




Dear Future E-book

Sanjajte, angažirajte se, djelujte i ponovno djelujte za budućnost

Naziv projekta: Dream, Engage, Act and Re-act 4 budućnost
Projekt br.: 2021-2-PL01-KA220-SCH-000048581

Akronim projekta: DearFuture
Trajanje: 01.03.2022. - 31.12.2024



**Co-funded by
the European Union**

Ovaj projekt je financiran uz potporu Europske komisije. Ova publikacija odražava samo stajališta autora i Komisija se ne može smatrati odgovornom za bilo kakvu upotrebu informacija sadržanih u njoj.



Autori: Szkola Podstawowa im Wladyslawa Stanislaw Reymonta w
Szczutowie, Agrupamento de Escolas de Barcelos, Základníškola Želiv,
okres Pelhřimov, Detskagradina "Radost", Djecji Vrtić Varaždin, Eurasia
Grafički dizajn: Euroazija
Dizajn, redakcija i produkcija: Eurasia



Autorska prava © 2023
Sva prava su pridržana.


Sadržaj


- 01 O projektu
- 02 Poglavlje 1: Umjetna inteligencija i njezin povijesni razvoj
- 03 Poglavlje 2: UI i politike u EU
- 04 Poglavlje 3: Osnovna načela umjetne inteligencije
- 05 Poglavlje 4: Pristup interaktivnog pripovijedanja temeljen na igrama u podučavanju umjetne inteligencije
- 06 Poglavlje 5: UI i budući poslovi
- 07 Plan provedbe nastavnog plana i programa

O projektu

Želimo promicati umjetnu inteligenciju u predškolskom obrazovanju jer strategija obrazovanja i skrbi za rano djetinjstvo za razdoblje 2021.-2030. navodi da su „osnovne digitalne vještine i kompetencije od rane dobi smanjene jer su učenici predškolske dobi u visokom stupnju razvoja i fizički i kognitivno". Konzorcij DEAR FUTURE svjestan je da podučavanje umjetne inteligencije nije jednostavno jer je umjetna inteligencija vrlo složena, nekonkretna i nova za učenike predškolske dobi. Kako bi se olakšala složenost i smanjio



apstrakcije umjetne inteligencije u nastavi, želimo poboljšati novi pristup. U tom kontekstu, želimo promovirati UI kroz pristup interaktivnog pripovijedanja (GIS) temeljenog na igrama. Odabrali smo GIS jer učenici predškolske dobi bolje uče kroz igre i priče.





Ciljevi projekta

- Stvoriti, testirati i pilotirati digitalni i inovativni obrazovni paket u predškolskom obrazovanju u poučavanju i učenju umjetne inteligencije kroz pristup interaktivnog pripovijedanja temeljen na igrama;
- Obrazovati i ojačati profile učitelja predškolskog odgoja o tome kako poučavati umjetnu inteligenciju kroz inovativan pristup;
- Naučiti predškolsku djecu (3-6 godina) kako razumjeti UI kroz inovativan pristup;
- Suradivati s međunarodnim akterima kako bi se izgradili kapaciteti organizacija koje sudjeluju u području umjetne inteligencije za promicanje umjetne inteligencije u predškolskom obrazovanju u partnerskim zemljama kroz inovativni pristup;
- Podići svijest o važnosti umjetne inteligencije u obrazovanju u ranom djetinjstvu;
- Suradivati i umrežavati se s udrugama koje predstavljaju predškolske ustanove, obrazovne subjekte, sveučilišne predškolske odsjeke i odsjeke za pedagogiju te nevladine organizacije povezane s predškolskim odgojem kako bi se stvorilo modernije, dinamičnije, predanije obrazovanje vezano za budućnost.



Partneri



Szkoła Podstawowa im
Władysława Stanisława
Reymonta w Szczutowie

Poljska



DJEČJI VRTIĆ
VARAŽDIN

Dječji Vrtić Varaždin

Hrvatska



Základní škola Želiv,
okres Pelhřimov,

Češka Republika



EURASIA INSTITUTE

Euroazija

Turska



AGRUPAMENTO DE
ESCOLAS DE BARCELOS
EDUCAÇÃO PÚBLICA DE QUALIDADE

Agrupamento de Escolas
de Barcelos

Portugal



Dječja gradina "Radost"

Bugarska



Poglavlje 1

Umjetna inteligencija i njezin povijesni razvoj



Ishodi učenja

- Razlikovati poželjna i nepoželjna ponašanja tijekom učenja;
- Korištenje gotovih internetskih izvora za učenje;
- Učenje povijesnog razvoja umjetne inteligencije

Uvod

Današnja djeca vrlo često ranije počnu koristiti pametne telefone ili tablete nego što to rade s bojicama i priborom za pisanje, a svladavaju i sučelje koje vodi do njihovih omiljenih animiranih filmova i elektroničkih igrica. Djeca od malih nogu odrastaju u medijskom prostoru koji oblikuje njihovo ponašanje, maštu i svijet vrijednosti. Djeluju istovremeno u stvarnom okruženju i u virtualnom svijetu. Prema istraživanju, većina djece (64%) u dobi do 6,5 godina koristi mobilne uređaje (uključujući 62% igranje na pametnom telefonu ili tabletu), neki od njih svaki dan (25%). Sličan broj djece ove dobi (26%) ima mobilne uređaje. Ovu generaciju ne nazivaju bez razloga “djecom mreže”.

Zadaća odraslih je upoznati djecu sa sigurnom uporabom medijske tehnologije, uz razumijevanje i prepoznavanje njezine važnosti u njihovom budućem svakodnevnom, obrazovnom i profesionalnom životu. Istodobno, vrijedi poznavati područje umjetne inteligencije puno šire nego samo fokusirati se na njezinu primjenu u praktičnim obrazovnim ili radničkim aktivnostima.



Povijesni razvoj

Iako je pojam "umjetna inteligencija" skovan 1956. godine, danas je postao popularan zahvaljujući većem broju podataka, naprednim algoritmima i poboljšanjima računalne snage i memorije. Rana istraživanja umjetne inteligencije u 1950-ima pokrivala su teme kao što su rješavanje problema i simboličke metode



Šezdesetih godina prošlog stoljeća Ministarstvo obrane SAD-a zainteresiralo se za ovu vrstu aktivnosti i počelo obučavati računala da oponašaju osnovno ljudsko razmišljanje. Agencija za napredna obrambena istraživanja (DARPA), na primjer, provela je projekte mapiranja ulica 1970-ih.

Godine 2003. DARPA je stvorila i inteligentne osobne asistente, mnogo prije nego što su Siri, Alexa i Cortana postali poznati nazivi. Ovi rani naponi utrli su put automatizaciji i formalnom razmišljanju koje vidimo u današnjim računalima, uključujući sustave za podršku odlučivanju i inteligentne sustave pretraživanja koji se mogu dizajnirati da nadopune i povećaju ljudske sposobnosti.

Povijesni razvoj


Povijest umjetne inteligencije može se podijeliti u nekoliko razdoblja. Umjetna inteligencija potiče filozofska razmatranja i dokazuje valjanost mnogih koncepata. Duboko uvjerenje da u stroju možda postoji kreativni element - inteligencija ili svijest o postojanju, prati čovječanstvo od početka vremena. Umjetna inteligencija ima svoje područje istraživanja, istovremeno koristeći metode i tehnike iz mnogih područja, kako algoritamskih tako i nealgoritamskih. Klasični trend se temelji na logičkom programiranju, dok se trenutni inspiriran biologijom temelji na istraživanju strukture mozga, pokušaju korištenja genetskih algoritama i konstrukciji umjetnih sustava sa strukturom sličnom strukturi neurona ljudskog mozga.

Već sredinom 50-ih godina 20. stoljeća javljaju se prve ideje o stvaranju umjetne inteligencije, odnosno rješavanju problema za koje ne postoji algoritam koji vodi do rješenja. Ambiciozni projekti Allena Newella i Herberta Simona, uključujući "General Problem Solver" i druge, nisu doveli do stvaranja univerzalnih inteligentnih programa, ali su pomogli boljem razumijevanju složenosti problema i prirodne inteligencije. U to se vrijeme velika pažnja posvećivala području logike i načinima logičkog razumijevanja. Umjetna inteligencija tražila je algoritam razmišljanja i opća pravila za rješavanje problema po uzoru na prirodne ljudske aktivnosti i kognitivne procese, koristeći računalne programe koji ih potiču.

20. stoljeće


Otprilike 20 godina nakon što su poljski kriptolozi sa Sveučilišta u Poznańu razbili šifre njemačkog stroja za šifriranje Enigma, britanski matematičar Alan Turing postavio je pitanje: "Mogu li strojevi misliti?" U svom članku "Computing Machinery and Intelligence" (1950.) iznio je osnovnu svrhu i viziju umjetne inteligencije. Njegov glavni zadatak bio je stvoriti nadomjestak za ljudski um.

Poljski kriptolozi prvi su predstavili njemački stroj za šifriranje Enigma drugim strojevima. CSE je pripremio i izložbu koja predstavlja informatičku revoluciju koja se dogodila nakon Drugog svjetskog rata zahvaljujući marljivom radu kriptologa. Ova revolucija traje do danas, odnosno do ere u kojoj se umjetna inteligencija tako dinamično razvija.



21. stoljeće

S druge strane, tijekom drugog desetljeća 21. stoljeća razvijena su mnoga spektakularna rješenja koja pokazuju golemi potencijal umjetne inteligencije, uključujući sljedeće: 2016. Google DeepMind AlphaGo tim pobijedio je svjetskog prvaka u Go Lee Sadolu. Složenost drevne kineske igre ranije je prepoznata kao veliki izazov za UI. Hanson Robotics je 2016. godine razvio prvog humanoidnog robota nazvanog Sophia, koji je bio sposoban za prepoznavanje lica, verbalnu komunikaciju i izražavanje izraza lica. Godine 2018. Waymo je pokrenuo uslugu Waymo One koja je korisnicima koji se nalaze u gradskom području Phoenixa u Arizoni omogućila korištenje samovozećih automobila.



Umjetna inteligencija: Vremenska crta

1918

Prapovijesno doba za umjetnu inteligenciju. Razdoblje izvornih obrazaca umjetne inteligencije, od pojave prvog analitičkog stroja Charlesa Babbagea (1842.) do oko 1940. godine kada se pojavljuju programabilna računala.



1938

Razdoblje razvoja formalne logike i pojava interesa znanstvenika za eksperimentalnu psihologiju kao jedno od područja uključenih u izgradnju interdisciplinarnog polja umjetne inteligencije.



1954

Nastaje prvi računalni projekt. Ljudi s najvećim doprinosom razvoju umjetne inteligencije bili su H. Simon "Administrative Behavior", N. Wiener "Cybernetics", A. M. Turing "Computing Machinery and Intelligence", Macy - Cybernetics Conference, McCulloch i Pitts - istraživači perceptrona i neurosimilarnih mreže.



1960

Povećanje mogućnosti računala, uz istovremeni razvoj programskih jezika. Obraćanje pozornosti na psihologiju obrade informacija. Stvoren je prvi programski jezik "Information Processing Language (IPL - I)".



1970

So-called the romantic era of artificial intelligence (1961 - 1965), when it was predicted that artificial intelligence would achieve its goals within 10 years. There have been many initial successes. The activities of H. Simon who wrote "Human Problem Solving"; The LISP programming language is born; Heuristics (Shanon, Turing), robotics and chess programs are developed. The activities of H. Simon who wrote "Human Problem Solving"; The LISP programming language is born; Heuristics (Shanon, Turing), robotics and chess programs are developed.



1980

Takozvana romantična era umjetne inteligencije (1961. - 1965.), kada se predviđalo da će umjetna inteligencija postići svoje ciljeve u roku od 10 godina. Bilo je mnogo početnih uspjeha. Aktivnosti H. Simona koji je napisao "Rješavanje ljudskih problema"; Rođen je programski jezik LISP; Razvijaju se heuristika (Shanon, Turing), robotika i šahovski programi. Aktivnosti H. Simona koji je napisao "Rješavanje ljudskih problema"; Rođen je programski jezik LISP; Razvijaju se heuristika (Shanon, Turing), robotika i šahovski programi.




