhledávacího stromu. **TP** Počítače prochází bludištěm, hledají trasy a vyvozují z pojmů ve znalostních grafech pomocí vyhledávacích algoritmů, ze kterých vznikají vyhledávací stromy. **Doplnění** Prostor prohledávání — oblast, která vymezuje množinu všech proveditelných kroků při prohledávání grafu, počínaje vybraným startovním uzlem. Operátory, používané pro řešení bludiště, umožňují pohyb o jeden uzel na sever, jih, východ nebo západ. V obecnějším případě prohledávání grafu operátory rozšiřují cestu přidáním nového uzlu na její konec. Proveditelné tahy přidávají uzel, který je dosažitelný přímým spojením v grafu. Dosažitelné stavy jsou ty, do kterých se lze dostat posloupností proveditelných tahů. **Příklad** Chceme-li určit, zda je klokan savec, hledáme ve znalostním grafu cestu z uzlu „klokan“ do uzlu „savec“, která se skládá z kladných spojení. » Stručný úvod do této problematiky.	**VC** Identifikovat typy reálných problémů, které jsou spojeny s vyhledáváním, a popsat jejich stavy a operátory. **TP** Počítače mohou řešit mnoho typů úloh pomocí vyhledávacích technik, pokud lze úlohu popsat jako nalezení cesty z počátečního do cílového stavu. **Doplnění** Příkladem mohou být úlohy plánování (možné přesuny mezi stavy) a rozvrhování (některé přechody jsou vhodnější nebo méně nákladné). Vyhledávací algoritmus určuje, které operátory se mají použít a v jakém pořadí. Nalezení posloupnosti proveditelných kroků (operátorů) k dosažení cílového stavu lze použít i u úloh, jejichž řešení neumožňuje návaznost. Je-li například úkolem naskládat objekty různých velikostí do kontejnerů s různou kapacitou, cílem je umístění objektů do kontejnerů tak, aby žádný kontejner nebyl ve výsledku přeplněný nebo naopak prázdný. To lze formulovat jako vyhledávací úlohu, kde operátor umístí nejdříve jeden objekt do kontejneru, do kterého se vejde, a na konci jsou umístěny rovnoměrně všechny objekty do kontejnerů. U tohoto typu úlohy nezáleží na pořadí, v jakém jsou operátory použity.
Vyhledávání (kombinatorické úlohy) 2-B-II	**VC** Nakreslit jednoduchý vyhledávací strom, který bude obsahovat kořenový uzel a dva navazující proveditelné stavy. **TP** Počítač se při hraní her musí rozhodovat stejně jako lidé. **Doplnění** Žáci nakreslí strom o třech uzlech, jehož kořenem je počáteční stav hry a dvě větve, které navazují na kořenový uzel a znázorňují alternativní tahy. Výchozím stavem nemusí být prázdná šachovnice (viz » obrázek).	**VC** Nakreslit vyhledávací strom zobrazující všechny možné další tahy a jejich výsledné stavy a vybrat nejlepší další tah. **TP** Programy hrající počítačové hry mohou vytvářet vyhledávací stromy, aby se mohly rozhodnout o svém dalším tahu. **Doplnění** Vyhledávací stromy představují způsob, jak systematicky prozkoumat všechny možné tahy ve hře. (» obrázek). Stavový prostor hry je množina všech stavů šachovnice dosažitelných ze startovního stavu a operátory jsou množina možných tahů, které může hráč provést a které jsou v souladu s pravidly hry.	**VC** Modelovat proces řešení úlohy prohledáváním grafu s využitím algoritmu prohledávání do šířky (systematické procházení všech uzlů grafu po vrstvách) a nakreslit vyhledávací strom. **TP** Algoritmus prohledávání do šířky je efektivní metodou pro systematické prozkoumávání grafů, protože umožňuje kompletní a vrstevnaté průzkumy struktury grafu. **Doplnění** Při prohledávání do šířky jsou všechny uzly na aktuální úrovni prohledávaného stromu postupně rozbalovány a vytvářejí další úroveň. Poté je rozšířena další úroveň a proces pokračuje, dokud není dosaženo cíle. Příkladem úkolu vyhledávání je graf vazeb mezi lidmi, v němž hledáme, zda mají dva lidé společného přítele. Dalším úkolem může být určení úrovně odloučení dvou lidí, jako v myšlence » Šest stupňů odloučení.	**VC** Ilustrovat následující algoritmy pro prohledávání stavového prostoru: prohledávání do šířky, prohledávání do hloubky a uspořádané prohledávání pro generování vyhledávacího stromu. **TP** Pro generování vyhledávacího stromu existuje více algoritmů, z nichž každý má své výhody. **Doplnění** Studenti mohou nakreslit strom (psaní kódu je vhodné pro ty pokročilé). » Prohledávání do šířky rychle najde řešení, pokud existují, ale vyžaduje hodně paměti. » Prohledávání do hloubky je lepší než do šířky v případech, kdy počet uzlů na každé úrovni roste exponenciálně, protože spotřebuje méně paměti. » Uspořádané prohledávání může nalézt optimální řešení (s nejnižšími náklady) za předpokladu, že zná přesnou míru nákladů, jako je například celková vzdálenost na silniční mapě, zatímco u předchozích výše zmíněných algoritmech není optimum zaručeno, protože nevěnují pozornost nákladům.
Usuzování (typy usuzovacích úloh) 2-C-I	**VC** Identifikovat klasifikační nebo vyhledávací úlohy. **TP** V klasifikačních úlohách se rozhodujeme, jaký druh věci máme, na základě jejích příznaků (vlastností). Ve vyhledávacích úlohách hledáme cestu od počátku k cíli, například trasu na mapě nebo zkoumáme možné tahy ve hře.	**VC** Rozdělit úlohy na klasifikační nebo vyhledávací. **TP** Klasifikační úlohy přiřazují každý vstup do jedné z předem určených tříd. Vyhledávací úlohy konstruují odpovědi tak, že na stavy aplikují operátory, které generují nové stavy. **Doplnění** Označování obrázků jako fotografiích psů nebo koček (jako v programu » Teachable Machine nebo » Machine Learning for Kids) je klasifikační úloha. Hledání pozic na šachovnici, kterých lze dosáhnout jedním tahem z dané výchozí pozice, je příkladem vyhledávací úlohy.	**VC** Rozdělit úlohy na klasifikační, predikční, kombinatorické nebo sekvenční rozhodovací. **TP** Predikční úlohy jsou podobné úlohám klasifikačním s tím rozdílem, že odhadují spojitou hodnotu, například výšku nebo denní teplotu. Úlohy sekvenčního rozhodování vybírají další tah pro libovolný stav tak, aby maximalizovaly celkovou odměnu. **Doplnění** Úlohy sekvenčního rozhodování jsou zahrnuty ve 3. velké myšlence — řeší se pomocí posilovaného (zpětnovazebního) učení. **Příklady** Spam nebo není spam (klasifikační úloha), zítřejší vysoká teplota (predikční úloha), řešení úloh, jako je například převoz vlka, kozy a zelí z jednoho břehu na druhý (kombinatorické úlohy), a hraní videoher, jako je Super Mario (sekvenční rozhodovací úloha).	**VC** Rozdělit problémy reálného světa na klasifikační, predikční, sekvenční rozhodovací, kombinatorické, heuristické, adversariálním, logické nebo statistické. TP Usuzovací úlohy lze rozdělit do kategorií na základě typů vstupů a výstupů, které mají být vytvořeny, a případných charakteristik prohledávaného prostoru. **Doplnění** Heuristické prohledávání je nutné, když je stavový prostor příliš velký na to, aby bylo možné prozkoumat všechny možné stavy. Používá „pravidlo palce“ (heuristika) k omezení prohledávání tím, že se zaměří na nejslibnější stavy. Při adversariálním vyhledávání, které se používá při hraní her, algoritmus střídavě hledá nejlepší tah pro hráče a zároveň nejlepší tah pro soupeře, který by byla z pohledu hráče nejmíň výhodný. Adversariální vyhledávání může vyžadovat heuristiku, pokud je hra složitá, například šachy nebo go. Při logické dedukci začíná usuzující s množinou faktů a odvozuje nová fakta pomocí pravidel odvozování. Logické odvozování lze provádět pomocí formální logiky, jako je výroková nebo predikátová logika, nebo ad hoc odvozovacích pravidel používaných u sémantických sítí nebo pravidel IF-THEN, která se vyskytují v expertních systémech. Statistické odvozování zahrnuje usuzování s pravděpodobnosti.
Usuzování (usuzovací algoritmy) 2-C-II	**VC** Navrhnout využití klasifikačního nebo vyhledávacího algoritmu k řešení problému. **TP** Usuzovací algoritmy jsou způsoby řešení logických úloh. **Doplnění** Žáci mohou vyřešit klasifikační úlohu pomocí tabulky znaků, kterou vytvořili v sekci 2-A-IV, nebo rozhodovacího stromu, který vytvořili v sekci 3-A-V. Případně úlohu vyhledávání s použitím mapy, kterou vyvinuli v sekci 2-A-I.	**VC** Popsat rozdíly mezi dvěma klasifikačními algoritmy — rozhodovacími stromy a neuronovými sítěmi (jako např. Teachable Machine). **TP** K řešení jedné argumentační úlohy lze použít více algoritmů. **Doplnění** Klasifikaci těstovin lze provést buď sestavením rozhodovacího stromu (viz aktivita s těstovinami), nebo trénováním vizuálního klasifikátoru, jako je Teachable Machine, na příkladových obrázcích jednotlivých typů těstovin.	**VC** Porovnat několik algoritmů, které by mohly být použity k řešení určitého typu argumentační úlohy. **TP** Výběr usuzovacího algoritmu závisí na vlastnostech vstupních dat a na typech rozhodnutí, která je třeba učinit. **Doplnění** Pro klasifikaci psů a koček, pokud máme k dispozici pouze nezpracované obrázky, nemůžeme použít rozhodovací strom, protože by vyžadoval obrovský počet uzlů. Musíme použít » neuronovou síť, protože dokáže efektivně provádět extrakci příznaků (v orig. feature extraction). Pokud však již máme k dispozici popis zvířete z hlediska znaků, jako je délka čenichu a tvar uší, pak lze rozhodovací strom použít. Obecně lze klasifikační problémy řešit pomocí rozhodovacích stromů, » metodou nejbližšího souseda nebo neuronových sítí. Predikční úlohy lze řešit pomocí lineární regrese nebo neuronových sítí. Kombinatorické vyhledávání může využívat několik různých algoritmů pro generování vyhledávacího stromu. Úlohy sekvenčního rozhodování mohou k výběru nejlepší akce používat buď Q tabulky, nebo neuronové sítě.	**VC** Pro každý z těchto typů usuzovacích úloh (klasifikační, predikční, sekvenční rozhodování, kombinatorické vyhledávání, heuristické vyhledávání, adverzní vyhledávání, logická dedukce a statistické odvozování) uvést algoritmus, který by mohl být použit k řešení daného problému. **TP** Umělá inteligence zahrnuje širokou škálu usuzovacích algoritmů pro řešení různých typů usuzovacích úloh. Některé využívají symbolickou reprezentaci (např. vyhledávací stromy), zatímco jiné jsou numerické povahy (např. neuronové sítě pracující s příznakovými vektory). **Doplnění** Problémy s usuzováním se probírají v kapitole 2-C-i. Výběr algoritmu závisí na vlastnostech vstupních dat a složitosti rozhodnutí, která je třeba učinit. Mezi heuristické vyhledávací algoritmy patří uspořádané prohledávání a vyhledávání A* algoritmus (A star). Adverzní vyhledávání lze provádět pomocí variant kombinatorického vyhledávání nebo heuristicky pomocí alfa-beta ořezávání (vylepšení algoritmu Minimax). Logické usuzování lze provádět pomocí dokazování rezolučních tvrzení nebo použitím ad hoc pravidel IF-THEN. Statistické odvozování zahrnuje usuzování s pravděpodobnostmi nebo rozděleními, například Bayesovské sítě.