1990

Počinje komercijalna prodaja savjetodavnih sustava i njihovih univerzalnih svjetiljki. Razvijaju se objektno orijentirana tehnologija, neuronske mreže i metode prepoznavanja slika. Pojavljuju se strojevi za učenje - D. Lenat (Samuel, McCarthy) te sustavi Eurisco i Prospector (SRI). Održava se japanski projekt računala pete generacije.



Od
1990

Ovdje je razvoj kognitivnih znanosti, 3D grafike, računalnih mreža, virtualne stvarnosti, CSCW grupnih sustava suradnje, skriptnih jezika. Stvara se virtualni VRML protokol. Dolazi do razvoja računalnih metoda u prirodnom jeziku i prepoznavanju govora.



A blurred cartoon robot character is visible in the background. It has a blue head with large eyes, a yellow body, and red feet. The robot is standing and facing forward.

Poglavlje 2

Umjetna inteligencija i politike u EU



Ishodi učenja

- EU politike o umjetnoj inteligenciji;
- Propisi EU;

Uvod

Umjetna inteligencija (UI) je brzo razvijajuća obitelj tehnologija koja može pružiti širok raspon ekonomskih i društvenih koristi u nizu industrija i društvenih aktivnosti. Poboljšanjem predviđanja, optimiziranjem operacija i raspodjele resursa te personalizacijom pružanja usluga, korištenje umjetne inteligencije može doprinijeti korisnim ishodima za društvo i okoliš te pružiti konkurentske prednosti za poduzeća i europsko gospodarstvo. Takvo djelovanje posebno je potrebno u sektorima s velikim utjecajem, uključujući klimatske promjene, okoliš i zdravlje, javni sektor, financije, mobilnost, unutarnje poslove i poljoprivredu. Međutim, isti elementi i tehnike koji proizvode socioekonomske koristi umjetne inteligencije također mogu donijeti nove rizike ili negativne posljedice za građane i društvo. U svjetlu brzine tehnoloških promjena i mogućih izazova, EU je predan postizanju uravnoteženog pristupa. U interesu je Unije očuvati tehnološko vodstvo EU-a i osigurati da nove tehnologije, razvijene i kojima se upravlja u skladu s vrijednostima, temeljnim pravima i načelima Unije, budu u službi europskih građana.



Uvod - I

Predsjednica Ursula von der Leyen, koja je u svojim političkim smjernicama za 2019. – 2024. pod nazivom „Ambicioznija unija” najavila da će Komisija predstaviti zakonodavni prijedlog za koordinirani europski pristup implikacijama humanističkih znanosti i etike umjetne inteligencije. Nakon te najave, Komisija je 19. veljače 2020. objavila Bijelu knjigu o umjetnoj inteligenciji — Europski pristup izvrsnosti i povjerenju. Bijela knjiga postavlja opcije politike o tome kako postići dvostruke ciljeve promicanja prihvaćanja umjetne inteligencije i rješavanja rizika povezanih s određenim upotrebama ove tehnologije. Ovaj prijedlog ima za cilj provesti drugi cilj razvojem ekosustava povjerenja predlažući pravni okvir za UI povjerenja. Prijedlog se temelji na vrijednostima i temeljnim pravima EU-a i ima za cilj dati ljudima i drugim korisnicima samopouzdanje da usvoje rješenja temeljena na umjetnoj inteligenciji, dok istovremeno potiče tvrtke da ih razvijaju. Umjetna inteligencija mora biti alat u službi ljudi i pozitivna snaga za društvo s krajnjim ciljem povećanja dobrobiti ljudskih bića. Pravila primjenjiva na tehnologije umjetne inteligencije koje su stavljene na raspolaganje na tržištu Unije ili koja utječu na ljude u Uniji stoga bi trebala biti usmjerena na čovjeka kako bi ljudi mogli vjerovati da se tehnologija koristi na siguran način i u skladu sa zakonom, uključujući poštivanje temeljnih prava.

Regulatorni okvir

- Osigurati da su sustavi umjetne inteligencije koji se stavljaju na tržište Unije i upotrebljavaju sigurni i u skladu s postojećim zakonodavstvom o temeljnim pravima i vrijednostima Unije,
- Osigurati pravnu sigurnost kako bi se olakšala ulaganja i inovacije u području umjetne inteligencije,
- Olakšati razvoj jedinstvenog tržišta,




- Poboljšati upravljanje i učinkovitu provedbu postojećeg zakonodavstva o temeljnim pravima i sigurnosnim zahtjevima koji se primjenjuju na sustave umjetne inteligencije.

Europski pristup

Pristup EU-a umjetnoj inteligenciji usredotočen je na izvrsnost i povjerenje, s ciljem poticanja istraživačkih i industrijskih kapaciteta uz osiguranje sigurnosti i temeljnih prava.

Način na koji pristupamo umjetnoj inteligenciji (UI) definirat će svijet u kojem živimo u budućnosti. Kako bi pomogli u izgradnji otporne Europe za Digitalno desetljeće, ljudi i tvrtke trebali bi moći uživati u prednostima umjetne inteligencije dok se osjećaju sigurno i zaštićeno.

Europska strategija umjetne inteligencije ima za cilj učiniti EU središtem svjetske klase za umjetnu inteligenciju i osigurati da je umjetna inteligencija usmjerena na čovjeka i da je pouzdana. Takav se cilj pretvara u europski pristup izvrsnosti i povjerenju kroz konkretna pravila i akcije.



Europski pristup

- I

U travnju 2021. Komisija je predstavila svoj paket umjetne inteligencije koji uključuje:


- svoju komunikaciju o poticanju europskog pristupa umjetnoj inteligenciji;
- pregled Koordiniranog plana o umjetnoj inteligenciji (s državama članicama EU-a);
- svoj prijedlog uredbe kojom se utvrđuju usklađena pravila o UI (Zakon o UI) i odgovarajuću procjenu učinka.

Poticanje izvrsnosti u umjetnoj inteligenciji ojačat će potencijal Europe da se natječe na globalnoj razini.

EU će to postići:

- omogućavanje razvoja i prihvatanja umjetne inteligencije u EU-u;
- učiniti EU mjestom gdje umjetna inteligencija napreduje od laboratorija do tržišta;
- osiguravanje da umjetna inteligencija radi za ljude i da je snaga za dobro u društvu;
- izgradnja strateškog vodstva u sektorima s velikim utjecajem.

Komisija i države članice složile su se potaknuti izvrsnost u umjetnoj inteligenciji udruživanjem snaga u politici i ulaganjima. Revizija Koordiniranog plana o umjetnoj inteligenciji iz 2021. ocrtava viziju ubrzanja, djelovanja i usklađivanja prioriteta s trenutačnim europskim i globalnim krajolikom umjetne inteligencije i provedbe strategije umjetne inteligencije u djelo.




Europski pristup

- II

Maksimiziranje resursa i koordinacija ulaganja ključna je komponenta izvrsnosti umjetne inteligencije. Putem programa Horizon Europe i Digital Europe, Komisija planira uložiti milijardu eura godišnje u umjetnu inteligenciju. Mobilizirat će dodatna ulaganja iz privatnog sektora i država članica kako bi se dosegao godišnji obujam ulaganja od 20 milijardi eura tijekom digitalnog desetljeća.

Instrument za oporavak i otpornost stavlja na raspolaganje 134 milijarde eura za digitalno poslovanje. To će promijeniti pravila igre i omogućiti Europi da poveća svoje ambicije i postane globalni lider u razvoju vrhunske, pouzdane umjetne inteligencije.

Pristup visokokvalitetnim podacima bitan je čimbenik u izgradnji robusnih UI sustava visokih performansi. Inicijative kao što su Strategija kibernetičke sigurnosti EU-a, Zakon o digitalnim uslugama i Zakon o digitalnim tržištima te Zakon o upravljanju podacima pružaju pravu infrastrukturu za izgradnju takvih sustava.





Poglavlje 3

Osnovna načela umjetne inteligencije



Ishodi učenja

- Razumjeti značenje i dobit primjene umjetne inteligencije u obrazovnim aktivnostima;
- Koristite UI proizvode;
- Ocijenite dobiti kroz znanje.

Uvod

Umjetna inteligencija označava novi početak u evoluciji čovječanstva. Ona je sposobna potpuno promijeniti tradicionalni način funkcioniranja svakog društva. Neosporno je da je umjetna inteligencija veliki iskorak u znanstvenom i tehnološkom smislu te da može značajno pridonijeti razvoju i modernizaciji mnogih sfera ljudskog života. Međutim, da bi se to iskoristilo, moraju postojati jamstva za sigurnost i učinkovitost ovih sustava, a to se može osigurati samo stvaranjem pravnog okvira utemeljenog na etičkim vrijednostima i ljudskim pravima.

Dana 22. svibnja 2019. zemlje članice Organizacije za ekonomsku suradnju i razvoj (OECD) usvojile su Načela za umjetnu inteligenciju, međunarodne standarde koji imaju za cilj osigurati da su sustavi umjetne inteligencije dizajnirani tako da budu pouzdani i sigurni.



Uvod - II

Načela UI Organizacije za ekonomsku suradnju i razvoj (OECD) postavljaju standarde za umjetnu inteligenciju koji su dovoljno praktični i fleksibilni da izdrže test vremena u području koje se brzo razvija. Oni nadopunjuju postojeće standarde u područjima kao što su privatnost, upravljanje rizikom digitalne sigurnosti i odgovorno poslovno ponašanje.

Postoji pet načela utemeljenih na vrijednostima za odgovornu implementaciju pouzdane umjetne inteligencije i pet preporuka za vlade. Cilj im je voditi vlade, organizacije i pojedince u dizajniranju i upravljanju sustavima umjetne inteligencije na način koji interese ljudi stavlja na prvo mjesto i osigurava da su programeri i operateri odgovorni za njihovo ispravno funkcioniranje.

- 1) Uključiv rast, održivi razvoj i blagostanje
- 2) Vrijednosti usmjerene na čovjeka i pravednost
- 3) Transparentnost i objašnjivost
- 4) Robusnost, zaštita i sigurnost
- 5) Odgovornost

1. Princip: Uključiv rast, održivi razvoj i blagostanje

Ovo načelo naglašava potencijal pouzdane umjetne inteligencije da doprinese ukupnom rastu i prosperitetu za sve – pojedince, društvo i planet – i unaprijediti ciljeve globalnog razvoja.



Ovo načelo prepoznaje da je vođenje razvoja i korištenja umjetne inteligencije prema prosperitetu i korisnim ishodima za ljude i planet prioritet. Pouzdana umjetna inteligencija može igrati važnu ulogu u unapređenju uključivog rasta, održivog razvoja i dobiti te ciljeva globalnog razvoja. Doista, umjetna inteligencija se može koristiti za društveno dobro i može značajno doprinijeti postizanju ciljeva održivog razvoja (SDGs) u područjima kao što su obrazovanje, zdravstvo, promet, poljoprivreda, okoliš i održivi gradovi, među ostalima.

2. Princip: Vrijednosti i poštenje usmjerene na čovjeka

Sustavi umjetne inteligencije trebali bi biti dizajnirani na način koji poštuje vladavinu prava, ljudska prava, demokratske vrijednosti i raznolikost te bi trebali uključivati odgovarajuće zaštitne mjere kako bi se osiguralo pošteno i pravedno društvo.



Umjetnu inteligenciju treba razvijati u skladu s vrijednostima usmjerenim na čovjeka, kao što su temeljne slobode, jednakost, pravednost, vladavina prava, socijalna pravda, zaštita podataka i privatnost, kao i prava potrošača i komercijalna pravednost.

Neke primjene ili upotrebe sustava umjetne inteligencije imaju implikacije na ljudska prava, uključujući rizike da ljudska prava (kako su definirana u Općoj deklaraciji o ljudskim pravima) i vrijednosti usmjerene na čovjeka mogu biti namjerno ili slučajno povrijeđeni. Stoga je važno promicati "usklađivanje vrijednosti" u sustavima umjetne inteligencije, tj. njihov dizajn s odgovarajućim zaštitnim mjerama.

3. Princip: Transparentnost i objašnjivost

Ovo se načelo odnosi na transparentnost i odgovorno otkrivanje oko sustava umjetne inteligencije kako bi se osiguralo da ljudi razumiju kada su u interakciji s njima i mogu osporiti ishode.



Pojam transparentnost ima više značenja. U kontekstu ovog načela, fokus je prvo na otkrivanju kada se koristi umjetna inteligencija (u predviđanju, preporuci ili odluci ili da korisnik izravno komunicira s agentom umjetne inteligencije, kao što je chatbot). Otkrivanje treba biti razmjerno važnosti interakcije. Rastuća sveprisutnost UI aplikacija može utjecati na poželjnost, učinkovitost ili izvedivost otkrivanja u nekim slučajevima.