VC (vzdělávací cíl) — co by žáci/studenti měli umět. **TP** (trvalé porozumění) — co by žáci/studenti měli znát.

3. Velká myšlenka — Učení

Klíčové poznatky	Vysvětlení
Počítače se mohou učit z dat.	
Díky strojovému učení se počítače na základě mnoha příkladů a zkušeností učí, jak samostatně řešit různé úkoly.	definice pojmu „strojové učení“
Učení nových vzorců chování je výsledkem změn, které učící se algoritmus provádí ve vnitřní reprezentaci modelu strojového učení, jako je rozhodovací strom nebo neuronová síť.	jak fungují algoritmy strojového učení
Čím rozmanitější chování model strojového učení vykazuje, tím větší a komplexnější musí být sada trénovacích dat.	úloha tréninkových dat
Model natrénovaný pomocí strojového učení se dá použít na nová data k řešení úloh nebo rozhodování.	fáze učení vs. fáze aplikace

Úroveň ↦	1. stupeň základní školy		2. stupeň základní školy	Střední škola
Ročník ↦	2. ročník	3.—5. ročník	6.—9. ročník	
Koncept ↧				
Podstata učení (Lidé vs. stroje) 3-A-I	**VC** Popsat a uvést příklady toho, jak se učí lidé a jak se učí počítače. **TP** Počítače se učí jinak než lidé. **Doplnění** Lidé se učí tím, že propojují své znalosti a zkušenosti s pozorováním, vyprávěním, kladením otázek a experimentováním. Počítače se učí hledáním vzorů v datech nebo metodou pokus/omyl. **Můžete vyzkoušet** Popište, co jste se dozvěděli z vyprávění, pozorováním jiné osoby nebo kladením otázek. K ilustraci toho, že se počítač něco naučil, lze použít ukázku — například modelu natrénovaného k rozpoznávání dvou různých tříd v nástroji Teachable Machine.	**VC** Rozlišit, jak se učí lidé a jak se učí počítače. **TP** Lidé i počítače se mohou učit hledáním vzorů v datech nebo metodou pokus/omyl. Lidé se však učí flexibilně, dokáží se přizpůsobit neznámým situacím a učit se jinými způsoby, například pozorováním ostatních, kladením otázek nebo navazováním na předchozí znalosti. **Doplnění** Lidé se učí přirozeně, zatímco počítače musí být k učení naprogramovány. V současné době existují dva způsoby, jak lze počítače naprogramovat k učení: mohou se učit hledáním vzorů v příkladech připravených člověkem, nebo se mohou učit metodou pokus/omyl.	**VC** Porovnat jedinečné vlastnosti lidského učení se způsoby, jakými fungují systémy strojového učení. **TP** Lidé se učí tím, že propojují své znalosti a zkušenosti s pozorováním, vyprávěním, kladením otázek a experimentováním. Počítače se učí aplikací specializovaných algoritmů na velké množství trénovacích dat nebo tisíci či dokonce miliony zkušeností (pokus/omyl) při řešení úzce vymezených úloh. **Doplnění** Lidé se učí flexibilně a používají více strategií. Počítače používají specializované algoritmy, které vyžadují velké množství dat nebo mnoho zkušeností a řeší pouze úzce vymezené problémy. Lidé sice mohou sami vytvářet programy (algoritmicky), ale u složitých úloh je často výhodnější nechat práci na algoritmu strojového učení.	**VC** Definovat algoritmy strojového učení s učitelem, bez učitele a posilované učení a uvést příklady lidského učení, které jsou podobné jednotlivým algoritmům. **TP** Algoritmy strojového učení, ať už s učitelem nebo bez učitele, hledají vzory v datech. Učení s učitelem využívá anotovaná data k předpovídání tříd (kategorií); na druhou stranu, učení bez učitele seskupuje podobné vzory a tvoří své vlastní shluky (klastry). Posilované učení se opírá o metodu pokus/omyl, díky níž se učí, jaké strategie přinášejí nejvyšší zisk. **Doplnění** Učení s učitelem se podobá situaci, kdy vás učitel vede tím, že opravuje vaše chyby. Učení bez učitele je jako když analyzujete data a zjistíte, že máte tři typy zákazníků podle toho, jak nakupují. Posilované učení připomíná hraní videoher, kde zkoušíte různé strategie a zjišťujete, které vám přinesou nejvíce bodů.
Podstata učení (hledání vzorů v datech) 3-A-II	**VC** Identifikovat vzory v anotovaných datech, které určují, jak jsou klasifikována. **TP** Třídy (kategorie) v datech mohou být definovány na základě hodnot určitých příznaků (vlastností). Příslušné příznaky lze odvodit zkoumáním anotovaných příkladů. **Doplnění** Žákům můžeme jednoduše vysvětlit pomocí hry, jak se anotují data při strojovém učení s učitelem. Ukažte jim například obrázky ryb a požádejte je, aby popsali, které znaky naznačují, že je ryba jedovatá (např. červená ryba s hranatou hlavou). Pro začátek je vhodné využít obrázky, protože je jejich anotace intuitivnější (i když třeba klasifikační pravidlo být nemusí). **Můžete vyzkoušet** online hru » AI for Oceans.	**VC** Vysvětlit, jak algoritmus učení s učitelem identifikuje vzory v anotovaných datech. **TP** Při trénování mohou být vzory (nebo pravidla), která najdeme v anotovaných datech, reprezentována jako váhy v neuronové síti nebo jako uzly v rozhodovacím stromu. **Doplnění** Žáci mohou navázat na hru s jedovatými rybami. Tato verze ji rozšiřuje tak, že žáci namísto pouhého slovního vyjádření navrhovaného pravidla, nakreslí rozhodovací strom. Úlohu lze navíc prohloubit zvýšením počtu tříd nebo jejich složitějšími definicemi. Například ryba může být jedovatá, pokud je buď červená s hranatou hlavou, nebo modrá s kulatou hlavou, nebo fialová se špičatými ostny a jakýmkoli tvarem hlavy. Každý uzel rozhodovacího stromu může testovat jednu hodnotu příznaku, např. barvu, takže složitější příznaky vyžadují hlubší stromy.	**VC** Vysvětlit, jak učení bez učitele nachází vzory v datech, která nejsou anotována. **TP** Učení bez učitele se hodí v situacích, kdy nevíme, jaké třídy (kategorie) v datech můžeme očekávat. Tento typ algoritmu vyhledává vzory (nebo třídy) v datech tím, že seskupuje podobné body dohromady. Jakmile jsou tyto shluky (klastry) identifikovány, můžeme nové body zařadit do těchto tříd podle toho, jak jsou blízko k jejich hranicím. **Doplnění** To lze provést graficky pomocí bodů v rovině a vizuální konstrukcí hranic shluků obkreslením (např. nakreslením elipsy kolem každého shluku.	**VC** Vysvětlit, jak model strojového učení, který slouží ke klasifikaci nebo predikci, upravuje své parametry (své vnitřní reprezentace), aby lépe odpovídal pozorovaným datům. **TP** Učení s učitelem upravuje parametry matematického modelu (předem vybraného člověkem) tak, aby se vytvořily správné klasifikace nebo predikce. Tímto modelem může být jednoduchá lineární rovnice, polynom vysokého stupně nebo ještě složitější nelineární rovnice, například hluboká neuronová síť. Vnitřní reprezentace, které kódují vztah mezi vstupy a výstupy, vyjadřují vzory nalezené v datech. **Doplnění** V lineární regresi si zvolíme matematický model, jako je lineární rovnice $y=mx+b$, a upravujeme její parametry, aby se co nejlépe hodily k našim datům. Pak můžeme tento model použít k odhadnutí hodnoty y pro jakoukoli hodnotu x. Lineární regresi můžeme provádět i vizuálně, například odhadem, jak přímka odpovídá bodům na grafu. Studenti mohou zkoušet polynomickou nebo logistickou regresi s grafickým zobrazením a posuvníky pro úpravu parametrů, a hledat nejlepší shodu s daty. Pokročilejší studenti se mohou naučit, jak kvalitu shody s daty matematicky hodnotit pomocí střední kvadratické chyby. Při klasifikaci bude hodnota Y 1 („ve třídě“) nebo 0 („mimo třídu“) a rozhodovací hranice je daná, když $y=0{,}5$.
Podstata učení (trénování modelu) 3-A-III	**VC** Popsat, jak naučit počítač něco rozpoznat. **TP** Počítače se mohou učit z příkladů. **Doplnění** S pomocí učitele/ky mohou žáci v nástroji Teachable Machine vyzkoušet rozpoznávání gest rukou nebo zvuků.	**VC** Natrénovat model strojového učení a poté prověřit jeho přesnost na nových vstupech. **TP** Počítače se mohou naučit klasifikovat příklady nebo předpovídat hodnoty, pokud jsou jim ukázána anotovaná data. Jsou-li výsledky na nových vstupech neuspokojivé, je možné upravit dataset a model přetrénovat. **Můžete vyzkoušet** Využijte pro trénování modelu aplikace » Teachable Machine nebo » Machine Learning for Kids. Trénovací data mohou být získána pomocí webové kamery nebo stažena z webu. Model může rozpoznávat například kočky a psi.	**VC** Natrénovat pomocí strojového učení a vyhodnotit fungování klasifikátoru nebo prediktoru na souboru tabulkových dat. **TP** Počítače se mohou naučit klasifikovat příklady nebo předpovídat hodnoty, pokud jsou jim ukázána anotovaná data. Jsou-li výsledky na nových vstupech neuspokojivé, je možné upravit trénovací sady a model přetrénovat. **Doplnění** V tabulkovém souboru s daty představuje každý řádek jeden trénovací příklad, a každý z těchto příkladů je charakterizován sadou příznaků, které jsou zastoupeny sloupci tabulky. Při klasifikaci je každý příklad zařazen do jedné z určitých tříd (například „kočka“ nebo „pes“). Naproti tomu, predikce spočívá v odhadu hodnoty, jako je například výška osoby na základě jejího věku. Pro tento typ úlohy je vhodnější použít rozhodovací strom než neuronovou síť. **Můžete vyzkoušet** V aplikaci » Machine Learning for Kids lze trénovat pomocí rozhodovacích stromů. Algoritmus strojového učení zjistí, které jsou příznaky jsou relevantní a jaké hodnoty by měly mít pro každou třídu.	**VC** Využít algoritmus strojového učení s učitelem nebo bez učitele k natrénování modelu na reálných datech a poté vyhodnotit výsledky. **TP** Při učení s učitelem je model strojového učení trénován na sadě dat (datasetu), která má přiřazené třídy (kategorie), tak aby dokázal správně určovat nové příklady. Úspěšnost modelu měříme pomocí pravděpodobnosti v procentech. Naopak při učení bez učitele je model naučen seskupovat data do shluků podle podobnosti, aniž by byla data předem označena (anotována). Výsledky posuzujeme zkoumáním, zda tyto shluky odhalují užitečné informace v datech. **Doplnění** Algoritmy strojového učení s učitelem i bez učitele nacházejí v datech vzory (podobnosti). V případě učení s učitelem je „vzor“ vztahem mezi hodnotami určitých příznaků a třídami. Při učení bez učitele je vzorem způsob, jakým jsou data seskupena do shluků. Soubory reálných dat jsou dostupné na webu (např. » Kaggle). V předchozích ročnících mohli žáci testovat své natrénované modely na několika nových příkladech, ale v tomto ročníku jsou studenti požádáni, aby kvantifikovali výkonnost natrénovaného modelu na složitějším testovacím souboru (tzn. představuje určitou míru výzvy nebo komplexity).
Podstata učení (vytváření vs. použití modelu strojového učení) 3-A-IV	Neuplatňuje se.	**VC** Ukázat, jakým způsobem se v nástroji strojového učení anotují trénovací data. **TP** V rámci přípravy na trénování modelu lze trénovací data anotovat tak, že se nejprve definují třídy (kategorie) a poté se přidají příklady pro každou třídu zvlášť. Po natrénování lze modelu předložit nová (testovací) data, pro které model v procentech predikuje třídu. Tato testovací data ale nejsou anotovaná, takže model nedostává žádnou zpětnou vazbu o správnosti svých předpovědí. **Doplnění** Nástroj Techable Machine nabízí ve svém rozhraní také možnost přidání příkladů do tříd pomocí tlačítka „Hold to Record“. Tyto příklady se nasnímají pomocí webkamery. Po natrénování modelu ho lze také otestovat v reálném čase pomocí webové kamery. Model ale nedostává žádnou zpětnou vazbu o správnosti svých předpovědí.	**VC** Vysvětlit rozdíl mezi vytvářením a používáním modelu strojového učení. **TP** Algoritmy strojového učení využívají anotovaná data k trénování modelů strojového učení. Tyto modely se pak naučí klasifikovat nebo předpovídat. V průběhu trénování se model učí z těchto dat, přičemž učící algoritmus upravuje jeho nastavení, aby lépe odpovídalo anotovaným datům. Po dokončení tréninku se model může použít na nové příklady pro řešení úloh nebo rozhodování. Jakmile je model natrénován, bez dalšího trénování se již nemění.	**VC** Ukázat, co se děje v jednotlivých krocích strojového učení při konstrukci klasifikátoru nebo prediktoru. **TP** Kroky jsou následující: rozhodnutí, jaký problém chceme řešit, určení, kde získáme trénovací data, výběr množiny příznaků, určení způsobu anotace dat, spuštění učícího algoritmu, použití křížové validační množiny dat pro rozhodnutí, kdy by se mělo trénování ukončit, a použití testovací množiny dat pro měření výkonnosti. **Doplnění** Křížová validační množina dat se používá k zamezení přeučení. Testovací množina se skládá z příkladů, které nebyly použity při trénování ani pro křížovou validaci, takže poskytuje nezkreslenou předpověď výkonu modelu na nových vstupech.
Podstata učení (úprava vnitřních reprezentací) 3-A-V	Neuplatňuje se.	**VC** Analyzovat hru, ve které je konstruován rozhodovací strom, popsat uspořádání stromu a učící algoritmus používaný k přidávání uzlů. **TP** V rozhodovacím stromu jsou uzly stromu otázkami a terminální uzly (listy) třídami. Učící algoritmus postupuje stromem tak, že klade otázky v uzlech (testuje vlastnosti vstupu), dokud nedojde k teminálnímu uzlu. Pokud je třída tohoto terminálního uzlu nesprávná, je nahrazen uzlem s novou otázkou a terminální uzel s třídou je znovu napojen na konec. **Můžete vyzkoušet** Hra „Uhodni zvíře“ je vhodnou volbou pro demonstraci učení rozhodovacího stromu.	**VC** Porovnat fungování učícího algoritmu rozhodovacího stromu a neuronové sítě. **TP** V rozhodovacím stromu se v každém kroku přidává nový uzel, který testuje jednu hodnotu určitého příznaku. Při učení neuronových sítí se v každém kroku provede malá změna vah v síti. **Doplnění** Vnitřní reprezentací rozhodovacího stromu jsou uzly, příznak, kterou každý uzel zkoumá, a hodnota, s níž je příznak porovnáván. Vnitřní reprezentace neuronové sítě jsou váhy. Učící algortimy rozhodovacího stromu se snaží pro každý nově vytvořený uzel najít nejvíce vypovídající příznaků, které je třeba zkoumat. Změna trénovacích dat může vést k jiné volbě příznaku, který se má zkoumat dále. U neuronové sítě povede změna trénovacích dat k dalším úpravám vah, protože algoritmus se snaží snížit chybu (bias).	**VC** Popsat, jak se různé typy algoritmů strojového učení učí úpravou svých vnitřních reprezentací. **TP** Učící se rozhodovací stromy vytvářejí rozhodovací stromy postupným přidáváním uzlů. Učící algoritmy neuronových sítí upravují váhy. Regresní algoritmy upravují parametry rovnic. Během posilovaného učení se aktualizují předpovědi hodnot nebo politiky.
Podstata učení (učení se ze zkušenosti) 3-A-VI	Neuplatňuje se.	**VC** Vysvětlit, jak posilované (zpětnovazební) učení umožňuje počítači učit se na základě zkušeností (tj. metodou pokus/omyl). **TP** Počítače se mohou učit na základě zkušeností, pokud mají zpětnou vazbu, zda jejich strategie vede k dobrým nebo špatným výsledkům. **Doplnění** Počítače se mohou naučit hrát hry pomocí zpětné vazby, která říká, zda počítač vyhrál nebo prohrál hru (nebo kolik bodů získal). Počítač musí odehrát stovky tisíc her, aby se stal zkušeným hráčem. **Ukázka** Zahrajte si hru. Úkolem je naučit se nejlepší cestu k cíli. V každém čtverci mřížky jsou přípustné akce pohyb S/J/V/Z. V průběhu opakovaných pokusů se agent naučí nejlepší pohyb v každém čtverci.	**VC** Vysvětlit rozdíly mezi učením s učitelem a posilovaným učením. **TP** Učení s učitelem říká systému, jaký výstup by měl produkovat pro každý vstup; posilované učení pouze pomocí politik vyhodnocuje kroky agenta. **Doplnění** Při učení s učitelem je předem udáván správný výstup pro každý trénovací příklad, aby učící se algoritmus ho mohl porovnat se svým výstupem. Při posilovaném učení zpětná vazba ukazuje, jak dobře si agent vede, ale neříká mu, jak by měl zlepšit svou strategii. To je třeba zjistit metodou pokus/omyl, takže k dosažení výkonnosti na úrovni experta může být zapotřebí statisíců pokusů. Například při hraní videohry může být zpětnou vazbou počet získaných bodů. Protože se počítač učí na základě vlastních zkušeností, může pomocí posilovaného učení nalézt řešení problému sám, pouze na základě nastavených politik.	**VC** Zvolit vhodný typ algoritmu strojového učení (s učitelem, bez učitele nebo posilované učení) pro řešení argumentačního problému. **TP** Hlavní typy učících se algoritmů a druhy úloh, které se s jejich pomocí řeší, jsou: učení s učitelem, které se používá pro klasifikaci a predikci, učení bez učitele, které se používá pro shlukování, a posilované učení, které se používá pro sekvenční rozhodování. **Doplnění** Algoritmy učení s učitelem i bez nacházejí v datech vzory. Algoritmy učení s učitelem používají anotovaná trénovací data a upravují parametry modelu strojového učení tak, aby správně klasifikoval nové příklady. Používají se pro klasifikační nebo predikční úlohy. Algoritmy strojového učení bez učitele, které nepoužívají anotovaná data, se snaží shlukovat podobné datové body. Používají se ke hledání tříd. Algoritmy posilovaného učení se používají pro úlohy sekvenčního rozhodování. Agenti vyvíjí své strategie na základě zpětné vazby, kterou určují nastavené politiky. Posilované učení může být pomalé, protože musí probíhat metodou pokus/omyl; algoritmus nemá žádného učitele, který by mu v každém kroku říkal, jaká akce je nejlepší. To, že se počítač učí na základě vlastních zkušeností, má však tu výhodu, že může objevit neobvyklá řešení.
Neuronové sítě (struktura neuronové sítě) 3-B-I	Neuplatňuje se.	**VC** Znázornit, jak neuronová síť složená z jednoho až tří neuronů jako funkci, která počítá výstup. **TP** Neuronová síť využívá jeden nebo více neuronů, které společně vytvářejí určitou funkci. Každý neuron přijímá jako vstup sadu čísel a jako výstup vytváří jedno číslo. **Doplnění** Neuronová síť je soubor vzájemně propojených neuronů. Každý neuron má sadu vstupů, z nichž každý má přiřazenou váhu, jež nese určitou hodnotu. Neuron vynásobí každou vstupní hodnotu váhou a získá vážený vstup. Součet všech vážených vstupů se porovná s prahovou hodnotou neuronu. Pokud je součet vyšší než prahová hodnota, neuron vydá hodnotu 1; v opačném případě vydá hodnotu 0. Tomu se říká aktivační funkce. Výstupní hodnotu lze použít jako vstup pro další neurony. **Můžete vyzkoušet** Vypočítejte výstup jednoho neuronu s více vstupy nebo síť dvou „skrytých“ neuronů s více vstupy, které napájejí jeden výstupní neuron. Takové sítě mohou počítat jednoduché funkce, například „AND“, „OR“ nebo „alespoň 2 ze 3“. Stručnou překlad metodiky na neuronové sítě pro 1. stupeň ZŠ najdete na v tomto » Google dokumentu.	**VC** Znázornit strukturu neuronové sítě a popsat, jak její části tvoří soubor funkcí, které počítají výstup. **TP** Neuronové sítě jsou organizovány jako vrstvy jednotek (vstupní, skrytá a výstupní vrstva) s váženými spojeními mezi jednotkami v po sobě jdoucích vrstvách. Každá jednotka počítá součet svých vážených vstupů. Tento součet prochází aktivační funkcí a vytváří číselný výstup. **Doplnění** Neuronová síť komplexně mapuje vstupní vzory na výstupní. Každý neuron počítá určitou funkci a síť jako celek počítá složitou funkci, kterou lze považovat za nepřímou (v orig. wiggly) matematickou funkci (pozn: reprezentace neuronové sítě pro nás není v matematice intuitivní jako např. přímka nebo parabola).	**VC** Popsat následující architektury neuronových sítí a jejich použití: dopředná neuronová síť, 2D konvoluční síť, rekurentní síť, generativní adversariální síť (GAN). **TP** Dopředné sítě se mohou učit libovolné funkce a používají se jak pro klasifikaci, tak pro regresi. Ve 2D konvoluční síti se učí malá „jádra“ (kernels), které jsou konvolvovány (propojovány) se vstupem, a vrstvy pro max-pooling (Obraz se rozdělí na oblasti — nejčastěji obdélníkové nebo čtvercové — a v každé oblasti se vybere maximální hodnota. Tím se výrazně snižuje množství dat — místo celé oblasti je reprezentována pouze jednou hodnotou, která je maximální). Tyto sítě jsou často používány pro analýzu obrazu, protože umožňují identifikovat a učit se z vlastností v různých částech obrázku. Rekurentní sítě mají zpětnovazební spojení. Tyto sítě se vyznačují tím, že část informací z předchozích kroků zpracování mohou být použity v krocích následujících. Používají se pro zpracování jazyka. Generativní adversariální sítě (GAN) mají generátor a diskriminátor a používají se například k vytváření deepfakes. Generátor se snaží vytvořit data, která vypadají jako reálná, zatímco diskriminátor se snaží rozlišit, co je věrohodné a co je vygenerováno.
Neuronové sítě (úprava vah) 3-B-II	Neuplatňuje se.	**VC** Ukázat, jak se v neuronové síti upravují váhy, aby se dosáhlo požadované hodnoty vstupů a výstupů. **TP** Výstupy neuronové sítě lze měnit úpravou jejích vah.	**VC** Ukázat, jak lze použít pravidlo učení k úpravě vah v jednovrstvé neuronové síti. **TP** Během trénování se váhy upravují v reakci na chyby (bias) na výstupu sítě, aby se při dalším zobrazení vstupu chyba stala méně pravděpodobnou. **Doplnění** Trénování lze provádět pomocí binárních jednotek a jednoduchého pravidla učení pro úpravu vah (jako je pravidlo učení perceptronu v cvičení „Kousne mě ten pes?“). Během trénování síť přijímá vstupní data (například různé podobnosti psů) a na základě svých aktuálních vah vytvoří výstup (například předpověď, zda pes kousne). Pokud je výstup správný, váhy zůstávají nezměněny. Pokud je výstup nesprávný, váhy se upraví.	**VC** Natrénovat vícevrstvou neuronovou síť pomocí algoritmu zpětného šíření (backpropagation) a popsat, jak se v důsledku učení mění váhy neuronů a výstupy latentních jednotek. **TP** Váhy neuronu začínají jako malé náhodné hodnoty a učením se vyvíjejí k přesnějšímu vzoru. Změny vah neuronu se vypočítávají pomocí pravidla zpětného šíření. Vzor vah neuronu určuje vlastnosti, které neuron detekuje. **Doplnění** Od žáků se neočekává, že budou znát podrobnosti algoritmu zpětného šíření, pouze to, že chyba se šíří zpětně z pozdějších vrstev do dřívějších. **Můžete vyzkoušet** K vizualizaci změn vah během učení lze použít online demo » TensorFlow Playground.