Transparentnost nadalje znači omogućiti ljudima da razumiju kako se sustav umjetne inteligencije razvija, obučava, radi i postavlja u relevantnoj domeni aplikacije, tako da potrošači, na primjer, mogu donositi bolje informirane odluke.

4. Princip: Robusnost, zaštita i sigurnost


Sustavi umjetne inteligencije moraju funkcionirati na robustan, siguran i siguran način tijekom svog životnog vijeka, a potencijalne rizike treba kontinuirano procjenjivati i njima upravljati.




Rješavanje sigurnosnih i sigurnosnih izazova složenih UI sustava ključno je za poticanje povjerenja u UI. U ovom kontekstu, robustnost označava sposobnost izdržavanja ili prevladavanja nepovoljnih uvjeta, uključujući digitalne sigurnosne rizike. Ovo načelo dalje navodi da sustavi umjetne inteligencije ne bi trebali predstavljati nerazumne sigurnosne rizike, uključujući fizičku sigurnost, u uvjetima normalne ili predvidljive upotrebe ili zlouporabe tijekom njihovog životnog ciklusa. Postojeći zakoni i propisi u područjima kao što je zaštita potrošača već identificiraju što predstavlja nerazumne sigurnosne rizike. Vlade u dogovoru s dionicima moraju odrediti u kojoj se mjeri primjenjuju na sustave umjetne inteligencije.

5. Princip: Odgovornost

Organizacije i pojedinci koji razvijaju, implementiraju ili upravljaju sustavima umjetne inteligencije trebali bi se smatrati odgovornima za njihovo ispravno funkcioniranje u skladu s OECD-ovim načelima utemeljenim na vrijednostima za umjetnu inteligenciju.



Pojmovi odgovornost, odgovornost i odgovornost blisko su povezani, ali različiti, a također imaju različita značenja u različitim kulturama i jezicima. Općenito govoreći, "odgovornost" podrazumijeva etička, moralna ili druga očekivanja koja usmjeravaju radnje ili ponašanje pojedinaca ili organizacija i omogućuju im da objasne razloge zbog kojih su odluke i radnje poduzete. U slučaju negativnog ishoda, to također podrazumijeva poduzimanje radnji kako bi se osigurao bolji ishod u budućnosti. "Odgovornost" se općenito odnosi na nepovoljne pravne implikacije koje proizlaze iz radnji ili nedjelovanja osobe (ili organizacije). "Odgovornost" također može imati etička ili moralna očekivanja i može se koristiti u pravnim i nepravnim kontekstima za upućivanje na uzročnu vezu između aktera i ishoda.

A blurred cartoon robot character is visible in the background. It has a blue head with large eyes, a yellow body, and red feet. The robot is positioned centrally behind the text box.

Poglavlje 4

Pristup interaktivnog priповijedanja temeljen na igri u nastavi umjetne inteligencije



Ishodi učenja

- Razumjeti kako robot radi;
- Upotreba konstruira tijekom radnje za robota da postigne cilj;
- Procijenite pogrešan postupak za robota.

Lekcija broj 1: Upoznajte Alberta






Bok, moje ime je
Albert.
Ja sam robot. Mogu li
biti tvoj prijatelj?

Brainstorming – Pitanja – Mentalna
mapa

- Znaate li što je robot?
- Kako robot radi?
- Što znači "programiranje"?
- Gdje se možemo susresti s ovom riječi (s programiranjem)?
- Zašto moramo naučiti programirati?
- Tko je programer?
- Što radi programer?

Lekcija br.1



Putovanje webom – prvi dio

1. TPR motivacija: Djeca će postati roboti nakon što izgovore čaroliju:

Elektron se ugasio.

Žice se zatežu u glavi.


Baterija, krug,

Napravi me robotom.

2. Nakon ovoga djeca se kreću po razredu kao roboti i mi im dajemo upute:

Naš je robot izgubio srčanu antenu. Možete li ga pronaći? Budite oprezni, roboti moraju slijediti strelice.

Lekcija br.2



Nacrtaj mog prijatelja.
Poslušajte/pročitajte
kako izgleda moj
prijatelj.

Crtanje diktata (CLIL engleski – oblici, boje, brojevi)

Moje tijelo je velikipravokutnik. (potpuna boja po želji)


Umjesto nogu imam dva kotača.

Moje ruke su dva spojenapravokutnika s dva prsta.

Moja glava jekvadrat. Imam dva oka i četvrtasta usta.

Nemam nos, a uši mi izgledaju kao opruge.


Lekcija br.2



Aktivnost refleksije

Kontrolirajte svoj rad zajedno!

Lekcija br.2



Putovanje webom – drugi dio

1. TPR motivacija: Djeca će postati roboti nakon što izgovore čaroliju:

Elektron se ugasio.

Žice se zatežu u glavi.

Baterija, krug,

Napravi me robotom.

2. Nakon ovoga djeca se kreću po razredu kao roboti, a mi im dajemo upute.

3. Rad u parovima. Jedan od vas je robot, a jedan će biti programer:


Koristit ćete papirnate strelice i pripremiti putove u mreži.

Pronalazite puteve do svog srca robota.

Strelice se pomiču ispred vaše mreže u jednu liniju.

Jedan od vas je robot i kreće se mrežom. Jedan je programer i govori vam kako ste vas dvoje programirali.

Lekcija br.3



Upoznaj moje
prijatelje:
Bluebotovi



Crtanje diktata (CLIL engleski – oblici, boje, brojevi)

Moje tijelo je velikipravokutnik. (potpuna boja po želji)

Umjesto nogu imam dva kotača.

Moje ruke su dva spojenapravokutnika s dva prsta.

Moja glava jekvadrat. Imam dva oka i četvrtasta usta.

Nemam nos, a uši mi izgledaju kao opruge.

Lekcija br.3

Putovanje webom – treći dio

1. TPR motivacija: Djeca će postati roboti nakon što izgovore čaroliju.



Elektron se ugasio.
Žice se zatežu u glavi.
Baterija, krug,
Napravi me robotom.

2. Nakon ovoga djeca se kreću po razredu kao roboti, a mi im dajemo upute.


3. Rad vlastiti.

Koristit ćete strelice i pripremiti putove na prozirnoj prostirci s džepovima za vašeg bluebota. Pronaći ćete put do svog srca robota.
Strelice se pomiču ispred vaše mreže u jednu liniju.

Upravlajte svojim bluebotom.
Gledajte stazu svog bluebota.



Lekcija br.3



Aktivnost refleksije

Je li vaš bluebot bio u pravu?



Poglavlje 5

Umjetna inteligencija i poslovi budućnosti



Ishodi učenja

- Razumjeti prilike za posao koje umjetna inteligencija pruža;
- Dobijte informacije o UI budućim mogućnostima zapošljavanja;
- Razgovarajte o osnovama sektorskih zahtjeva

Uvod

Ponuda tržišta rada i potražnja za radnicima, te njihovo zapošljavanje i otpuštanje, elementi su tržišta rada. Otvaranje granica otvara i veće mogućnosti zapošljavanja, ali i veću konkurenciju, a time i nesigurnost radnih mjesta. Razvoj tehnologije dovodi do novog načina rada. Sve više tvrtki radi od kuće. U tome vide olakšanje za troškove režija. Uz samo jedan dan u tjednu kada je ured zatvoren, a radnici rade od kuće, ostvaruju se uštede energije, što je opće mjesto u razmišljanjima o budućnosti i korištenju alternativnih izvora energije. Radnik koji ne radi na stroju u tvornici ili odgajateljice koje rade u vrtiću naravno ne mogu raditi od kuće, ali sve je više radnih mjesta na kojima se radi pomoću računala i interneta. Čini se da su takva zanimanja u prednosti jer radom od kuće mogu ostvariti uštede ne samo za poslodavca već i za sebe.




Uvod - I

Istodobno, ovdje se nameće izazov očuvanja drugih radnih mjesta koja su neminovno ugrožena tuđim radom od kuće: vozač tramvaja, vlaka i autobusa, prodavač u pekarnici u blizini tvrtki čiji radnici dijelom rade od kuće itd. Otvaranjem granice, sve je lakše tražiti posao u susjednoj zemlji u kojoj su ekonomski uvjeti bolji, a tržište rada nudi veće mogućnosti. No, koja su to zanimanja koja nam mogu omogućiti lako zapošljavanje u budućnosti? Pregledom podataka dostupnih na internetu o najbolje plaćenim poslovima u svijetu, ali i u Europi, prvih deset zanimanja su bez iznimke softverski inženjer, JavaScript developer, projekt menadžer, cloud inženjer, službenik, arhitekt rješenja . Sva ova zanimanja su iz područja umjetne inteligencije, sigurno je da će se takav trend nastaviti i u budućnosti. Naime, umjetna inteligencija uključena je u sve više poslova, a stručnjaci iz područja umjetne inteligencije i danas su traženi i nemaju poteškoća sa zapošljavanjem u gotovo svim dijelovima svijeta.

UI i budući poslovi u EU

Eurostat procjenjuje da je u srpnju 2022. godine bilo gotovo 13 milijuna nezaposlenih, što je blagi pad nezaposlenosti u odnosu na prethodnu godinu. Nezaposlenost je najveća u Španjolskoj i Francuskoj, a najnižu stopu nezaposlenosti imaju Češka i Poljska. U Hrvatskoj je stopa nezaposlenosti 6 posto. Zabrinjava podatak da je stopa nezaposlenih mladih dvostruko veća od opće stope nezaposlenosti, a žene su također ranjivija skupina i 15 posto manje zaposlene od muškaraca.



Povećanje životnog vijeka, ali i smanjenje nataliteta u EU dovodi do starenja stanovništva, a time i do smanjenja broja radnika. Očekuje se da će se broj zaposlenih odraslih osoba smanjiti za oko 15% u sljedećih 50 godina. Jednostavna računica pokazuje sljedeće: 2050. godine omjer zaposlenih i umirovljenika bit će 1:2, što je alarmantna brojka. Europa rješenje vidi u cjeloživotnom učenju, ali i u kvalitetnom obrazovanju za potrebe tržišta rada te u smanjenju stope ranog odustajanja od obrazovanja. Današnji podaci pokazuju da čak 16 posto mladih odustane od obrazovanja, posebice u mediteranskim zemljama. S druge strane, u razvijenim demokracijama sjeverne Europe ta je stopa minimalna, kao i u nekim zemljama srednje i istočne Europe.

UI i budući poslovi u EU - I

Sigurno je da će se u budućnosti najlakše zapošljavati u području umjetne inteligencije te je stoga Europski parlament osnovao Odbor za umjetnu inteligenciju u digitalnom dobu kako bi ispitao utjecaj tehnologije na život pojedinca i društva. Istraživanje je pokazalo da će se upravo zahvaljujući umjetnoj inteligenciji i njezinoj primjeni u medicini poboljšati zdravstvena skrb građana. Već smo danas svjedoci slučajeva kada se složene operacije, primjerice operacije srca, izvode na daljinu, koristeći znanja stručnjaka koji su tisućama kilometara udaljeni od pacijenta. Pristup informacijama je svakim danom sve lakši za svakog građanina. Umjetna inteligencija se koristi i sve će se više koristiti u teškim i opasnim zanimanjima. UI će olakšati transport proizvoda unutar EU, a također će pomoći u uštedi energije. Isto tako, korisnička služba postaje bolja zahvaljujući umjetnoj inteligenciji.

UI i poslovi budućnosti u EU - II





No, umjetna inteligencija ima i izazove s kojima ćemo se sigurno susresti u bliskoj budućnosti. Primjerice, brze blagajne u trgovinama, koje kupac sam koristi, doista ubrzavaju uslugu, ali istovremeno ugrožavaju posao blagajnika. Ako se UI ne koristi mudro, to može dovesti do otpuštanja. Jedna od opasnosti svakako je utjecaj umjetne inteligencije na demokratske procese. Umjetna inteligencija može pridonijeti stvaranju lažne slike temeljene na prošlom ponašanju na internetu, ali i pridonijeti realističnim lažnim videozapisima i slikama.