Datové sady (sady příznaků) 3-C-I	**VC** Vytvořit dataset s explicitními příznaky, aby bylo možné ilustrovat, jak se počítače mohou naučit klasifikovat věci, jako jsou potraviny, filmy nebo hračky. **TP** Můžeme přimět počítač, aby klasifikoval věci tím, že je popíšeme pomocí hodnot určitých příznaků, které může počítač využít. Lidé jsou ti, kdo vybírají příznaky. **Doplnění** Roztřiďte potraviny na zdravé a nezdravé nebo hračky na bezpečné či nebezpečné pro děti. Nebo vytvořte rozhodovací strom na základě těchto příznaků (vlastností). Nicméně je třeba klást důraz na uvědomění, že tuto práci za nás mohou vykonávat počítače.	**VC** Vytvořit anotovaný dataset s explicitními příznaky několika typů a použít nástroj strojového učení k natrénování klasifikátoru. **TP** Mezi typy prvků patří diskrétní hodnoty (např. „New York“, „Pennsylvania“, „Iowa“), binární hodnoty (ano/ne) a spojité hodnoty (věk, výška). **Doplnění** Aplikace, jako je Machine Learning for Kids, trénují klasifikátory rozhodovacích stromů na základě dat tohoto typu (» článek na toto téma na blogu Dalea Lanea).	**VC** Vytvořit dataset pro trénování rozhodovacího stromu klasifikátoru nebo prediktoru a prozkoumat, jaký vliv mají na rozhodovací strom různá přiřazení příznaků k třídám (kategoriím). **TP** Výběr příznaků, které je třeba zahrnout, a jejich nejvhodnější přiřazení příznaků k třídám, závisí na konkrétním problému, který se snažíme vyřešit. **Doplnění** V každém uzlu rozhodovacího stromu se učící algoritmus pokusí vybrat příznak, který bude nejvíce užitečný při rozdělování zbývajících příkladů do tříd. Příznaky, které významně nekorelují s žádnou třídou, nebudou vybrány. **Můžete vyzkoušet** Machine Learning for Kids nakreslí rozhodovací strom, aby si ho žáci mohli prohlédnout a zjistit, na kterou funkci se odkazuje v každém uzlu (viz předchozí odkaz na blog Dalea Lanea).	**VC** Porovnat dva datové soubory z reálného světa z hlediska příznaků, které obsahují, a způsobu, jakým jsou tyto příznaky přiřazeny k třídám. **TP** Lidé rozhodují, které příznaky zařadit do datového souboru a jak. To může mít důsledky pro algoritmy strojového učení, které jsou na těchto datech trénovány. **Doplnění** Věk může být v granularitě měsíců (datové soubory pediatrů), let (pro dospělé) nebo jako věkové rozmezí (kojenec, dítě, teenager, dospělý, staří a velmi staří lidé). Přiřazení spojité proměnné pomocí diskrétních hodnot může vést učící algoritmus k rozlišování, které odpovídá lidskému pochopení dané oblasti. Příklad: Věk je spojitá proměnná, ale v některých kontextech může být užitečnější přiřadit ji do tříd jako „dítě“, „dospělý“, „senior“ atd. Taková klasifikace může pomoci učícímu algoritmu lépe identifikovat vzory nebo charakteristiky, které jsou relevantní pro danou věkovou skupinu.
Datové sady (velké datové soubory) 3-C-II	Neuplatňuje se.	**VC** Ukázat, jak trénování klasifikátoru pro tak obecný pojem, jako je „pes“, vyžaduje velké množství dat, aby bylo možné pojmout oborovou rozmanitost. **TP** Strojové učení vyžaduje velké množství dat, aby bylo efektivní. K rozpoznání psů na snímcích je třeba mítk dispozici nejen mnoho různých ras psů, ale také mnoho různých úhlů pohledu a kontextů. **Doplnění** Jedním ze způsobů, jak studentům pomoci představit si potřebnou rozmanitost, je projít některé standardní datasety používané pro rozpoznávání objektů, jako je » Coco nebo » ImageNet.	**VC** Ukázat, jak lze segmentovat a anotovat objekty na obrázku a vytvořit tak dataset pro rozpoznávání objektů. **EU** Strojové učení vyžaduje velké množství dat, aby bylo efektivní. K anotaci dat je obvykle zapotřebí lidských znalostí, což může být náročné na pracovní sílu. **Doplnění** Žáci mohou dostat sadu obrázků a mít za úkol nakreslit ohraničující rámeček kolem každé osoby, psa nebo dopravní značky na obrázku a objekt vhodně označit. V návaznosti na to mohou být požádáni, aby odhadli čas, který by byl potřebný k sestavení označené sady dat s několika tisíci příklady.	**VC** Vyhodnotit dataset použitý k trénování reálného systému umělé inteligence s ohledem na velikost datové sady, způsob, jakým byla data získána a anotována, úložiště a odhadovaný čas potřebný k vytvoření datasetu. **TP** Pro zachycení rozmanitosti oboru a zúžení rozsahu možného chování modelu je obvykle zapotřebí rozsáhlý soubor dat. Existuje více způsobů, jak datovou sadu sestavit, vyčistit a zkontrolovat. S vytvořením datové sady a zpracováním dat mohou být spojeny velké náklady. Anotování trénovacích dat je pracné a může vyžadovat specializované odborné znalosti (např. rozpoznávání anomálií na rentgenových snímcích.) V každém kroku vytváření datové sady může dojít k předpojatosti. **Doplnění** Soubory dat pro problémy reálného světa často obsahují mnoho různých příznaků. Tyto příznaky mohou být vzájemně propojeny složitými vztahy, které definují charakteristiku dané třídy. Aby bylo možné přesně určit, kterou třídu je potřeba naučit a odlišit ji od milionů dalších možných tříd, je nutné, aby algoritmus pro učení měl k dispozici mnoho příkladů. **Můžete vyzkoušet** Aktivitu lze provádět se soubory dat, které lze nalézt v úložištích, jako je » Kaggle, nebo s veřejně dostupnými demografickými, ekonomickými nebo environmentálními údaji.
Datové sady (předpojatost) 3-C-III	**VC** Prozkoumat soubor anotovaných dat a identifikovat problémy v datech, které by mohly vést počítač k nesprávným předpovědím. **TP** To, jak dobře se počítač naučí klasifikovat, závisí na datech použitých k jeho trénování. **Doplnění** Pokud jsou příklady zdravých potravin: brokolice, zelené fazolky, hrášek a špenát (všechny zelené) a nezdravých potravin: koblihy, koláče a sladké tyčinky — co počítač usoudí o gumových medvídcích?	**VC** Prozkoumat příznaky a třídy trénovacích dat a odhalit potenciální zdroje předpojatosti (zkreslení, bias). **TP** Algoritmy strojového učení vyžadují reprezentativní soubor dat, aby bylo možné vytvořit přesný model. Trénovací datové sady získané z historických dat mohou odrážet předsudky (lidské i společenské). **Doplnění** Program na třídění životopisů společnosti Amazon byl na trénován na historicky podjatých datech a upřednostňoval na některé pozice muže.	**VC** Vysvětlit, jak výběr trénovacích dat ovlivňuje chování klasifikátoru a jak může dojít ke zkreslení, pokud není trénovací sada správně vyvážena. **TP** Pokud je model požádán, aby klasifikoval vstupy, které se nepodobají trénovacím datům, nebo pokud trénovací data obsahují irelevantní korelace, na které nechceme, aby se klasifikátor spoléhal, může dojít ke zkreslení. **Doplnění** Klasifikátor vycvičený pouze na tvářích lidí s bílou pletí bude špatně fungovat na tvářích lidí s tmavou pletí nebo Asiatů. Klasifikátor vycvičený na souboru dat žádostí o půjčku, kde většina odmítnutých žadatelů žila v Chomutově, se může rozhodnout, že neposkytne půjčku nikomu, kdo uvede místo bydliště Chomutov.	**VC** Prozkoumat pomocí nástroje pro vizualizaci dat nerovnováhu v trénovacích datech z hlediska pohlaví, věku, etnického původu nebo jiných demografických proměnných, která by mohla vést k neobjektivnímu modelu. **TP** Algoritmy strojového učení využívají nerovnováhy nebo korelace v trénovacích datech, které pomáhají snižovat chybovost. Pokud však soubor dat není dostatečně reprezentativní, mohou být tyto korelace zavádějící. **Doplnění** Zkoumání dat, které studentům pomůže odhalit nerovnováhu nebo korelace, lze provést pomocí histogramů v aplikaci Excel nebo pomocí libovolného nástroje pro vizualizaci dat, jako je například » Pandas (pro Python).

VC (vzdělávací cíl) — co by žáci/studenti měli umět. **TP** (trvalé porozumění) — co by žáci/studenti měli znát.

4. Velká myšlenka — Přirozená interakce

Klíčové poznatky	Vysvětlení
Aby mohly inteligentní systémy komunikovat s lidmi přirozeným způsobem, je nutné, aby obsahovaly rozmanité typy znalostí.	
Počítače jsou schopné komunikovat faktické informace v přirozeném jazyce, ale často se potýkají s těžkostmi při pochopení nepřímých forem vyjadřování, jako jsou metafory, symbolika, humor nebo sarkasmus.	Jazyk je klíčovou složkou naší lidskosti. Metafory, obrazy a humor jsou integrální součástí lidské kultury, avšak stále nám chybí přesné a detailní vysvětlení, jak je lidé vnímají a jak by se s nimi měly počítače vypořádat.
Počítače mohou rozpoznávat emoce, ale nemohou je samy prožívat. Vhodné reakce na emoce musí být naprogramovány člověkem.	Systémy umělé inteligence sice dokáží rozpoznávat lidské emoce prostřednictvím algoritmů, ale chybí jim schopnost skutečného soucitu, i když mohou empaticky reagovat.
Současné systémy umělé inteligence jsou specificky zaměřené na řešení jasně vymezených problémů. Flexibilní, lidskému myšlení podobné uvažování, které se nazývá „obecná umělá inteligence“ (AGI — Artificial General Inteligence) zatím nebylo dosaženo.	Není jasné, kdy bude lidstvo schopno vytvořit systémy obecné umělé inteligence, které by mohly napodobit nebo překonat lidské schopnosti usuzování.
Současné systémy umělé inteligence nemají vědomí ani si neuvědomují sami sebe. Počítač se schopností sebeuvědomění by musel být vědom vlastní existence, svých myšlenek a vzpomínky na dřívější zkušenosti.	Vědomí znamená pochopení vlastní existence, tedy uvědomění si svého těla a okolí. Sebeuvědomění pak představuje poznání, že člověk je vědomou, myslící bytostí, která má schopnost uvažovat o svých vlastních myšlenkách. Stručné pojednání na toto téma viz článek » Does Self-Awareness Require a Complex Brain? (2012).