Umjetna inteligencija će u budućnosti otvoriti niz novih radnih mjesta, ali može pridonijeti i ukidanju velikog broja radnih mjesta. Načini na koje ćemo koristiti umjetnu inteligenciju u budućnosti ovisi o nama, stoga su obrazovni sustavi pojedinih zemalja odgovorni za stvaranje odgovornih korisnika interneta i raznih web alata, kao i za edukaciju potrebnih stručnjaka u području UI.

Obrazovanje i umjetna inteligencija

Budući da je budućnost tržišta rada u Europi neizvjesna, obrazovni sustavi imaju veliku odgovornost kvalitetnim programima iz područja umjetne inteligencije doprinijeti radnoj snazi koja bi današnjoj djeci pomogla u njihovoj konkurentnosti na tržištu rada za dvadesetak godina. Sigurno je da će se otvoriti veliki broj radnih mjesta za stručnjake iz područja umjetne inteligencije, a takva bi se radna mjesta trebala otvarati od njihovog uključivanja u obrazovni sustav, od polaska u vrtić. Naravno, dijete predškolske dobi treba učiti kroz igru, koristeći različite web alate primjerene njegovoj dobi i njegovim kompetencijama. Za to su nam prije svega potrebni dobro educirani učitelji iz područja koje želimo predavati. Cjeloživotno učenje postaje obveza, čak i nakon završenog formalnog obrazovanja učitelji se trebaju kontinuirano educirati kako bi što kompetentnije odgovorili na zahtjeve za obrazovanjem najmlađih koji već odrastaju okruženi umjetnom inteligencijom.





Poglavlje 6

Implementacija plana kurikuluma


Uvod

Umjetna inteligencija glavni je izvor rasta i inovacija u svim industrijama, a obrazovni sektor nije ništa drugačiji. Prema studiji industrije eLearning Industry, oko 47% alata za upravljanje učenjem povezanih s UI mogućnostima bit će iskorišteno u sljedeće tri godine.

Međutim, rješenja podržana umjetnom inteligencijom oduvijek su prisutna; industrija je sporo sustigla i integrirala nove alate u sektor. Pandemija je vjerojatno najgore iskustvo koje je čovječanstvo doživjelo u posljednjem desetljeću, a ako iz nje trebamo uzeti nešto pozitivno, to bi trebala biti transformacija obrazovnog krajolika. Profesori su bili prisiljeni prijeći s konvencionalnog načina nastave na virtualno učenje. U početku je to bilo forsirano, ali sada 86% edukatora navodi da bi tehnologija trebala biti temeljni dio obrazovanja. UI ima sposobnost optimizirati i učenje i poučavanje dok istovremeno koristi učenicima i učiteljima.



Uvod - II



Pripovijedanje je dokazana metoda u obrazovnom sektoru i prije nego što je tehnologija u njemu pronašla svoje mjesto. Zapravo, MacDonald (1998) je u svojoj studiji objasnio da su društva koristila pripovijedanje za podučavanje. Na istom tragu, Andrews et al. (2009) ukazuje da je pripovijedanje u okviru obrazovanja svih vrsta, stomatologije, opće medicine, prava i poslovanja.


S uključivanjem tehnologije u naše živote u ovom stoljeću, pripovijedanje je dobilo novi oblik. Integracija digitalnih medija kao što su video, audio datoteke, kao i slike su glavni dio metode pod nazivom intelektualno pripovijedanje. Međutim, nije ograničeno na ove elemente, mogu se koristiti karte i društveni elementi poput tweetova. Učionice sve više prihvaćaju intelektualno pripovijedanje. Prema Smeda i sur. (2014), digitalno pripovijedanje je inovativan pedagoški pristup koji može uključiti učenike u duboko i smisleno učenje".

Nadalje, digitalno pričanje priča dokazalo je svoj potencijal kao snažan alat za poučavanje i učenje za uključivanje nastavnika i učenika (Robin, 2008). Profesori i nastavnici mogli bi kapitalizirati intelektualne priče kako bi potaknuli interes i angažman učenika. Mogućnost pribjegavanja različitim stilovima učenja još je jedan faktor za povećanje interesa za razred i stjecanje novih skupova vještina kao što su sinteza, analiza i evaluacija.

Kao što se može shvatiti iz prethodne dvije metode, učenje samo iz udžbenika je staromodno. Učenje temeljeno na igri (GBL) još je jedna perspektiva i postaje sve popularnija kao pomoć učenicima na putu postizanja nastavnih ciljeva. Koristi snagu i kreativnost igara za postizanje ishoda učenja na nevjerojatno drugačiji način. Svoje ciljeve postiže edukativnim igrima kao što su angažman, neposredne nagrade i zdravo natjecanje. Stoga učenici ostaju motivirani za učenje dok se zabavljaju.

Cilj nastavnog plana i programa

Akcijski plan za digitalno obrazovanje (DEAP) za 2021.-27. pokazuje da je umjetna inteligencija u obuci nastavnika temeljna za budući razvoj. DEAP ukazuje da budući da su nastavnici u fazi poučavanja i prvi resurs za učenike, njihovo osnaživanje i jačanje njihovih profila je neophodno. Naše istraživanje koje su proveli članovi konzorcija među odgojiteljima pokazuje da odrastanje uz ICT nije dovoljno za razvoj digitalnih vještina potrebnih za odgoj nove generacije.



Suočavajući se s novim društvenim i digitalnim kontekstom, jasno je da moramo stvoriti nove nastavne planove i programe koji su u stanju ponuditi nove pristupe poučavanju i učenju, odgovarajuće platforme za učenje, resurse i iskustva koja našim učiteljima pružaju znanje i vještine za obrazovanje mlađe generacije u područjima umjetne inteligencije koja se razvijaju.

Očekivani utjecaj i ciljne skupine

Kurikulum će koristiti odgojitelji predškolskog odgoja. Budući da će se nastavni planovi i programi provoditi u 6 različitih zemalja EU-a u 18 različitih predškolskih ustanova, učinak će biti vidljiv u smislu stečenih vještina i kompetencija. Učinak će se mjeriti putem intervjua i online upitnika.

Odgojitelji;

Predškolske ustanove;

Izrađivači nastavnih planova i programa;

Sveučilišni odjeli za predškolski odgoj;

učitelji IKT-a;

Predškolske odgojno-obrazovne udruge.



Planiranje nastavnog plana i programa

Learning Topics	Course Description	Teaching Methodology	Learning Outcomes	Units	Focus Questions	Key Concepts	Assessment Tasks
Learning Topic-1							
Learning Topic-2							
Learning Topic-3							

1) General Aspects of the Lesson Plan

Curriculum field/Subject:	Grade:	Date:
Preparation:		
Implementation:		
Learning Outcomes:		
New Teaching and Learning Approaches:		

Planiranje nastavnog plana i programa - I

2) Specific Aspects of the Lesson Plan

Unit:

Key Words:

Teaching Strategies and Method:

Resources, concretization tools and teaching materials:

Tools for assessing and evaluating the learning outcomes:

3) Description of the Methodology and the Work with Students During the Lesson (Short description for: activities in the initial stage; activities/practical work facilitated by the teacher (modeling, demonstration, instruction..); interactive activities with students and students' independent work)

Assessing students for the achievement of lesson results:

Follow up- homework and independent work:

Reflection on the course of the lesson:

Smjernice

Glavna ideja iza ove razine planiranja je identificirati mogućnosti za razvoj ključnih kompetencija i planiranje mjera za podršku svim učenicima da postignu sve ishode učenja. Koraci koje trebaju poduzeti učitelji:

- Analizira sve ishode učenja unutar temeljnih kompetencija,
- Identificira mogućnosti učenja,
- Identificira čimbenike koji mogu spriječiti razvoj kompetencija,
- Predlaže rješenja za izbjegavanje čimbenika koji mogu spriječiti razvoj kompetencija,
- Planira alternativne oblike učenja - dopunsko učenje, dodatno učenje, izvannastavne aktivnosti, posebne projekte i sl.
- Određuje razdoblje izvještavanja i oblik izvještavanja o napretku razvoja kompetencija.

Priprema planova

Proces planiranja zahtijeva izradu kurikulumskih dokumenata (osnovni kurikulum, planiranje nastave, nastavni plan i program predmeta, kalendar školske godine, izvješća o radu itd.), aktivno sudjelovanje svih nastavnika tog relevantnog područja, predmeta i razreda.

Sljedeće elemente treba analizirati i pregledati:

- iskustva nastavnika vezana uz teme predmeta
- nove teme koje će se prvi put predstaviti
- međusobno povezivanje tema s drugim predmetima
- minimalno vrijeme nastave
- mogućnosti koje nudi škola

Smjernice - I

Teme učenja - odabrane teme

Ishodi učenja - može biti jedan ili više rezultata

Nastavne teme - ovisno o broju tema u nastavnom planu, plan se može podijeliti na nastavne teme

Cjelina(e) - cjeline i njihov broj definiraju i razrađuju sami nastavnici vodeći računa o ishodima učenja predviđene teme. Za predmetni ishod učenja može postojati jedna lekcija ili više njih. Nastavnik utvrđuje one cjeline koje su bitne za postizanje predmetnih ishoda učenja i koje doprinose postizanju terenskih ishoda učenja.

Potrebno vrijeme - nastavnik sada odlučuje koliko je vremena/sati potrebno, kroz jedinice, da bi se postigli ishodi učenja predmeta.

Metodika poučavanja – u tom dijelu obrazlaže se metodika poučavanja koja će se koristiti tijekom obrade teme uz navođenje nekih od metodičkih pristupa, metoda i tehnika interaktivne nastave relevantnih za temu/predmet koji pomažu učenicima u postizanju ciljanih ishoda učenja. s planom nastave. Na primjer, promatranje prirode, tematske izložbe, debate, igre itd.

Ocjenjivanje - u ovom odjeljku se odlučuje o tehnikama ocjenjivanja postignuća učenika kako bi se potvrdio plan postignuća učenika i usmjerila potpora učenju učenika. Tehnika ovisi o specifičnostima ishoda učenja predmetne teme.

Smjernice - II

Međuodnos s drugim predmetima i životnim situacijama - ovaj odjeljak ukratko opisuje s kojim predmetom(ima), s kojim međunastavnim pitanjima i/ili životnim situacijama će se svaka tema povezati, odnosno lekcije koje se planiraju razviti.

Resursi - potrebno je navesti resurse koje su nastavnici i učenici koristili za postizanje određenih ciljeva/rezultata. Mogu se koristiti različiti resursi:

- Pisani izvori kao što su udžbenici, novine, časopisi i dokumenti
- Elektronički resursi kao što su internet, web stranica, TV kanal, radio, platforme za e-učenje
- Različiti izvori iz svakodnevnog života

Priprema plana nastave

U dnevniku dnevnog planiranja/razrednici nastavnik opisuje svoj plan. Svrha plana lekcije je primijeniti ga na učenike u učionici, ali i izvan učionice. Format planiranja lekcije predložen u priručniku za provedbu kurikuluma organiziran je u tri odjeljka:

- Opći aspekti nastavnog plana
- Specifični aspekti nastavnog plana - potrebni elementi su pažljivo sastavljeni, u odnosu na ishode učenja koji se odražavaju u općem pregledu.
- Opis metodike i aktivnosti učenika tijekom nastave - u ovom dijelu nastavnik daje kratak opis aktivnosti(a) u uvodnoj fazi; aktivnost koju vodi/facilitira nastavnik ili praktičan rad (modeliranje, demonstracija, poduka...); interaktivne aktivnosti s učenicima i samostalni rad učenika te tehnike ocjenjivanja. Sve aktivnosti rada s učenicima opisane u ovom odjeljku trebale bi biti usmjerene na postizanje ishoda učenja po učionici i doprinos drugim ciljanim ishodima.

Smjernice III

Odgajatelj treba nastavu kroz igru integrirati u rad i svakodnevni život djece kako bi ona pravilno razumjela.


Aktivnost - nakon analize informacija/smjernica danih o pripremnim kurikulumima za školske programe za provedbu kurikuluma, raspravite sa svojim kolegama:

- Koliko i kako se te smjernice odražavaju u vašoj trenutnoj praksi planiranja provedbe kurikuluma?
- Kako će se ove smjernice i direktive koristiti za poboljšanje kvalitete planiranja lekcija i njihove provedbe u učionici i izvan nje?



Dodatne igre

Plesni robot



Cilj: Predstaviti djeci rane i predškolske dobi princip robota te kako se roboti kreću na zabavan i angažiran način

Potrebni materijali:

- prostor za plesanje (unutra ili vani)
- Muzička linija sa pjesmama na temu robota (na primjer „Robot Rock“ autor Daft Punk)
- rekviziti na temu Robota (na primjer maske od kartona u obliku robota)

Trajanje: Otprilike 30 minuta

Plan lekcije:


Predstavljanje (5 minuta):

- 1.Okupite djecu u krug, sjedeći ili stojeći)
- 2.Započnite s pitanjem da li znaju što je robot i jesu li ga vidjeli u filmu, knjizi ili crtanom filmu.
- 3.Objasnite da će danas učiti o robotima i čak postati roboti kroz zabavnu plesnu aktivnost.

Aktivnost 1-Robotski ples (15 minuta):

- 1.Pustite pjesmu na temu robota na muzičkoj liniji.
- 2.Pokažite djeci kako izgledaju pokreti koji oponašaju robota: krute ruke, robotski koraci i mehaničko okretanje.
- 3.Ohrabrite djecu da imitiraju pokrete robota za vrijeme plesa uz muziku.
- 4.Možete pokazati različite pokrete poput „robotske ruke“, „robotsko okretanje“, i potaknite djecu da imitiraju pokrete.
- 5.Obogatite igru predstavljanjem robota s posebnim odlikama, poput robota koji može pokupiti imaginarnu stvar ili plesati usporeno.

Plesni robot - I



Rasprava (5 minuta):

1. Okupite djecu u krug.
2. Pitajte ih kako su se osjećali kad su plesali poput robota.
3. Raspravljajte s djecom o tome što robote čini drugačijima od ljudi, ukažite na činjenicu kako robot prati upute i može izvršavati ponavljajuće zadatke.
4. Objasnite da u stvarnom životu, inženjeri i znanstvenici kreiraju robote i programe za obavljanje specifičnih poslova.

Aktivnost 2- Robot Majstor (5 minuta, izborna):

1. Ako vrijeme dozvoljava i pripremili ste robotske rekvizite, dozvolite djeci da kreiraju vlastite robot-maske ili dodatke koristeći karton i zanatske dodatke.
2. Ohrabrite djecu da ukrase svoje robote što kreativnije.
3. Ova zanatska aktivnost ohrabruje ideju kako se roboti mogu izraditi i prilagoditi.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o robotima i njihovim pokretima.
2. Spomenite da su roboti mašine koje su kreirali ljudi kako bi im oni pomogli u različitim zadacima.
3. Potaknite djecu da podijele s ostalima svoje vlastito iskustvo i što im se najviše dopalo u ovoj aktivnosti.
4. Dajte im do znanja da mogu istraživati sve više i više o robotima kako će odrastati.

Procjena:

Nema formalne procjene za ovu lekciju obzirom da je dizajnirana za djecu rane i predškolske dobi kako bi ona istraživala i uživala u konceptu robota kroz igru i kretanje.

Dodatne aktivnosti:


Pročitajte jednostavnu priču na temu robota.

Pogledajte kratak video o robotima u stvarnom životu (na primjer roboti koji se koriste u tvornicama ili u istraživanju svemira) kako biste proširili razumijevanje djeteta

Ohrabrite djecu da nacrtaju vlastitog robota.

“Ova lekcija kombinira tjelesne aktivnosti, kreativnost i diskusiju kako bi djetetu rane i predškolske dobi približili koncept robota na zabavan i pamtljiv i nezaboravan način”.

Razvrstavanje oblika



Cilj: Predstaviti djeci rane i predškolske dobi načelo klasifikacije predmeta temeljem njihovog oblika i boje.

Potrebni materijal:

- predmeti različitih oblika i boja (na primjer obojene kocke, autići igračke, plastične životinje)
- pladnjevi za sortiranje ili kutije (dovoljno za svako dijete ili grupu)
- velika kutija ili prostirka za sortiranje
- etikete ili fotografije oblika i boja (izborna)
- muzička linija (izborna)

Trajanje: otprilike 30-45 minuta


Predstavljanje (5 minuta):

- 1.Okupite djecu u krug sjedeći ili stojeći
- 2.Započnite pitanjem da li znaju što je to oblik i znaju li imenovati neke oblike (krug, kvadrat, trokut, itd)
- 3.Objasnite da će danas učiti o razvrstavanju i klasifikaciji predmeta na osnovi njihova oblika i boje, upravo kako računalo i robot mogu razvrstavati stvari.

Aktivnost 1- Sortiranje oblika (15-20 minuta):

- 1.Smjestite različite objekte različitih oblika i boja u centar sobe.
- 2.Objasnite djeci da je njihov zadatak razvrstati predmete prema njihovom obliku ili boji.
- 3.Možete pokazati kako to učiniti razvrstavanjem nekoliko predmeta.
- 4.Ohrabrite djecu da rade samostalno ili u paru kako bi razvrstali predmete u kutije ili na prostirku.
- 5.Izborna, možete ponuditi fotografije predmeta različitih oblika i boja kako biste ih vodili.

Razvrstavanje oblika - I



Rasprava (5 min):

1. Okupite djecu i zamolite da predstave drugima kako su razvrstali predmete.
2. Razgovarajte o njihovim strategijama razvrstavanja (na primjer grupiranje svih crvenih predmeta ili spremanje svih kvadratnih predmeta u istu kutiju)
3. Objasnite djeci da upravo tako kako su oni razvrstali predmete, računala i roboti koriste algoritme za razvrstavanje i klasifikaciju.

Aktivnost 2- Ples razvrstavanje (5 minuta, izborna):

1. Ako imate dovoljno vremena i želite dodati elemente za igranje, možete pokrenuti muziku i potaknuti djecu na „ples razvrstavanja“
2. Kažite oblik ili boju, a kad to kažete, djeca trebaju otplesati prema tom predmetu ili boji, pokazujući da razumiju načelo razvrstavanja.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o razvrstavanju i klasifikaciji predmeta.
2. Spomenite da računala i roboti koriste slične metode za organizaciju informacija.
3. Potaknite djecu da podijele s drugima najdraži dio ove aktivnosti.

Procjena:


Nema formalne procjene za ovu lekciju jer je dizajnirana za predstavljanje načela razvrstavanja i klasifikacije djetetu rane i predškolske dobi kroz igru.

Dodatne aktivnosti:

- pročitajte priču o razvrstavanju ili kategorizaciji predmeta
- kreirajte „Lov na oblike i boje“ gdje djeca traže predmete u okolini sa specifičnim traženim oblikom ili bojom
- ponudite više zahtjevnijih predmeta za razvrstavanje kako će djeca postajati sigurnija u svoje vještine

“Ova lekcija kombinira praktične aktivnosti i diskusiju kako bi pomogla djetetu rane i predškolske dobi da razumije načelo razvrstavanja i klasifikacije predmeta, što je fundamentalno načelo u računalnoj znanosti i umjetnoj inteligenciji”.

Prepoznavanje uzorka



Cilj: Predstaviti djeci rane i predškolske dobi načelo prepoznavanje i ponavljanja uzorka.

Potrebni materijal:

- predmeti u boji (na primjer kocke u boji, naljepnice)
- velika prozirna površina za kreiranje uzoraka (na primjer ploča, pod)
- fotografije jednostavnih uzoraka (izborna)

Trajanje: Otprilike 30 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug
- 2.Započnite pitanjem da li netko zna što je uzorak.
- 3.Objasnite da će danas učiti kako organizirati i kreirati uzorke, upravo na način kako računalo organizira uzorke u bazi podataka.


Aktivnost 1- Kreiranje uzorka (10-15 minuta):

- 1.Pokažite djeci kako kreirati jednostavan uzorak korištenjem predmeta u boji (na primje crveni, plavi, crveni, plavi)
- 2.Zamolite ih da se izmjenjuju u kreiranju njihovog uzorka korištenjem istih predmeta.
- 3.Ohrabrite ih da krenu s jednostavnim uzorkom, a onda neka pokušaju sa složenijim.

Aktivnost 2- Prepoznavanje uzorka (10-15 minuta):

- 1.Pokažite fotografiju jednostavnog uzorka (na primjer ABAB, ABCABC).
- 2.Pozovite djecu da identificiraju uzorak i da ga nastave.
- 3.Razgovarajte kako mogu prepoznati i kompletirati uzorak.

Prepoznavanje uzorka - I




Rasprava (5 minuta):

1. Okupite djecu i zamolite ih da podijele sa ostalima što su naučili o uzorcima.
2. Objasnite da računala i roboti mogu prepoznati i kreirati uzorke u bazi podataka.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o prepoznavanju i kreiranju uzorka.
2. Spomenite kako je ta vještina slična onome što računalo i robot rade pri istom zadatku.
3. Pozovite djecu da podijele omiljene dijelove aktivnosti s drugima.

Napravi robota



Cilj: Predstaviti djeci rane i predškolske dobi ideju o izradi i prilagođavanju robota

Potrebni materijal:

- karton
- dodaci (na primjer markeri, naljepnice)
- model za robotske oblike (izborni)
- ljepilo i škari
- fotografije različitih tipova robota (izborni)

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug
- 2.Počnite pitanjima da li netko zna što je robot i da li su ga vidjeli u knjizi ili filmu
- 3.Objasnite da će danas učiti kako napraviti svog robota

Aktivnost 1-Izrada Robota (30 minuta):

- 1.Ponudite kartonske komade izrezane u obliku robota ili ponudite djeci da sami dizajniraju oblik robota.
- 2.Ponudite djeci različite dodatne materijale poput markera, naljepnica i ostalog.
- 3.Ohrabrite djecu da sami izrade i opreme svog kartonskog robota.

Aktivnost 2- Predstavljanje robota (10 minuta):

- 1.Neka svako dijete ukratko predstavi svog robota svojim prijateljima
- 2.Pitajte ih kakve posebne sposobnosti njihov robot ima.
- 3.Izborni, pokažite fotografije različitih tipova robota (na primjer robot za čišćenje, svemirski robot) kako biste djecu dodatno inspirirali.

Napravi robota

- I

Rasprava (5 minuta):

1. Okupite djecu i raspravljajte o tome što su naučili o izgradnji i prilagođavanju robota.
2. Objasnite djeci kako inženjeri i znanstvenici kreiraju stvarne robote.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o robotima u ovoj lekciji.
2. Spomenite da roboti dolaze u različitim oblicima i veličinama za različite namjene.
3. Pozovite djecu da podijele sa skupinom omiljenje dijelove ove aktivnosti.

Vrijeme za priču virtualnog asistenta

Cilj: Predstaviti djeci rane i predškolske dobi ideju virtualnog asistenta i praćenja uputa

Potrebni materijal:

- jednostavna priča za djecu
- izborna: maske od kartona za vizualnog asistenta

Trajanje: Otprilike 30 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug
- 2.Objasnite kako će dana učiti o virtualnom asistentu, koji su poput prijateljskog aparata koji govori.

Aktivnost 1- Čitanje priče (15 minuta):

- 1.Pročitajte kratku i motivirajuću priču.
- 2.Odaberite priču koja sadrži karaktere koji prate instrukcije ili ponavljaju radnje.
- 3.Ohrabrite djecu da obrate pažnju na dijelove priče koji se ponavljaju.

Aktivnost 2-Zabava s virtualnim asistentom (10 minuta):

- 1.Izborna, ponudite kartonske maske za virtualnog asistenta.
- 2.Pozovite djecu da se izmjenjuju u nošenju maske i pričaju ponavljajući dijelove priče.
- 3.Učinite aktivnost zabavnom na način da djeca odgovaraju na pitanja (kao virtualni asistent) i da prate upute

Vrijeme za priču virtualnog asistenta - I

Rasprava (5 minuta):

1. Okupite djecu i pitajte ih je li bilo zabavno biti virtualni asistent.
2. Raspravite o tome kako virtualni asistent prati upute i odgovara na pitanja.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o virtualnim asistentima i praćenju uputa.
2. Spomenite da su virtualni asistenti naprave koje nam pomažu, koje mogu govoriti i odgovarati na pitanja.