Úroveň ↦	1. stupeň základní školy		2. stupeň základní školy	Střední škola
Ročník ↦	2. ročník	3.—5. ročník	6.—9. ročník	
Koncept ↧				
Přirozený jazyk (struktura jazyka) 4-A-I	**VC** Prokázat znalost struktury jazyka prostřednictvím úkolů, jako je vytváření věrohodných a nevěrohodných nových slov nebo změna pořadí slov ve zkomolené větě tak, aby dávala smysl. **TP** Lidské jazyky se řídí pravidly pro tvorbu slov a vět, a počítače mohou tato pravidla využívat k pochopení toho, co lidé říkají. **Doplnění** Slovo „mantl“ je v češtině málo užívané, narozdíl od jeho ekvivalentu „kabát“, proto je jeho užití ve větě nepravděpodobné. Věta „Jedl palačinky Josef.“ nedává smysl, protože má špatné pořadí slov. Věta dává smysl v následujícím pořadí „Josef jedl palačinky.“. **Můžete vyzkoušet** Pomocí hlasového asistenta nebo nástroje pro přepis mluveného slova (např. funkce v Google dokumentech) zkuste zadat na porovnání dvě věty, jednu s málo využívaným českým slovem „mantl“ a druhou s jeho často využívaným ekvivalentem „kabát“: „Oblékl si mantl.“ vs. častější varianta „Oblékl si kabát.“	**VC** Lidský jazyk je neomezený, což lze prokázat ukázkou, jak lze libovolnou větu neustále rozšiřovat. **TP** Lidský jazyk dokáže vyjádřit nekonečné množství myšlenek a vytvořit nekonečné množství vět. Tato vlastnost znemožňuje předem naprogramovat počítač s odpovědí na každou větu. Aby tedy počítač porozuměl nové větě, musí rozpoznat, jak se slova spojují do frází a klauzulí, aby sdělovala složité myšlenky. **Doplnění** Věty lze prodlužovat přidáváním nových frází nebo klauzulí bez omezení. Opakovaným prodlužováním věty získáte něco jako: „Honzík řekl, že Maruška věděla, že Péťa viděl, že Líza dala Markétce knihu o křečcích z vesmíru, kterou jí doporučil Pepík.“ **Můžete vyzkoušet** Žáci se střídají a snaží se prodloužit (a zapamatovat) větu v angličtině. Poté ji můžete vložit do » Berkeley neuronového parseru (stránky běží na nezabezpečeném protokolu http://, nemusí tedy fungovat) a zkontrolujte, zda dokáže správně rozpoznat strukturu věty.	**VC** Prokázat počítačovou znalost gramatiky pomocí programu Berkley neural parser, který zobrazí syntaktickou strukturu věty, a vysvětlit, co jednotlivé uzly představují. **TP** Syntaktické stromy (grafické reprezentace struktury vět) reprezentují syntaktickou strukturu věty a ukazují vztahy mezi slovy. Počítače mohou syntaktické stromy používat k analýze i generování vět. **Doplnění** Gramatická struktura věty je klíčem k pochopení jejího významu. Pokud chceme například odpovědět na otázku, musíme nejprve pochopit její význam. Když chceme, aby robot něco vykonal, musí nejprve „porozumět“, co se po něm žádá. Parsery vytvářejí syntaktické stromy, jejichž neterminálními uzly jsou gramatické kategorie, jako jsou jmenné, slovesné a předložkové fráze. Věta „Pila byla opřena o strom.“ vs. „Strom byl opřen o pilu.“ ilustruje důležitost syntaxe. Obě věty obsahují stejná slova, ale tato slova jsou v různých syntaktických vztazích. Proto změna pořadí slov mění význam. Kromě toho slovo „pila“ může být buď podstatné jméno nebo sloveso, ale v tomto kontextu syntax naznačuje, že je použito jako podstatné jméno. **Zdroj** » Berkeley neuronový parser demonstruje koncepty POS označování (Part Of Speech — umožňuje parseru označit každé slovo ve větě příslušnou gramatickou kategorií) a generování syntaktického stromu, které graficky zobrazuje strukturu věty. Značky pocházejí z projektu » Penn Treebank.	**VC** Určit části textu, které by byly pro počítač obtížně srozumitelné, a vysvětlit proč. **TP** Počítače se potýkají s porozuměním textů, které obsahují metafory, obrazná vyjádření, nadsázku, sarkasmus, humor nebo slovní hříčky. **Doplnění** V současnosti neexistují uspokojivé formální teorie vysvětlující metafory, obraznost, nadsázku, sarkasmus, humor nebo slovní hříčky. Tato témata jsou středem zájmu současného výzkumu v oblasti umělé inteligence, lingvistiky a kognitivních věd.
Přirozený jazyk (mnohoznačnost jazyka) 4-A-II	**VC** Ilustrovat mnohoznačnost jazyka na příkladech homofonů (zvukově shodná, ale graficky odlišná slova) a homonym (slova se stejnou grafickou i zvukovou podobou, ale rozdílným významem) a ukázat, jak lze správné slovo určit pomocí kontextu. **TP** Některá slova mohou mít více než jeden význam, ale lidé i počítače jsou schopni na základě kontextu identifikovat ten správný. **Doplnění** Homonymum je např. slovo „pila“ (může být jak podstatným jménem, tak slovesem) a homofony jsou např. slova „bít“ a „být“. Tomu se říká dvojsmysl. **Můžete vyzkoušet** V nástroji pro přepis mluveného slova (např. funkce v Google dokumentech) si můžete vyzkoušet, jak si aplikace poradí s homofony.	**VC** Ukázat, jak může být porozumění větě pro počítač náročné, a to na základě vět, v nichž se zájmeno může vztahovat k jednomu ze dvou podstatných jmen. **TP** Věty mohou mít více významů v závislosti na tom, ke kterému podstatnému jménu se zájmeno vztahuje. Lidé a (v menší míře) počítače mohou k výběru nejpravděpodobnějšího významu využít kontext a znalost světa. **Doplnění** Příkladem nejednoznačné reference je věta „Klára pozvala Lenku na večeři a ona ji uvařila.“ Uvařila Klára Lenku k večeři? A pokud ne, kdo uvařil večeři? Často může znalost kontextu tento typ dvojznačnosti vyřešit. Nejednoznačná reference je otázkou sémantiky (významu). Syntaktický strom nám v tomto případě nenapoví.	**VC** Ukázat, jak může být pro počítač obtížné porozumět, když mu dáme větu, v níž se předložka může vázat k více slovům. Následně demonstrovat, jak lze někdy tuto nejednoznačnost vyřešit na základě významu věty. **TP** Jazyk bývá často nejednoznačný, ale některé významy lze zavrhnout, pokud nedávají smysl. Počítače zatím nedosahují úrovně lidské schopnosti porozumění kontextu. **Doplnění** Ve větě „Šla do kina na film s Brucem Willisem.“ nemůžeme s jistotou tvrdit, že to byl film s Brucem Willisem, ani to, že ona šla do kina s Brucem Willisem. Ale „Šla do kina na film s kyblíkem popkornu.“ je jednoznačné. Nejednoznačnost předložkových frází je příkladem syntaktické nejednoznačnosti, protože syntaktické stromy jsou různé: „s Brucem Willisem“ se může připojit buď k „filmu“, nebo k „ní“. Díky znalosti významu mohou lidem vybrat nejpravděpodobnější případ. Srovnejte to s nejednoznačnou referencí, o níž se hovoří v předchozí buňce. **Můžete vyzkoušet** Vytvořte nejednoznačné věty a vložte je do » Berkeley neuronového parseru, abyste zjistili, zda dokáže přiřadit předložku ke správnému slovu.	**VC** Ukázat, jak může být porozumění větě pro počítač náročné, a popsat více významů daného slova. **TP** Jedno slovo může mít několik významů. Lidé využívají kontext a znalost světa k určení správného významu, zatímco počítače obvykle nejsou schopny reprezentovat význam s takovou rozlišovací schopností. **Doplnění** Polysémie znamená, že jedno slovo má více významů. Například slovo „klíč“ může znamenat nástroj k otevření dveří („našel jsem klíč od domu“), ale také může znamenat řešení problému („našel jsem klíč k hádance“). Dalším příkladem je slovo „list“, které může označovat část stromu („list stromu padal na zem“), ale také může znamenat stránku papíru („napsal jsem to na list papíru“). Porovnejte tyto dvojsmysly s homonymy a homofony. Moderní systémy umělé inteligence využívající neuronové sítě a obrovské trénovací soubory používají statistický přístup k řešení nejednoznačnosti významu slov, ale samotná statistika není tak účinná jako lidský zdravý rozum. **Můžete vyzkoušet** Pomocí překladače » Deepl prozkoumejte, jak počítače řeší více významů slova při výběru vhodných slov pro překlad.
Přirozený jazyk (usuzování z textu) 4-A-III	**VC** Ukázat, jak počítač dokáže vytvořit různé tvary slovesa, například přítomný nebo minulý čas. **TP** Aby počítač mohl přirozeně komunikovat s lidmi, musí rozumět tomu, jak jsou slova tvořena a dávat je do správné formy. **Doplnění** Slovesa mohou mít různé tvary v první, druhé a třetí osobě, v jednotném nebo množném čísle a v přítomném nebo minulém čase. Aby počítač správně odpověděl na otázku „Kdy žili dinosauři?“, měl by říci „Dinosauři žili před více než 65 miliony let“. **Aktivita 1** Vyjmenujte všechny tvary, které slovesa mohou mít. Pokud bude aktivita v angličtině, můžete si výsledky zkontrolovat pomocí » tohoto konjugátoru. **Aktivita 2** Vytvořte věty v přítomném čase a pokuste se je převést do minulého. Můžete vyzkoušet také automatický převod v aplikaci využívající velký jazykový model. **Aktivita 3** Nastavte překladač Deepl pro překlad z češtiny do angličtiny a zadejte větu typu „Chodím do školy pěšky“. Pak vyzkoušejte různé formy věty („šel jsem“, „jdu pěšky“, „šel jsem pěšky“ atd.) a sledujte, jak se změní překlad.	**VC** Experimentovat se systémem převodu řeči na text a zjistit, zda správně řeší alternativní volby slov na základě kontextu. **TP** Systémy pro rozpoznávání řeči mohou používat gramatiku a kontext k řešení nejednoznačných slov, ale ne vždy se jim to podaří. **Můžete vyzkoušet** V nástroji pro přepis mluveného slova (např. funkce v Google dokumentech) vyzkoušejte alternativní interpretace přepisu vět „Být sám za dubem.“ a „Bít sám na buben“.	**VC** Ukázat, jak lze vektorové reprezentace slov (Word Embeddings) použít k usuzování o významu slov. **TP** Vektorové reprezentace slov představují slova s podobným významem jako blízké body v sémantickém prostoru a umožňují nám uvažovat o slovech pomocí aritmetiky. **Doplnění** Které slovo ze seznamu „snídaně“, „oběd“, „banán“, „večeře“ se nehodí k ostatním? Podobnost slov lze měřit jako vzdálenost v příznakovém prostoru; významově odlišný výraz bude od ostatních slov vzdálenější. Dalším příkladem usuzování o významu je doplňování analogií, např. „krále = muž, královna = žena“. To lze řešit tak, že se vypočítá příznakový vektor „král“ - „muž“ + „žena“ a najde se slovo, které je výsledku nejblíže. Skutečnou výhodou vektorových reprezentací slov je to, že slouží jako vstupy do sítí typu transformer, které provádějí mnohem složitější argumentační operace s textem. Více o vektorových reprezentacích slov a sítích typu transformer viz 2-A-IV. **Aktivita 1** Experimentujte s aplikací » Word2VecDemo (déle se načítá) a prozkoumejte reálné vektorové slovní reprezentace. **Aktivita 2** Využijte znalosti o slovních spojeních k vysvětlení, jak hra funguje » Semantris (Bloky).	**VC** Ukázat, jak lze jednoduchou bezkontextovou gramatiku použít k rozboru nebo generování jednoduchých vět. **TP** Bezkontextová gramatika popisuje, jak jsou slova kombinovaná do frází a klauzulí a mohou reprezentovat většinu syntaktické struktury přirozeného jazyka, ale neumí dobře zacházet s takovými věcmi, jako je shoda podmětu a přísudku. **Doplnění** Příkladem omezení shody je nutnost, aby se podměty a slovesa shodovaly v čísle, jako v případech „on říká“ a „oni říkají“. V bezkontextové gramatice by to vyžadovalo oddělená pravidla pro jednotné a množné číslo subjektu, což se komplikuje v případě složitějších vět, jako jsou například věty s koordinačními spojkami, které mohou vyžadovat shodu v čase i čísle. Viz 4-A-II pro příklady syntaktické nejednoznačnosti vedoucí k více syntaktickým stromům, které je třeba rozlišit pomocí sémantických znalostí. I jednoduchá gramatika, pokud je rekurzivní, může generovat nekonečné množství vět viz 4-A-I. **Zdroje** Nástroj » Stanford Context Free Grammar lze použít ke konstrukci syntaktických stromů, generování vět a ověřování správné gramatiky ve větách.
Přirozený jazyk (aplikace) 4-A-IV	**VC** Popsat, pro které úlohy jsou nebo nejsou vhodní hlasoví asistenti. **TP** Hlasoví asistenti (např. Siri, Alexa, Google asistent) jsou programy navržené tak, aby reagovaly na omezený soubor požadavků. Nemohou vést konverzaci jako člověk. **Doplnění** Mohou odpovídat na otázky, přehrávat hudbu, nastavovat budíky a vytvářet seznamy. Hlasoví asistenti však nejsou lidé. Navzdory schopnosti rozpoznat mluvenou řeč mají omezené konverzační schopnosti. Jedním z důvodů je to, že mají problémy s udržením kontextu, tj. zapamatováním si toho, co bylo řečeno dříve, aby jim pomohlo pochopit, co se říká nyní. **Aktivity** Vyzkoušejte hlasového asistenta. Jaké věci umí dělat dobře a jaké ne? Kde leží hranice jeho chápání?	**VC** Navrhnout typy otázek, na které může vyhledávač nebo hlasový asistent odpovědět, a se kterými si neporadí. **TP** Vyhledávače (např. Google) a inteligentní asistenti (např. Siri, Alexa nebo Google asistent) mají k dispozici soubor specializovaných a univerzálních modulů, z nichž čerpají odpovědi na různé typy otázek. **Doplnění** Příklady dotazů zpracovávaných specializovanými moduly: definice slov, převody jednotek (např. palce na milimetry, dolary na eura), aktuální čas a počasí kdekoli na světě, životopisná a zeměpisná fakta (datum narození Abrahama Lincolna, hlavní město Belgie), otevírací doba obchodů a pokyny pro jízdu autem, letové, vlakové a autobusové řády. Současní inteligentní agenti si vedou hůře, když jsou požádáni, aby uvažovali o vztazích mezi entitami (např. je aligátor větší než pštros), nebo když jsou požádáni, aby vytvořili vysvětlení spíše než jednoduchá fakta (např. Proč Shakespeare nepsal o letadlech?). Když žádný specializovaný modul nedokáže dotaz zpracovat, vyhledávače se vrátí k vyhledávání podle klíčových slov, ale výsledky jsou často neuspokojivé.	**VC** Popsat některé úlohy zpracování přirozeného jazyka (NLP — Natural Language Processing), které mohou provádět počítače a vysvětlit, jak fungují. **TP** Úlohy NLP zahrnují shrnutí textu, generování textu, analýzu sentimentu, zodpovídání otázek, strojový překlad a konverzační interakci.	**VC** Popsat několik přístupů ke zpracování přirozeného jazyka, od jednoduchých až po složitější. **TP** Jednoduché přístupy v oblasti zpracování přirozeného jazyka (NLP) zahrnují porovnávání klíčových slov, vyhledávání ve slovníku a porovnávání podle šablon. Tyto metody jsou obvykle transparentnější a snadněji pochopitelné. Na druhé straně, sofistikovanější přístupy využívají hluboké neuronové sítě a strojové učení mohou nabídnout výrazně lepší výsledky v komplexních úlohách NLP. **Doplnění** Vezmeme-li si jako příklad jednoduché chatboty, tak jejich algortimy hledají klíčová slova v uživatelských vstupech a dle toho rozhodnou, jakou odpověď poskytnout. O něco sofistikovanější přístup používá šablony (themes), které popisují všechny varianty, jichž může fráze nabývat, místo aby se zabývaly jednotlivými frázemi. Sofistikovanější chatboti používají hluboké neuronové sítě pro „porozumění záměru“, které zjišťují, kdy význam vstupu odpovídá šabloně, místo aby hledaly konkrétní slova nebo fráze. **Aktivity** Studenti by měli být schopni popsat omezení těchto přístupů. A také kdy mohou být užitečné a kdy ne.
Usuzování pomocí zdravého rozumu 4-B-I	**VC** Vysvětlit události nebo lidské chování založené na logickém úsudku, jejichž znalost by mohla být pro robota užitečná. **TP** Výběr nejpravděpodobnějšího konce příběhu je příkladem uvažování zdravým rozumem. Vyžaduje znalosti o lidech, věcech a jejich chování, které mohou počítače postrádat. **Aktivity** (1) Vyberte nejpravděpodobnější konec příběhu na základě seznamu alternativ a vysvětlete svou volbu; (2) Vysvětlete, proč postava v příběhu udělala určitou akci; (3) Navrhněte vhodné jednání postavy v určité situaci a vysvětlete, proč tomu tak je.	**VC** Vysvětlit, jaké znalosti by počítač potřeboval k porozumění příběhu. **TP** Umělá inteligence má problém porozumět příběhům, protože nemá takové znalosti o každodenním životě jako lidé. **Doplnění** „Každodenní život“ zahrnuje jak kulturní znalosti (k čemu slouží deštník), tak intuitivní fyziku (upuštěné předměty padají díky gravitaci). **Můžete vyzkoušet** Složte příběh, který může být pro počítač obtížně srozumitelný, a vysvětlete, co jej činí obtížným.	**VC** Vysvětlit, jaké znalosti by počítač potřeboval k vyřešení usuzovací úlohy týkající se lidové fyziky. **TP** Počítače mohou uvažovat o fyzikálních jevech pomocí odvozovacích pravidel intuitivní fyziky, která formalizují naše intuitivní chápání pojmů, jako jsou hmotnost, objem, síla a pohyb. V současné době v tom počítače nejsou příliš dobré. **Doplnění** Intuitivní fyzika zahrnuje znalost zákonů zachování. Když přelejeme vodu z velké nádoby do menší, tak přeteče, protože malé nádoby mají menší objem a množství vody se nemění. Lidová fyzika obsahuje také odvozovací pravidla o síle, například „Když těžká věc narazí na lehkou věc, lehká věc se pohne“. **Můžete vyzkoušet** Navrhněte argumentační problém, jehož řešení vyžaduje znalosti lidové fyziky, a řekněte, jaké tyto znalosti jsou.	**VC** Vysvětlit, jaké kulturní a lidově fyzikální znalosti jsou nutné, aby počítač správně interpretoval pohádku nebo bajku. **TP** K tomu, aby člověk nebo počítač dokázal odvodit smysl příběhu, je zapotřebí porozumět kulturním znalostem, lidové fyzice a lidové psychologii. To pro počítače stále obtížné. **Doplnění** Pohádky a bajky představují pro počítače výzvu, jelikož často zahrnují kulturní znalosti, složité lidské motivace, obraznost, humor a metafory. Lidová psychologie se vztahuje k naší běžné schopnosti přisuzovat ostatním lidem mentální stavy, jako jsou jejich přesvědčení, touhy a záměry. **Můžete vyzkoušet** Vysvětlete, jaká znalost je nutná pro porozumění větě dle Winogradova schématu. Příklad: „Míč se nevešel do kufru, protože byl příliš velký“. Co bylo příliš velké — míč nebo kufr? Proč to tak je?
Porozumění emocím 4-C-I	**VC** Vysvětlit, jak počítače rozpoznávají emoce z výrazu lidské tváře. **TP** Počítače rozpoznávají emoce v lidských tvářích podle tvaru úst, očí a obočí. **Můžete vyzkoušet** Na různých fotografiích obličeje identifikujte orientační body (např. obočí, oči a ústa), díky nimž je počítač schopen odvodit emoční stav. Popište, jak se lidé na fotografiích cítí a z čeho tak usuzujte. Aktivitu lze zahájit s emotikony, které reprezentují různé emoce. **Můžete vyzkoušet** Online nástroj » face-api pro rozpoznávání emocí v lidské tváři.	**VC** Ukázat, jak mohou počítače posoudit emocionální zabarvení textu. **TP** Počítače dokáží rozpoznat pozitivní a negativní výroky na dané téma pomocí technik zpracování přirozeného jazyka známých jako analýza sentimentu. **Doplnění** Analýza sentimentu se používá k různým úkolům, jako je např.: • Recenze filmů: Analýza online recenzí filmů s cílem získat informace o filmu od diváků. • Recenze restaurací: analýza recenzí restaurací z důvodu měření spokojenosti zákazníků. • Zpravodajství: Analýza zpravodajství, např. událostí, osob nebo společností za účelem posouzení názorů médií. • Analýza obsahu sociálních sítí: analýza nálad v příspěvcích na Facebooku, Twitteru nebo Instagramu s cílem posoudit veřejné mínění o událostech, osobách nebo produktech. **Můžete vyzkoušet** Úloha pro analýzu sentimentu je dostupná v nástroji » Machine Learning for Kids (úloha Udělej mi radost/Make me happy).	**VC** Popsat, jak počítače využívají různé vstupy k rozpoznání lidských emocionálních stavů. **TP** Počítače dokáží rozpoznat, jak se lidé cítí, na základě výrazu obličeje, pohledu, gest, řeči těla, tónu hlasu nebo volby slov. **Doplnění** Například řeč těla může naznačovat angažovanost, nepřátelství, úzkost nebo nudu. Řeč těla může být například to, jak má člověk složené ruce, v jaké poloze má nohy, zda je předkloněný nebo zakloněný a jak naklání hlavu. Počítače mohou tyto informace získat např. ze snímků z webových kamer.	**VC** Určit způsoby, jak mohou aplikace umělé inteligence upravit své chování tak, aby lépe reagovaly na emocionální stavy lidí. **TP** Počítače mohou reagovat na lidské emoce způsobem, který lidé považují za podpůrný a společensky vhodný, pokud jsou schopné rozpoznat jejich emocionální stavy. **Doplnění** Například výukové systémy založené na umělé inteligenci sledují chování studentů a rozpoznávají frustraci, nudu a únavu, aby mohly přizpůsobit výuku nebo vyzvat studenta k přestávce. Automatizovaní agenti zákaznických služeb, kteří rozpoznají lidské emoce, by mohli odpovídajícím způsobem přizpůsobit své reakce, např. úpravou tempa řeči a tónu hlasu. **Můžete vyzkoušet** Diskutujte o tom, jak by počítače měly reagovat na lidi způsobem, který považujeme za podpůrný a společensky přiměřený, vzhledem k tomu, že umělá inteligence dokáže rozpoznat lidské emoce.