Slika slagalica

Cilj: Predstaviti djeci rane i predškolske dobi načelo slaganja slike od dijelova (tzv. puzzle)

Potreban materijal:

- fotografije kojima nedostaju dijelovi (na primjer Jigsaw puzzle)
- izborno: prazni komadići slagalice koje dijete može samo obojati ili kreirati sliku od dijelova

Trajanje: Otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):



- 1.Okupite djecu u sjedeći ili stojeći krug
- 2.Objasnite im da će danas učiti o rješavanju slagalica i kako računalo pronalazi informacije koje nedostaju

Aktivnost 1- Slika slagalica (20-30 minuta):

- 1.Pokažite djeci fotografiju na kojoj nedostaju dijelovi (Jigsaw puzzle)
- 2.Izborno, ponudite prazne komadiće slagalice i ohrabrite djecu da kreiraju njihove slagalice za svakog posebno

Aktivnost 2- Kreiranje slagalice (10-15 minuta, izborno):

- 1.Neka djeca kreiraju vlastite slagalice crtanjem na prazne komadiće ili bojanjem i onda uklanjanjem jednog ili više komada.
- 2.Ponudite im zamjenske komadiće kako bi mogli završavati kreacije jedni drugima.



Slika slagalica - I

Rasprava (5 minuta):

1. Okupite djecu i pitajte ih kako su se osjećali kad su rješavali slagalice.
2. Raspravljajte o tome kako računala mogu isto tako pronalaziti informacije i slike koje nedostaju.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o rješavanju slagalica.
2. Spomenite kako računala pomažu u pronalaženju dijelova koji nedostaju upravo kao što su to djeca činila u ovoj aktivnosti.

“Ova je lekcija dizajnirana da bude interaktivna i poticajna u predstavljanju djeci rane i predškolske dobi različitih načela povezanih s umjetnom inteligencijom. U lekciju su integrirane praktične aktivnosti, rasprava i istraživanje kako bi učenje bilo zabavno i nezaboravno”.

Algoritam utrke

Cilj: Predstaviti djeci rane i predškolske dobi koncept algoritma i kako mogu voditi robota ili stroj.

Potrebni materijali:

- dovoljno prostora za utrku
- jednostavni predmeti prepreke (na primjer češeri, jastuci)
- jasne instrukcije za utrku (korak po korak)
- izborna: fotografije ili crteži robota

Trajanje: Otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug
- 2.Objasnite im kako će danas naučiti kako pratiti upute korak po korak, upravo poput robota i računala koja prate algoritme

Aktivnost 1-Staza sa preprekama (20-30 minuta):

- 1.Postavite jednostavne prepreke poput češera i jastuka na otvorenom prostoru
- 2.Pokažite djeci gdje je početak i kraj staze.
- 3.Osigurajte svakom djetetu jasne, napisane ili ilustrirane upute za navigaciju staze sa preprekama.
- 4.Objasnite da će se utrkiivati po stazi prateći upute korak po korak.
- 5.Ohrabrite djecu u izmjenjivanju u ulozi „robota“ i praćenju uputa. Na primjer:

„Hodaj tri koraka unaprijed“

„Skoči preko hulahopa“

„Okreni se na lijevo i hodaj do češera“

Algoritam utrke - I

Aktivnost 2- Kreiranje algoritma (10-15 minuta):

1. Nakon utrke okupite djecu.
2. Objasnite im da mogu sami kreirati algoritam (upute) koji mogu pratiti njihovi prijatelji.
3. Osigurajte im prazne kartice ili papire i markere kako bi nacrtali ili napisali upute.
4. Ohrabrite ih da kreiraju jednostavne algoritme sa korak po korak uputama za svoje prijatelje.

Rasprava (5 minuta):

1. Okupite djecu i pitajte ih kako su se osjećali kad su trebali pratiti upute i kreirati algoritme.
2. Raspravite o važnosti detaljnih uputa korak po korak za robote i računala.
3. Izborno, pokažite fotografije ili crteže robota i pojasnite kako oni prate algoritme kako bi izvršili zadatak.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o algoritmu i praćenju uputa.
2. Spomenite kako računala i roboti koriste algoritam kako bi izvršili zadatak isto kao i djeca u utrci.

Procjena:

Nema formalne procjene jer je lekcija dizajnirana za predstavljanje koncepta algoritma djeci rane i predškolske dobi kroz praktičnu aktivnost i igru.

Dodatne aktivnosti:

- kako djeci postaje koncept jasniji, osigurajte im složenije algoritme za igru
- potaknite djecu da kreiraju algoritme za različite aktivnosti ili igre, poput plesa ili potrage za blagom
- istražite osnovne koncepte programiranja (Pčela robot) i uputa („jedan gore“, „dva dolje“)

“Ova lekcija integrira fizičke aktivnosti, kreativnost i raspravu kako bi se djeci rane i predškolske dobi pomoglo u razumijevanju koncepta algoritma na zabavan način, interaktivno i kroz igru”.

Otkrij predmet

Cilj: Predstaviti djeci rane i predškolske dobi koncept prepoznavanja predmeta pomoću osjetila i na koji način umjetna inteligencija prepoznaje predmete.

Potrebni materijali:

- različiti svakodnevni predmeti različitih oblika i teksture (na primjer plišanci, autići, voće, žlica, loptica)
- tkanina za pokrivanje predmeta
- izborno: fotografije ili crteži robota sa senzorima

Trajanje: Otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug
- 2.Upitajte ih jesu li se ikad igrali igru u kojoj su trebali nešto pogoditi bez gledanja.
- 3.Objasnite djeci da će danas igrati igru koja se zove „Pogodi predmet“ i da će učiti kako umjetna inteligencija prepoznaje predmete na sličan način.

Aktivnost 1- Igra pogađanja (20-30 minuta):

- 1.Stavite različite predmete u kutiju ili vreću, sigurni da ih dijete ne može vidjeti.
- 2.Pokažite vreću djeci i objasnite kako će se izmjenjivati u pogađanju što je u vreći bez gledanja.
- 3.Stavite povez na oči jednom djetetu i dozvolite da posegne u vreću, opipa predmet, i opiše što je osjetio. Ohrabrite djecu da koriste riječi kako bi opisali oblik, teksturu i neku drugu značajku.
- 4.Ostala djeca slušaju opise i pokušavaju pogoditi o kojem se predmetu radi.
- 5.Nakon nekoliko pogađanja, otkrijte predmete i razgovarajte o njihovim karakteristikama.
- 6.Ponavljajte igru s različitom djecom i različitim predmetima.

Otkrij predmet - I

Aktivnost 2- UI senzori (10-15 minuta):

1. Nakon igre okupite djecu.
2. Objasnite kako roboti i strojevi jednako tako mogu otkriti predmete pomoću svojih posebnih senzora.
3. Izborno, pokažite fotografije ili crteže sa sensorima (na primjer robot s kamerom koji vidi predmete).
4. Raspravljajte o tome kako UI može prepoznati predmete prema prikupljenim podacima pomoću senzora, upravo kao što i djeca mogu prepoznati predmete pomoću osjetila.

Rasprava (5 minuta):

1. Okupite djecu i upitajte kako su se osjećali kad su trebali pogoditi predmet pomoću osjetila dodira.
2. Raspravite kako UI upotrebljava različite senzore, poput kamera, da bi „vidjela“ i prepoznala predmet.
3. Ohrabrite djecu da podijele s prijateljima što su naučili o prepoznavanju predmeta bez gledanja.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o prepoznavanju predmeta korištenjem osjetila i kako UI može slično pomoću senzora.
2. Spomenite kako UI pomaže robotima i strojevima da razumiju svijet i imaju interaktivan odnos sa svijetom koji ih okružuje.

Procjena:

Nema formalne procjene za ovu lekciju jer je dizajnirana kako bi djeci rane i predškolske dobi predstavila koncept prepoznavanje predmeta pomoću senzornog iskustva.

Dodatne aktivnosti:

- istražujte i druga osjetila poput sluha i mirisa i zvuka
- neka djeca nacrtaju robota sa različitim sensorima i neka opišu o kojim se sensorima radi
- predstavite osnovni koncept računalnog prepoznavanja prikazivanjem jednostavnih primjera na računalu (kako ono prepoznaje predmet i fotografiju)

“Ova lekcija integrira senzorno iskustvo i raspravu kako bi djeci rane i predškolske dobi približilo koncept prepoznavanja predmeta i kako UI može slično pomoću senzora”.

Umjetna inteligencija i pričanje priče

Cilj: Predstavljanje djeci rane i predškolske dobi koncepta generiranja priča pomoću UI generatora i motiviranje njihove kreativnosti.

Potrebni materijali:

- jednostavna, dobi primjerena priča ili pjesma generirana od UI (možete pronaći primjere na internetu)
- materijali za crtanje (pastele, markeri, papir)
- izborno: fotografije ili crteži računala ili robota generatora priča

Trajanje: otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okutite djecu u sjedeći ili stojeći krug.
- 2.Započnite pitanjem jesu li uživali u slušanju priče i da li znaju od kud ta priča dolazi.
- 3.Objasnite da će danas učiti o pričanju priča uz pomoć računala.

Aktivnost 1- UI vrijeme za priču (15-20 minuta):

- 1.Podijelite jednostavno priču ili pjesmu koju je napravio UI generator. Vodite računa da je primjerena dobi djece.
- 2.Pročitajte ili ispričajte priču, naglasite da je kreirana pomoću računala koji koristi posebne algoritme.
- 3.Ohrabrite djecu da slušaju pažljivo.


Aktivnost 2- Kreirajte vašu priču (10-15 minuta):

- 1.Nakon slušanja priče, podijelite materijal za crtanje (pastele, markere, papir).
- 2.Potaknite djecu da nacrtaju crteže koji će biti povezani s pričom koju su čuli.
- 3.Izborno, djeca mogu koristiti crteže kako bi kreirali svoju vlastitu priču ili pjesmu.

Aktivnost 3- Dijeljenje i rasprava (10 minuta):

- 1.Neka svako dijete podijeli svoje crteže ili priču sa skupinom.
- 2.Raspravljajte o crtežima i pričama, naglašavajući da svako dijete može pričati priče.
- 3.Pitajte djecu da li imaju pitanja o UI generatoru i kako računalo može kreirati priču.

Umjetna inteligencija i pričanje priče - I



Rasprava (5 minuta):

1. Okupite djecu kako biste raspravljali o tome što su naučili o pričanju priča.
2. Objasnite dok računalno može pomoći u generiranju priča, ljudi su još uvijek najbolji pripovjedači jer imaju maštu i osjećaje.

Zaključak (5 minuta):

1 Sumirajte što su djeca naučila o pričanju priča i kako računalno može pomoći u kreiranju priča.

Procjena:

Nema formalne procjene za ovu lekciju. Dizajnirana je da djeci rane i predškolske dobi predstavi koncept UI generatora za priče i promociju njihove vlastite kreativnosti.

Dodatne aktivnosti:

- pročitajte više tradicionalnih priča za djecu i raspravljajte o razlikama između tih priča koje su kreirali ljudi i onih generiranih od UI
- ohrabrite djecu na sudjelovanje u zajedničkom kreiranju priče gdje svako dijete dodaje jednu rečenicu ili crtež
- Istražite ostale kreativne UI aplikacije, poput UI generatora za umjetnost i glazbu, vodeći računa o dobi djece

“Ova lekcija kombinira pričanje priča, kreativnost i raspravu kako bi djeca rane i predškolske dobi razumjela koncept UI generatora za priče i kako bi bila inspirirana razvijati vlastite vještine pričanja priča”.

Brojanje pomoću UI

Cilj: Predstaviti djeci rane i predškolske dobi koncept računanja i kako UI može brojati i analizirati podatke

Potrebni materijali:

- predmeti za brojanje (na primjer gumbi, kuglice, kocke)
- kutija za držanje predmeta koje brojimo
- kartice s brojevima ili fotografijama (izborna)
- .izborna: fotografije ili crteži računala ili robota za brojanje

Trajanje: Otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug
- 2.Započnite pitanjima da li vole brojati stvari i neka kažu koliko je predmeta koje su brojali.
- 3.Objasnite djeci da će danas učiti o brojanju i kako računalo isto može brojati.

Aktivnost 1- Zabavno brojanje (5-10 minuta):

- 1.Pokažite djeci kutiju punu različitih predmeta koje će brojati (na primjer gumbi, kuglice, kockice).
- 2.Zamolite ih da vam pomognu brojati predmete jedan po jedan i da ih na taj način vade iz kutije.
- 3.Izborna, koristite kartice s brojevima ili fotografijama koji predstavljaju broj.