Filozofie mysli 4-D-I	**VC** Popsat příklady, kdy systémy umělé inteligence nerozumí věcem stejně jako lidé. **TP** Systémy umělé inteligence nejsou lidé, ale lidmi navržené počítačové programy. **Doplnění** Inteligentní systémy nedokáží vyřešit některé složité usuzovací úlohy.	**VC** Popsat úlohy, které by systém obecné umělé inteligence mohl řešit a na něž ty současné (úzká umělá inteligence) nestačí. **TP** Úzká umělá inteligence mnohdy dokáže překonávat lidské schopnosti, ale pouze v konkrétních úlohách. Oproti tomu obecná umělá inteligence bude schopna usuzování srovnatelného s lidským intelektem. **Doplnění** V současné době vykazují obecnou inteligenci pouze lidé. Jsme schopni vykonávat spousty různorodých věcí a učíme se stále nové. Současné programy umělé inteligence jsou úzce zaměřené na jeden/několik málo druh/ů úloh. Například programy, které umí dobře hrát šachy nebo ovládat auto, nedokáží odpovídat na otázky týkající se příběhu. V současné době nemáme algoritmy ani technologie strojového učení, které by dokázaly napodobit všechny aspekty lidské inteligence najednou.	**VC** Pokusit se na základě toho, co je považováno za lidské vědomí, ohodnotit systémy umělé inteligence (nebo fiktivní AI persony). **TP** Zdá se, že dvěma důležitými kritérii vědomí jsou uvědomování si sebe sama a své osobní historie. **Doplnění** Otázky spojené s vědomím: (1) Je třeba uvědomování si sebe sama (uvědomování si uvědomování); (2) je třeba znalost osobní historie (vzpomínky na prožité); (3) je třeba mentální jazyk; (4) existují různé úrovně vědomí; (5) jaké druhy vědomí vykazují zvířata? **Můžete vyzkoušet** Zkoumejte, zda zvířata mají vědomí a jak se jejich vědomí liší od lidského. Pokud vědomí existuje na určité škále, myslíte si, že by se počítač mohl někdy na této škále vyrovnat člověku nebo ho předčit?	**VC** Diskutovat o alternativních pohledech na lidskou a umělou inteligenci. **TP** Někteří odborníci na umělou inteligenci a filozofové tvrdí, že počítače nikdy nemohou dosáhnout inteligence, která se vyrovná té lidské, zatímco jiní věří, že umělá inteligence nakonec lidskou inteligenci překoná. **Doplnění** Tvrzení, že počítač má inteligenci podobnou lidské, je problematické, jelikož neznáme podstatu lidské inteligence. Silnější argument proti počítačové inteligenci spočívá v tom, že pokud nemá dokonalé fyzické tělo, nemůže prožívat svět jako lidé. Naopak, lidé mají omezenou paměť a schopnost usuzování, což by počítač mohl překonat. To by vedlo k vyšší inteligenci než je ta lidská (superinteligence). Přesto můžeme mít zařízení, která zvládají složité úlohy zpracování informací, aniž by měla inteligenci srovnatelnou s lidskou. **Můžete vyzkoušet** (1) Vysvětlete Turingův test a vytáhněte si úryvek z Turingova článku a porovnejte dialog navržený Turingem s tím, co dokážou dnešní systémy umělé inteligence. (2) Porovnejte inteligenci zvířat s lidskou inteligencí. (3) Porovnejte inteligenci zvířat s AI.

VC (vzdělávací cíl) — co by žáci/studenti měli umět. **TP** (trvalé porozumění) — co by žáci/studenti měli znát.

5. Velká myšlenka — Společenské dopady

Klíčové poznatky
Umělá inteligence může mít na společnost pozitivní i negativní dopad.
Při navrhování systémů umělé inteligence je třeba brát v potaz technická i etická hlediska.
Systémy umělé inteligence mohou vznikat v komplikovaných prostředích, v nichž mohou mít různí aktéři, zasahující do jejich vývoje, rozdílné hodnoty a zájmy.
Systémy umělé inteligence, které dělají rozhodnutí o lidech, by měly být navrženy v souladu se společenskými hodnotami, jako je spravedlnost, vysvětlitelnost nebo soukromí.
Umělá inteligence je převratná technologie, která ovlivní nejen ekonomiku a zaměstnanost, ale také sociální a kulturní normy.
Umělá inteligence se stává součástí osobních i profesních nástrojů každého z nás.

Úroveň ↦	1. stupeň základní školy		2. stupeň základní školy	Střední škola
Ročník ↦	2. ročník	3.—5. ročník	6.—9. ročník	
Koncept ↧				
Etická umělá inteligence (zájmová diverzita a spravedlivá rozhodnutí) 5-A-I	**VC** Zhodnotit, jakým vliv mají různá rozhodnutí na různé skupiny lidí. **TP** Počítače mohou někdy učinit rozhodnutí, která jsou pro majoritu výhodná, ale minoritu znevýhodňuje nebo jí dokonce škodí.	**VC** Zhodnotit, jaké může mít umělá inteligence různé dopady na různé skupiny lidí. **TP** Rozhodnutí učiněná při vývoji systému umělé inteligence mohou mít na různé lidi a komunity různý dopad. **Doplnění** Některé aplikace umělé inteligence, fungují pro různé skupiny různě, například: rozpoznávání řeči spolehlivě sloužící rodilým mluvčím angličtiny, ale špatně pro mluvčí s přízvukem; systémy pro rozpoznávání tváří, které fungují spolehlivě pro dospělé bílé muže, ale méně spolehlivě pro ženy, děti nebo lidi s tmavším odstínem pleti.	**VC** Zhodnotit, jaké cíle a hodnoty různých aktérů při vývoji systémů umělé inteligence ovlivňují výsledný produkt. **TP** Fungování systémů umělé inteligence je určeno volbami vývojářů a dalších aktérů, které mohou zahrnovat kompromisy mezi protichůdnými cíli a hodnotami. Jestliže se nedostatečně zohledňují pohledy všech zúčastněných stran, může to vést k negativním důsledkům pro uživatele. **Doplnění** Mezi aktéry patří investoři, vývojáři, uživatelé (a lidé, kteří se starají o jejich blaho) a případně marketéři nebo tvůrci obsahu. Jako negativní příklad uveďme tvůrce aplikací, kteří za účelem výdělku, chtějí nalákat lidi ke sledování reklam. Takový přístup může negativně ovlivnit uživatele, kteří tráví velké množství času sledováním nekvalitního obsahu. Nebo ty, jejichž vidění světa je zkresleno opakouvanou konzumací dezinformací. Také to může vadit rodičům, kteří by chtěli, aby jejich děti trávili čas produktivnějším způsobem.	**VC** Vysvětlit, jak využívání systémů umělé inteligence může mít různé dopady na různé skupiny lidí. **TP** Na různé skupiny lidí mohou mít systémy umělé inteligence různý dopad. **Doplnění** K nespravedlivým rozhodnutím může dojít, pokud tvůrci systému nedostatečně zohlední rozdíly mezi uživateli. Například systém, který je určen k doporučování zdravotní péče, může pracovat se zkreslenými daty historických výdajů na zdravotní péči, u nichž přepokládá, že všichni pacienti mají stejné zdravotní pojištění. To může vést k tomu, že bude zdravotní péče doporučována více těm s lepší zdravotním pojištěním, než těm, kteří to doopravdy potřebují. Takováto nezjištěná zkreslení v systémech strojového učení (např. v aplikacích pro screening životopisů) mohou mít neblahé dopady na některé méně zastoupené skupiny.
Etická umělá inteligence (kritéria etického designu) 5-A-II	**VC** Charakterizovat spravedlivé a nespravedlivé systémů a jejich dopadu na společnost. **TP** Systémy umělé inteligence by měly být navrženy tak, aby přinášely prospěch lidem. Tvůrci těchto systémů by měli dbát na to, aby jejich systémy zacházely s každým spravedlivě. **Můžete vyzkoušet** Zprostředkujte ve třídě cvičení zaměřené na spravedlivé rozdělení věcí. Nechte žáky diskutovat, jak spravedlivě rozdělit 10 věcí mezi 15 lidí.	**VC** Zhodnotit, jak systém umělé inteligence splňuje kritéria transparentnosti a vysvětlitelnosti. **TP** Systém umělé inteligence je transparentní, pokud víme, jaká data a kritéria rozhodování využívá. Součástí transparentnosti je, že je systém schopen svá rozhodnutí vysvětlit. **Můžete vyzkoušet** Ukažte žákům dataset, na nichž se učila aplikace » Quick, Draw! a diskutujte o tom, na základě čeho rozpoznává nové kresby.	**VC** Zhodnotit, jak systém umělé inteligence splňuje kritéria odpovědnosti a respektování soukromí. **TP** Odpovědnost v systémech umělé inteligence znamená, že vývojáři a další aktéři přebírají odpovědnost za činnost systému. Respektování soukromí znamená, že systém nejedná způsobem, který porušuje práva lidí na jejich soukromí.	**VC** Analyzovat systém umělé inteligence a určit, zda splňuje etická kritéria návrhu. **TP** Aby bylo zajištěno, že systémy umělé inteligence budou užitečné, a nikoli škodlivé, patří mezi etická kritéria návrhu: férovost, transparentnost, vysvětlitelnost, odpovědnost, respektování soukromí a jednání na základě společenských hodnot. **Doplnění** Férovost — rovné zacházení s lidmi. Transparentnost — zveřejňovat, jak a jaké informace systém používá. Vysvětlitelnost — schopnost zdůvodnit rozhodnutí, která systém učinil. Odpovědnost — je jasné, kdo je odpovědný za důsledky činnosti systému. Respektování soukromí — nejednat způsobem, který by mohl narušit soukromí lidí. Dodržování společenských hodnot — jednat v souladu s nimi. **Zdroje** » AI Artist, katalog zdrojů » Karty modelu (podpora transparentnosti a odpovědnosti)
Etická umělá inteligence (tvorba etických systémů) 5-A-III	Neuplatňuje se.	**VC** Vytvořit kartu modelu pro klasifikační nebo predikční model. **TP** Karty modelu podporují transparentnost tím, že vysvětlují zamýšlené použití, uvádějí, na jakých datech byl trénován, jaká je jeho přenost a zda má nějaká omezení. **Můžete vyzkoušet** Žáci mohou vytvořit klasifikátor a následně karty modelu. **Zdroje** » Karty modelu od Google » Google Teachable Machine » Lekce Karty modelu na code.org » AI Lab na code.org	**VC** Zhodnotit způsoby, jakými mohou návrháři systémů umělé inteligence poznat hodnoty zúčastněných stran a začlenit je do procesu návrhu. **TP** Systémy umělé inteligence musí být v souladu s normami a hodnotami skupin lidí, kterým mají sloužit. Vývojáři systémů AI musí pochopit, že hodnoty se v různých kulturách liší, a zajistit, aby tyto hodnoty byly základem pro návrh produktů, které vytvářejí. **Můžete vyzkoušet** Zvolte systém umělé inteligence a sestavte etickou matici tak, že uvedete seznam zúčastněných stran a jejich hodnoty. Poté vyhodnoťte soulad mezi systémem a zúčastněnými stranami. **Zdroje** » MIT kurikulum — AI a etika (přehled) » Lekce MIT kurikulum — Etické matice	**VC** Navrhnout systém umělé inteligence s využitím etického procesu návrhu. **TP** Etický návrh ve všech fázích procesu návrhu zohledňuje hodnoty všech zúčastněných stran a dodržuje zásady spravedlnosti, transparentnosti, vysvětlitelnosti, odpovědnosti, respektování soukromí a dodržování společenských hodnot.
AI a kultura (AI v každodenním životě) 5-B-I	**VC** Identifikovat zařízení v každodenním životě, která využívají technologie umělé inteligence. **TP** Technologie umělé inteligence jsou součástí všech zařízení, která obsahují rozpoznávání řeči nebo počítačové vidění, jako jsou chytré telefony, inteligentní domácí asistenti nebo moderní automobily.	**VC** Popsat běžné využití služeb s umělou inteligencí v každodenním životě. **TP** Služby využívající umělou inteligenci se používají k vyhledávání informací, k doporučování na základě zájmů člověka, k zajištění větší bezpečnosti automobilů nebo jako hlasové rozhraní mnoha aplikací. **Doplnění** Umělá inteligence umožňuje poskytovatelům služeb porozumět preferencím lidí a na základě toho vytvořit personalizované modely. Vyhledávače používají AI k pochopení vyhledávacích dotazů a doporučování obsahu. Doporučovací systémy na základě dat uživatelského chování doporučují obsah na streamovacích platformách (YouTube, Spotify, Netflix…), velkých e-shopech (Amazon…), sociálních sítích atd. Autonomní vozidla používají počítačové vidění.	**VC** Popsat, u kterých aspektů každodenního života se předpokládá, že se změní v důsledku zavedení technologií umělé inteligence. **TP** Technologie umělé inteligence mění každodenní život, protože inteligentní systémy nacházejí nové uplatnění ve společnosti. **Doplnění** Klíčové aspekty každodenního života, jako jsou způsoby komunikace, učení se, sociální interakce a struktura našich rutinních činností, se mohou významně proměnit v důsledku rostoucího využívání umělé inteligence. Zamyslete se nad možnými změnami například v dopravě a to v důsledku nárustu množství autonomních aut. Jak budou řidiči interagovat s vozidly, které něřídí člověk? Budou moci děti cestovat samy v samořiditelných autech a jak tato vozidla upravit pro jejich bezpečnou přepravu? Automatizované služby objednávání jízd mohou zredukovat potřebu vlastního auta a snížit poptávku po parkovacích místech. Lidé se nebudou muset učit řídit. Průvodcovské služby by mohly integrovat chatboty do autonomních vozidel…	**VC** Popsat výzvy, které se objevují nebo mohou v budoucnu objevit v souvislosti s dalším vývojem technologie umělé inteligence a jejím dalším pronikáním do naší kultury. **TP** Některé nové způsoby využití umělé inteligence představují a budou představovat výzvu pro kulturní normy a očekávání. Tyto výzvy musí společnost identifikovat a vypořádat se s nimi. **Doplnění** Mezi takové výzvy patří: Co je přijatelné při interakci s inteligentními systémy nebo roboty? Jak bychom se měli dívat na výstupy, vytvořené pomocí generativní umělé inteligence nebo ve spolupráci s ní? Jaké je přijatelné využití velkých jazykových modelů ve vzdělávání? Jakým způsobem mohou vývojáři AI aplikací pracovat s osobními údaji uživatelů nebo na používat veřejně dostupná data? Podobných výzev lze očekávat mnohem více.