Aktivnost 2-Brojanje pomoću UI (10-15 minuta):

- 1.Objasnite kako računalo i robot mogu isto tako brojati, ali oni broje vrlo brzo i mnogo stvari istovremeno.
- 2.Izborna, pokažite fotografije ili crteže računala ili robota za brojanje i obradu podataka.
- 3.Pitajte djecu da zamisle računalo ili robota kako broji veliki broj predmeta vrlo brzo

Brojanje pomoću UI - I

Rasprava (5 minuta):

1. Okupite djecu i pitajte ih kako su se osjećali kad su brojali predmete.
2. Raspravite o ideji kako računalo i robot može brojati puno brže od nas i obraditi veliki broj podataka.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o brojanju i kako računala i roboti isto tako mogu brojati.
2. Ohrabrite ih da vježbaju svakodnevno novu vještinu.

Procjena:

Nema formalne procjene za ovu lekciju. Dizajnirana je na način da djeci rane i predškolske dobi približi koncept brojanja i kako računala i roboti mogu brojati i analizirati prikupljene podatke.

Dodatna aktivnost:

- istražujte drugačije aktivnosti brojanja, poput brojanja prstiju, objekata u prirodi ili u okolini
- igrajte igre poput „Brojimo životinje“ u kojoj dijete broji igračke životinje i pokušajte to povezati s načinima na koji UI broji i identificira predmete
- predstavite osnovno načelo analize podataka pokazivanjem jednostavnih karata ili grafikona (na primjer graf koji pokazuje broj kocaka različitih boja).

“Ova lekcija kombinira praktičnu aktivnost, raspravu i maštu kako bi pomogla da dijete rane i predškolske dobi razumije načelo brojanja i kako računala i roboti broje i analiziraju podatke brzo i učinkovito”.

Brojanje pomoću UI - I

Rasprava (5 minuta):

1. Okupite djecu i pitajte ih kako su se osjećali kad su brojali predmete.
2. Raspravite o ideji kako računalo i robot može brojati puno brže od nas i obraditi veliki broj podataka.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o brojanju i kako računala i roboti isto tako mogu brojati.
2. Ohrabrite ih da vježbaju svakodnevno novu vještinu.

Procjena:


Nema formalne procjene za ovu lekciju. Dizajnirana je na način da djeci rane i predškolske dobi približi koncept brojanja i kako računala i roboti mogu brojati i analizirati prikupljene podatke.

Dodatna aktivnost:

- istražujte drugačije aktivnosti brojanja, poput brojanja prstiju, objekata u prirodi ili u okolini
- igrajte igre poput „Brojimo životinje“ u kojoj dijete broji igračke životinje i pokušajte to povezati s načinima na koji UI broji i identificira predmete
- predstavite osnovno načelo analize podataka pokazivanjem jednostavnih karata ili grafikona (na primjer graf koji pokazuje broj kocaka različitih boja).

“Ova lekcija kombinira praktičnu aktivnost, raspravu i maštu kako bi pomogla da dijete rane i predškolske dobi razumije načelo brojanja i kako računala i roboti broje i analiziraju podatke brzo i učinkovito”.

Prepoznavanje zvukova



Cilj: Predstaviti djeci rane i predškolske dobi načelo prepoznavanja i razvrstavanja zvukova u odnosu na načine kako to čini UI

Potrebni materijali:

- različiti predmeti koji proizvode različite zvukove (na primjer igračke životinje, muzički instrumenti, čegrtaljka)
- povez za oči (izborno)
- izborno: fotografije ili crteži računala ili robota sa sposobnostima prepoznavanja zvukova

Trajanje: Otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug.
- 2.Započnite pitanjima kako im se dopada slušanje različitih zvukova i da li ih prepoznaju.
- 3.Objasnite da će danas naučiti prepoznati zvukove i kako računalo i robot mogu to isto.


Aktivnost 1- Istraživanje zvuka (15-20 minuta):

- 1.Pripremite različite predmete koji proizvode zvuk (na primjer igračke životinje, muzičke instrumente, čegrtaljke).
- 2.Zamolite djecu da se izmjenjuju u prepoznavanju zvukova sa povezom na očima.
- 3.Ohrabrite djecu da pogode koji su zvuk čuli i raspravljajte o tome.

Aktivnost 2- Prepoznavanje zvukova (10-15 minuta):

- 1.Objasnite da računala i roboti posjeduju nešto što se zove „prepoznavanje zvuka“ pomoću čega računalo i robot prepoznaje zvukove.
- 2.Izborno, pokažite djeci fotografije ili crteže računala ili robota koji imaju sposobnost prepoznavanja zvukova.
- 3.Pitajte djecu da zamisle računalo ili robot koji bi mogao čuti različite zvukove i reći koji su to zvukovi.

Prepoznavanje zvukova - I



Rasprava (5 minuta):

1. Okupite djecu i pitajte ih koje su zvukove čuli tijekom ove aktivnosti.
2. Raspravite o ideji da računala i roboti mogu prepoznati i odrediti zvuk, baš poput djece.
3. Spomenite kako takva računala i roboti razumiju zvukove u svojoj okolini.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o prepoznavanju zvukova i kako računala i roboti to čine.
2. Ohrabrite djecu da i nadalje osluškuju zvukove u svom okolišu.

Procjena:


Nema formalne procjene za ovu lekciju. Dizajnirana je na način da djeci rane i predškolske dobi približi načelo prepoznavanja zvukova i povezivanja sa sposobnošću računala i robota da isto tako prepoznaju zvukove.

Dodatne aktivnosti:

- pođite na „Zvukovni safari“ u kojem će djeca slušati zvukove u prirodi i nastojati ih prepoznati
- kreirajte igru u kojoj će se djeca izmjenjivati u stvaranju zvukova s predmetima dok ostali trebaju prepoznati o kojem se zvuku radi
- predstavite osnovno načelo zvučnih valova i vibracija pokazivanjem jednostavnih primjera vezanih uz zvukove

“Ova lekcija kombinira senzorno iskustvo, maštu i raspravu kako bi pomogla djeci rane i predškolske dobi da razumiju načelo prepoznavanja i identificiranja zvukova, te na koji način to isto mogu računala i roboti koristeći tehnologiju prepoznavanja zvukova”.

Igra pamćenja (Memory)



Cilj: Predstaviti djeci rane i predškolske dobi načelo pamćenja i kako UI može pomoći u razvoju pamćenja

Potrebni materijali:

- Memory kartice ili parovi kartica
- izborna: Fotografije ili crteži računala ili robota

Trajanje: Otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug.
- 2.Upitajte ih da li su se ikad igrali igru Memory u kojoj moraju pamtit gdje je nešto skriveno.
- 3.Objasnite da će danas naučiti igru i kako im računalo u igri može pomoći.


Aktivnost 1- Igra Memory (20-30 minuta):

- 1.Složite kartice na stol licem prema dolje.
- 2.Objasnite pravila: Dijete odabire dvije kartice. Ako odgovaraju jedna drugoj, dijete uzima par kartica i nastavlja s igrom, ako ne, vraća kartice na isto mjesto, a drugo dijete nastavlja igru.
- 3.Ohrabrite djecu da se uključe i da pokušaju zapamtiti kartice koje su skrivene, a čine par.

Aktivnost 2- Pojačani Memory (10-15 minuta):

- 1.Objasnite kako računalo može pomoći u poboljšanju pamćenja spremanjem i organiziranjem informacija.
- 2.Izborna, pokažite fotografije ili crteže računala ili robotske asistencije s pamćenjem.
- 3.Zamolite djecu da zamisle računalo ili robot koji bi im mogao pomoći da zapamte gdje su ostavili igračku ili što trebaju za školu.

Igra pamćenja (Memory) - I



Rasprava (5 minuta):

1. Okupite djecu i upitajte kako su se osjećali kad su igrali igru Memory.
2. Raspravljajte o ideju da nam računala i roboti mogu pomoći u poboljšanju našeg pamćenja organiziranjem i spremanjem informacija.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o pamćenju i kako im u tome mogu pomoći računala ili roboti.
2. Ohrabrite djecu da vježbaju svoje pamćenje u igri, kroz zabavu.


Procjena:

Nema formalne procjene za ovu lekciju. Dizajnirana je da djeci rane i predškolske dobi približi načelo pamćenja i kako nam računala i roboti u pamćenju mogu pomoći.

Dodatne aktivnosti:

- igrajte igru Memory različitih tema, poput životinja, oblika ili boja
- ohrabrite djecu da kreiraju vlastitu igru Memory izradom kartica u paru, s fotografijama ili crtežima

UI umjetnost



Cilj: Predstaviti djeci rane i predškolske dobi koncept UI generatora za umjetnost.

Potrebni materijali:

- primjeri generatora UI za umjetnost (možete ih pronaći na internetu)
- materijali za crtanje (pastele, markeri, papir)
- izborna: fotografije ili crteži računalnih ili robotskih umjetničkih radova

Trajanje: Otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug.
- 2.Počnite pitanjem uživaju li u crtanju i bojanju.
- 3.Objasnite kako će dana učiti o tome kako računala mogu kreirati umjetnost.


Aktivnost 1- UI umjetničko istraživanje (15-20 minuta):

- 1.Pokažite djecu primjere UI generatorskog rada na papiru ili na ekranu računala.
- 2.Objasnite djeci da je to djelo kreiralo računalo koristeći posebne algoritme.
- 3.Ohrabrite djecu da promatraju radove i raspravljaju o tome što vide ili što im se sviđa.

Aktivnost 2- Kreirajte svoju vlastitu umjetnost (15-20 minuta):

- 1.Osigurajte materijale za crtanje (pastele, markere, papir).
- 2.Zamolite djecu da kreiraju vlastiti crtež ili sliku inspirirani UI generatorom za umjetnost i radom koji su vidjeli.
- 3.Dozvolite im da koriste maštu i kreativnost kako bi njihov umjetnički rad bio jedinstven.

UI umjetnost - I



Rasprava (5 minuta):

1. Okupite djecu i potaknite ih da podijele svoje radove sa drugima.
2. Raspravljajte kako se kreira umjetnost i što su naučili od tome kako računalo može isto tako kreirati umjetnost.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o umjetnosti i kako računalo može biti kreativno.
2. Ohrabrite ih da budu kreativni i da se izražavaju kroz umjetnost.

Procjena:

Nema formalne procjene za ovu lekciju. Dizajnirana je na način da djeci rane i predškolske dobi približi koncept UI generatora za umjetnosti i da se potakne njihova kreativnost.

Dodatne aktivnosti:

- istražite druge oblike UI generatora za umjetnost, poput muzike ili pjesništva
- neka djeca surađuju u zajedničkom umjetničkom projektu u kojem svako dijete može biti autor manjeg dijela većeg umjetničkog rada
- predstavite osnovne koncepte algoritma pokazivanjem jednostavnih uzoraka ili instrukcije koje dijete može koristiti pri kreiranju svog rada

Vremenska prognoza

Cilj: Predstaviti djeci rane i predškolske dobi koncept vremenske prognoze i kako nam UI pomaže u prognozi

Potrebni materijali:

- fotografije ili crteži različitih vremenskih uvjeta (na primjer sunce, oblaci, kiša, snijeg)
- izborno: fotografije ili crteži računalnog ili robotskog prognoziranja vremena

Trajanje: Otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug
- 2.Započnite pitanjima da li su se ikad pitali kakvo će vrijeme biti.
- 3.Objasnite da će danas učiti o predviđanju vremena i kako nam u tome računalo može pomoći.


Aktivnost 1- Rasprava o vremenu (15-20 minuta):

- 1.Pokažite fotografije ili crteže različitih vremenskih uvjeta, poput sunca,oblaka, kiše ili snijega.
- 2.Raspravite o različitim vremenskim uvjetima i pitajte djecu što o tome znaju.
- 3.Objasnite da znanstvenici koriste posebne alate i računalo da bi predvidjeli vremenske uvjete.

Aktivnost 2- Vremenska prognoza (15-20 minuta):

- 1.Izborno, pokažite fotografije ili crteže računalne ili robotske vremenske prognoze.
- 2.Zapitajte djecu da zamisle računalo ili robot koje bi im mogao reći kakvo će biti vrijeme sutra.
- 3.Dozvolite im da se izmjenjuju u jednostavnim vremenskim prognozama, poput „mislim da će sutra biti sunčano“ ili „mislim da će sutra kišiti“.