AI a kultura (důvěra a odpovědnost) 5-B-II	Neuplatňuje se.	**VC** Anayzovat vygenerované obrázky nebo videa a identifikovat nedokonalosti, prozrazující, že se jedná o deepfake. **TP** Současné deepfakes jsou okem téměř nerozeznatelné or skutečných obrazů nebo videí, což může podkopávat naši důvěru v digitální média. **Zdroje** Zkuste rozpoznat skutečnou tvář od vygenerované » Která tvář je skutečná	**VC** Kriticky posoudit způsoby využití umělé inteligence ke sledování lidí nebo narušení jejich soukromí. **TP** Technologie umělé inteligence umožňují s výrazně nižšími náklady sledování (dohled) osob, objektů nebo procesů — monitorování kamerami, odposlechy, mapování pohybu…, čímž mohou ohrožovat soukromí. **Dlaší** K typům sledování (monitoringu) patří nejen rozpoznávání osob a sledování registračních značek na veřejně přístupných místech, odposlechy telefonních hovorů, ale také sledování chování uživatelů v online prostoru, které lze využít k vytvoření uživatelských profilů obsahujících citlivé osobní údaje.	**VC** Určit oblasti, ve kterých je vhodné regulovat používání technologií umělé inteligence, a zhodnotit navržené regulace. **TP** Právní regulace umělé inteligence je vhodná v oblastech, kde existují společenské hodnoty, které vyžadují ochranu. **Doplnění** Do oblasti evropské regulace patří používání AI technologií, které jsou klasifikovány jako zakázané nebo vysoce rizikové. Požadavky jsou také na AI systémy obecného účelu a základní modely.
AI a ekonomika (dopady AI na různé společenské oblasti) 5-C-I	**VC** Identifikovat současná využití umělé inteligence a jejich dopad na společnost. **TP** Společnost se díky umělé inteligenci změnila a bude se měnit i v budoucnu. **Doplnění** AI v současnosti ovlivňuje například způsob, jakým získáváme informace, jak se orientujeme a jak vyhledáváme zábavu.	**VC** Identifikovat změny ve fungování společnosti v důsledku rozšíření umělé inteligence. **TP** V důsledku rozšíření umělé inteligence se mění (a měnit budou) všechny oblasti společnosti. **Doplnění** Mezi společenské oblasti patří výroba, maloobchod, zemědělství, potravinářství, pohostinství, doprava, bydlení, životní prostředí, vzdělávání, zábava, zdravotnictví, finance, státní správa, veřejná bezpečnost, sociální služby a vymáhání práva. Příklad změny: Výroba se pomocí AI více automatizuje, což může vést ke snížení nákladů a zlepšení kvality. Zároveň také ke změnám na pracovním trhu. Díky AI můžou vzniknout i nové produkty, potraviny nebo zdravější či odolnější klony rostlin. **Můžete vyzkoušet** Vyhledejte konkrétní příklad pozitivní a negativní změny, kterou rozvoj umělé inteligence přinesl do nějaké společenské oblasti.	**VC** Porovnat dopady umělé inteligence na společnost s dopady předchozích průmyslových revolucí. **TP** Umělá inteligence přináší pokrok a změny ve společnosti, které jsou srovnatelné s dopady minulých průmyslových revolucí. **Doplnění** První průmyslová revoluce byla založena na mechanické síle, druhá na elektřině a masové výrobě, třetí na počítačích a síťových technologiích. Probíhající čtvrtá průmyslová revoluce je založena na umělé inteligenci, robotice, internetu věcí a technologiích genetického inženýrství.	**VC** Pokusit se předpovědět, jak se v krátkodobém a střednědobém horizontu pravděpodobně změní určité oblasti společnosti v důsledku rozvoje umělé inteligence. **TP** Diskuze o tom, jak se promítnou do společnosti změny na základě rozvoje umělé inteligence, jsou důležité pro zdravý vývoj společnosti. **Doplění** Dva často zmiňované typy dopadů umělé inteligence jsou vyšší úroveň automatizace a nové typy služeb. Roy Amara, bývalý prezident Institutu pro budoucnost, vytvořil Amarův zákon, který říká: „Máme tendenci přeceňovat účinek technologie v krátkodobém horizontu a podceňovat účinek v dlouhodobém horizontu.“ **Můžete vyzkoušet** (1) Diskutujte o možných nových službách, které se mohou vyvinout díky umělé inteligenci. (2) Určete a vysvětlete nezamýšlený důsledek ve společnosti, který vznikl v důsledku systému AI.
AI a ekonomika (vliv na zaměstnanost) 5-C-II	**VC** Uvést některá zaměstnání, která v důsledku technologického pokroku již neexistují. **TP** Nové technologie mění typy pracovních míst, která jsou pro lidi dostupná. **Doplnění** Automobil snížil naši závislost na koních, což snížilo potřebu kočí, ale vytvořilo pracovní místa například pro automechaniky. Automatizace továren umožnila masovou výrobu, což snížilo potřebu kovářů, přadláků a tkalců, ale vytvořilo pracovní místa pro lidi, kteří továrny staví a udržují.	**VC** Popsat, jak se změní konkrétní pracovní místo vlivem umělé inteligence nebo robotiky. **TP** S nástupem umělé inteligence a robotických technologií na pracovišti se změní způsoby, jakými lidé vykonávají svou práci. **Můžete vyzkoušet** Žáci si mohou přečíst články vhodné pro danou třídu, které popisují pracovní místa, jež se modernizují s využitím technologií umělé inteligence a robotů (např. skladníci pracující společně s roboty).	**VC** Pokusit se předpovědět, jaký nový typ práce by mohl vzniknout nebo jak by se mohl transformovat či zaniknout stávající typ práce vlivem umělé inteligence. **TP** V důsledku zavádění nových technologií dochází ke změnám v kultuře, což vede k omezení některých typů pracovních míst a vzniku nových. **Můžete vyzkoušet** Zkuste vymyslet náplň práce pro konkrétní budoucí profesi — jak bude vypadat práce s umělou inteligencí a robotickými systémy? Jaké dovednosti budou potřeba?	**VC** Identifikovat dovednosti potřebné pro povolání, ve kterých je využívána AI. **TP** Dovednosti, které jsou třeba pro využívání AI, budou klíčové pro celý pracovní trh, nikoli jen pro programátory. Většina pracovních pozic bude zahrnovat nějakou formu interakce s technologiemi AI. **Doplnění** S rozmachem nových technologií se během života člověka mění i povaha jeho práce. Lidé se budou muset neustále učit po celou dobu své kariéry. Dovednosti, které jsou stále důležitější a jsou v souladu s AI, zahrnují shromažďování a kurátorskou činnost datových souborů pro strojové učení, interakci s inteligentními systémy, trénování robotů pro konkrétní úkoly, používání kreativních nástrojů na bázi AI pro tvorbu a úpravu obrázků, a znalostní inženýrství pro systémy umělé inteligence.
AI pro společenské dobro (demokratizace umělé inteligence) 5-D-I	Neuplatňuje se.	**VC** Využít některé funkce, rozšíření nebo zásuvné moduly, využívající umělou inteligenci, které jsou k dispozici v dostupném programovacím nástroji. **TP** Umělá inteligence se stává součástí běžných nástrojů dostupných prostřednictvím funkcí, rozšíření nebo zásuvných modulů. Komunity díky nim mohou snadno vyvíjet aplikace využívající AI přímo na základě svých specifických potřeb. **Doplnění** Například na platformě Scratch naleznete rozšíření pro převod řeči na text, převod textu na řeč, rozpoznávání tváří, analýzu sentimentu, zodpovídání otázek a rozšíření vizuálních klasifikátorů. Nástroj » Machine Learning for Kids propojuje trénování modelů strojového učení a platformu Scracth.	**VC** Vytvořte novou aplikaci s využitím některého z rozšíření nebo zásuvných modulů umělé inteligence, které jsou k dispozici ve zvoleném programovacím nástroji. **TP** Umělá inteligence se stává součástí běžných nástrojů dostupných prostřednictvím funkcí, rozšíření nebo zásuvných modulů. Komunity díky nim mohou snadno vyvíjet aplikace využívající AI přímo na základě svých specifických potřeb. **Doplnění** Například na platformě Scratch naleznete rozšíření pro převod řeči na text, převod textu na řeč, rozpoznávání tváří, analýzu sentimentu, zodpovídání otázek a rozšíření vizuálních klasifikátorů. Nástroj » Machine Learning for Kids propojuje trénování modelů strojového učení a platformu Scracth nebo MIT App Inventor. Mnoho implementovaných funkcí má také » Calypso.	**VC** Vytvořte novou aplikaci využívající některé z nástrojů umělé inteligence dostupných ve zvoleném programovacím prostředí. **TP** Nástroje umělé inteligence se stávají běžnými a volně dostupnými a mohou je používat i lidé bez specifického vzdělání nebo drahého vybavení.
AI pro společenské dobro (využití AI k řešení společenských problémů) 5-D-II	**VC** Popsat, jak lze umělou inteligenci využít k řešení společenského problému. **TP** Umělou inteligenci lze použít k vytvoření klasifikačního modelu, který řeší problém důležitý pro společnost. **Doplnění** Pomocí správně natrénovaných klasifikančích modelů můžeem automaticky rozlišovat například volně žijící mořské živočichy od objektů, které do moře nepatří. Nebo také recyklovatelné materiály od těch nerecyklovatelných. Nebo zdravé rostliny od nemocných. **Můžete vyzkoušet** online hru » AI for Oceans, v rámci níž mohou žáci natrénovat model strojového učení pro klasifikaci mořských živočichů a objektů, které do moře nepatří.	**VC** Navrhnout řešení společenského problému s využitím umělé inteligence. **TP** Umělá inteligence se využívá k řešení společenských problémů, jako je například ochrana životního prostředí, úspora energie a zlepšení veřejného zdraví.	**VC** Navrhnout společenský problém a popsat jeho udržitelné řešení pomocí umělé inteligence. **TP** Technologie umělé inteligence pro vnímání, usuzování a strojové učení lze využít na mnoho společenských problémů. **Zdroje** » 16 cílů udržitelného rozvoje OSN Stránka » Google AI for Social Good	**VC** Zhodnoťte projekt » Google AI for Social Good z hlediska problému, který řeší, a jeho skutečného nebo potenciálního dopadu. **TP** Termín „AI pro společenské dobro“ znamená využití umělé inteligence k řešení společenských problémů. **Doplnění** Společenské dobro se snaží přinést co největší užitek co největšímu počtu lidí, aby se svět stal lepším místem. Patří sem cíle jako je úspora energie, ochrana životního prostředí, ochrana ohrožených druhů, dostupné zdravotnictví a prevence obchodování s lidmi. **Zdroje** » 16 cílů udržitelného rozvoje OSN

VC (vzdělávací cíl) — co by žáci/studenti měli umět. **TP** (trvalé porozumění) — co by žáci/studenti měli znát.