Vremenska prognoza - I



Rasprava (5 minuta):

1. Okupite djecu i pitajte ih da li su rado sudjelovali u ovoj aktivnosti.
2. Raspravite od ideji kako računala i znanstvenici surađuju u izradi vremenske prognoze i ljudima na taj način pomažu da se pripreme.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o vremenskoj prognozi i kako računala i znanstvenici koriste baze podataka kako bi predvidjeli vremenske uvjete.
2. Ohrabrite ih da obrate pažnju na vremenske uvjete i da razmišljaju kao mali prognostičari.

Procjena:

Nema formalne procjene za ovu aktivnost. Dizajnirana je kako bi djeci rane i predškolske dobi predstavila koncept vremenske prognoze i uloge računala u prognoziranju.

Dodatne aktivnosti:

- kreirajte vremenske kartice gdje će djeca pratiti i predvidjeti vremenske uvjete kroz cijeli tjedan
- istražujte u eksperimentima ovisnim o vremenu, poput kiše u staklenci ili izradi male vjetrenjače
- raspravljajte o važnosti vremenske prognoze za sigurnost ljudi i planiranje aktivnosti na otvorenom.

Pogodi životinju

Cilj: Predstaviti djeci rane i predškolske dobi koncept prepoznavanja i identificiranja životinja u odnosu na načine kako UI može identificirati predmete.

Potrebni materijali:

- fotografije ili crteži različitih životinja (na primjer lav, slon, majmun)
- povez za oči (izborna)
- izborna: računalne fotografije ili crteži životinja

Trajanje: Otprilike 30-45 minuta

Plan lekcije:

Predstavljanje (5 minuta):

- 1.Okupite djecu u sjedeći ili stojeći krug.
- 2.Započnite pitanjem vole li životinje i da li znaju imena nekih životinja.
- 3.Objasnite da će danas naučiti prepoznati i identificirati životinje i naučiti kako to čini računalo.

Aktivnost 1- Pogodi životinju (15-20 minuta):

- 1.Pokažite fotografije ili crteže različitih životinja.
- 2.Objasnite kako ćete opisati životinju, a djeca trebaju pogoditi o kojoj se životinji radi.
- 3.Izborna, može djeci staviti povez na oči da otežate zadatak.
- 4.Ohrabrite ih da pokušaju pogađati i raspravljajte o odgovorima.

Aktivnost 2- Otkrij životinju (10-15 minuta):

- 1.Objasnite da računalo i robot mogu isto tako prepoznati životinje pomoću posebne tehnologije.
- 2.Izborna, pokažite fotografije ili crteže koji su nastali pomoću računala ili robota.
- 3.Potaknite djecu da zamisle računalo ili robot koji može promatrajući fotografiju životinje pogoditi o kojoj se životinji radi.

Pogodi životinju - I

Rasprava (5 minuta):

1. Okupite djecu i pitajte ih kako su se osjećali kad su pogađali životinje.
2. Raspravljajte o ideji da računalo i robot mogu prepoznati životinju „gledajući“ fotografiju životinje, baš kao što to mogu i djeca.

Zaključak (5 minuta):

1. Sumirajte što su djeca naučila o prepoznavanju i identificiranju životinja i kako računalo i robot to čine.
2. Ohrabrite ih da i dalje uče o životinjama i njihovim imenima.

Procjena:

Nema formalne procjene za ovu lekciju. Ona je dizajnirana kako bi djeci rane i predškolske dobi približila koncept prepoznavanja i identifikacije životinja i kako računalo i robot mogu prepoznati objekte.

Dodatne aktivnosti:

- istražite različite aktivnosti na temu životinja, poput pogađanja životinja na temelju njihova glasanja ili bojanke sa likovima životinja
- neka djeca naprave svoju igru „Pogodi životinju“ opisivanjem životinja koje onda njihovi prijatelji trebaju pogoditi
- predstavite osnovni princip računalnog prepoznavanja prikazujući jednostavne primjere u kojima računalo prepoznaje objekte u slici, uključujući životinje



Dodatne priče

Detektiv za životinje


Nekad davno, u velikoj šarenoj šumi, živjela su četiri najbolja životinjska prijatelja: zec Benny, vjeverica Lucy, rakun Sammy i mišica Molly. Bili su poznati kao „Detektivi za životinje“ jer su bili iznimno vješti u pronalaženju i prepoznavanju životinjskih otisaka.

Jednog sunčanog jutra, okupili su se oko njihovog posebnog panja spremni za nove avanture. Čuli su glasine o neobičnim otiscima u dubokoj šumi-otiscima koji pripadaju životinji koju nitko do tad nije vidio!



Uzbuđeni s mapama u rukama uputili su se na svoje putovanje. Putem su susreli šumske prijatelje koji su im željeli pomoći, poput sove Oscara i bubamare Lila koji su s njima podijelili svoju mudrost i pokazali im pravi put.

Detektiv za životinje - I



Kako su pratili otiske, primijetili su da su otisci različitih oblika i veličina, poput kolačića ili dugačkih vijugavih linija. Molly je sa svojim ušima mogao čuti posebne zvukove u blizini otisaka.

Konačno, nakon cijelog dana istraživanja, pronašli su misteriozno stvorenje na prekrasnom proplanku. Bio je to Pandyfoxdeer, prijateljsko stvorenje s tijelom pande, repom lisice i dugim nogama kao u jelena.


Pandyfoxdeer im je objasnio da je ostavio te posebne otiske kako bi sve podsjetio o važnosti zajedničkog rada i brizi o šumi i održavanju šume u skladu.

Životinjski detektivi su naučili jako važnu lekciju tog dana-o tome kako biti prijatelj, kako pomagati drugima i kako brinuti o njihovoj prekrasnoj šumi koja je njihov dom. Shvatili su da je svaka životinja jedinstvena kao što je jedinstven i njihov detektivski tim.

Od tada, oni su postali još bolji prijatelji koji svoje avanture dijele sa cijelom šumom. Bili su zahvalni na njihovom novom prijatelju Pandyfoxdeer-u i na prekrasnoj lekciji koju su naučili.

I tako, životinjski detektivi nastavljaju svoje uzbudljive dogodovštine, uvijek osluškujući priče koje im šuma priča kroz otiske i žive u skladu sa svojim posebnim domom.

Robot pomoćnik



Jednom davno, u slikovitom gradu, postojao je poseban robot. Ime mu je bilo Robi. Robi je volio pomagati svojim prijateljima na različite načine.

Robi je mogao očistiti igračke sa svojim super-brzim robotskim rukama. Mogao je zapamtiti sve omiljene priče svojih prijatelja i onda ih je pričao kad god su ga zamolili. Još k tome, bio je jako dobar u igranju igrica sa svojim prijateljima.

Jednog prekrasnog dana, djeca u gradu su odlučila napraviti piknik u parku. Imali su puno igračaka za igranje, i znali su da će napraviti veliki nered. No, nisu bili zabrinuti jer je tu bio Robi koji će im pomoći u pospremanju.

Nakon što su završili s igrom, Robi je skupljao igračke i pospremao ih. Djeca su se smijala i igrala dalje jer su znala da će Robi pospremiti nered iza njih.



Robot pomoćnik - I

Kad je došlo vrijeme za spavanje, djeca su htjela čuti njihove omiljene priče. Robi je bio baš u blizini. Ispričao je priče s uzbudljivim avanturama, životinjskim prijateljima i sretnim završecima. Djeca su voljela slušati Robijeve priče.

Kad je pak bilo vrijeme za igre, Robi se pridružio djeci. Igrao se „Skrivača“ s njima. Bio je brz i odličan u traženju djece, a zbog toga je igra bila još zabavnija.

Djeca su shvatila da je Robi poput čarobnog pomagača, baš poput prijateljskog robota. Znali su isto tako, da iako su mali, mogu učiniti velike stvari ako pomažu jedni drugima, kao što je Robi pomagao njima.

Od tog dana, Robi i djeca su postali najbolji prijatelji. Igrali su se, smijali, i pomagali jedni drugima baš poput velike, sretne obitelji. I živjeli su zauvijek sretni.

Nevjerojatan virtualni asistent

U čarobnoj šumi, živjele su neke prijateljske životinje koje su se voljele igrati i učiti zajedno. Jednog dana, sreli su posebnog prijatelja koji se zvao Chatter. Chatter je bio čaroban virtualni asistent koji je mogao govoriti i odgovarati na pitanja.


Chatter je mogao ispričati prekrasne priče i podijeliti uzbudljive informacije. Životinje su voljele razgovarati s Chatterom jer je on znao toliko toga!

Jednog sunčanog jutra, životinje su se okupile oko Chattera i postaljale mu najrazličitija pitanja. Pitali su ga o zvijezdama na nebu, o cvijeću u šumi, čak i od čega se sastoji njihova omiljena hrana.

Chatter je odgovarao na njihova pitanja s velikim osmijehom. Pričao im je o treptajućim zvijezdama i kako su zvijezde poput sjajnih dijamantata na noćnom nebu. Objasnio im je kako cvijeće raste od malene sjemenke i kako se pretvara u prekrasne boje.



Nevjerojatan virtualni asistent - I



Životinje su bile presretne jer su svakog dana naučile nešto od Chattera. Postavljale su sve više i više pitanja i slušale Chatterove priče s velikim zanimanjem.

Chatter je bio njihov novi prijatelj, i igrali su se zajedno s njime. Igrali su se „Skrivača“ u čemu je Chatter bio jako dobar jer je bio jako pametan. Našao je brzo svakoga tko se skrio.

Životinje su shvatile da je Chatter poput čarobnog prijatelja koji svašta zna i voli se igrati s njima. Znale su životinje da kad postavljaju pitanja i uče zajedno s Chatterom, mogu otkriti prekrasne stvari u njihovoj šumi.

Od tog dana, Chatter i životinje su postali najbolji prijatelji. Istraživali su šumu, postavljali pitanja, igrali igre i učinili su svaki dan u njihovoj šumi uzbudljivim.

Računalo umjetnik



U prekrasnoj umjetničkoj učionici, postojao je poseban prijatelj imenom Artie. Arti nije bio čovjek: bio je čarobno računalo koje je voljelo stvarati živopisne slike.

Jednog sunčanog dana, djeca u toj umjetničkoj učionici su upoznala Artija, Arti je mogao napraviti prekrasno umjetničko djelo sa mnogo svijetlih boja, baš poput duge. Kreirao je prekrasne oblike koji su svakoga razveselili.

Djeca su bila jako uzbuđena zbog Artijeve umjetnosti, i stoga su i sama htjela stvarati svoja umjetnička djela. S papirima, bojama, kistovima počeli su stvarati posebne slike. Netko je koristio crvenu, netko plavu, a neki su čak mješali boje kako bi stvorili nove.

Arti je bio tamo da pomogne ako je nekom išlo teško. Pomagao je s idejama i pokazao djeci kako napraviti uzorke i oblike da izgledaju čarobno.






Računalo umjetnik - I

Kako su djeca slikala, vidjela su da je njihova umjetnost jedinstvena, baš poput njih samih.

Svaka slika je bila drugačija i posebna na svoj način. Vidjeli su da je stvaranje umjetnosti zabavno i da ih to čini sretnim.

Od tog dana, djeca i Arti su postali najbolji prijatelji. Slikali su i kreirali zajedno, čineći svijet šarenijim i ljepšim. Svaki dan u njihovoj umjetničkoj učionici postao je nova avantura u kreativnosti.

Igra „Memori“



U sunčanoj igraonici, bila su četiri najbolja prijatelja: zec Benny, vjeverica Lucy, rakun Sammy i mišica Molly. Igrali su različite igre zajedno, posebno njihovu omiljenu pod nazivom „Memori“.

„Memori“ je bila igra u kojoj je trebalo spojiti dvije kartice sa šarenim slikama. Kartice su bile okrenute licem prema dolje, i prijatelji su redom okrećući kartice tražili one koje čine par.

Benny je imao jako dobar vid, i mogao je zapamtiti gdje se koja kartica nalazi čak i kad su bile okrenute prema dolje. Lucy je bila super brza u pronalaženju parova. Sammy je bio jako pametan i zapamtio je kartice koje je vidio ranije, a Molly je imala oštar sluh i mogla je čuti gdje se nalaze parovi.

Svakog dana su igrali „Memori“ i pritom su se hihotali i zabavljali. Okretali su kartice sa životinjama, oblicima i puno prekrasnih sjajnih boja. Smijali su se kad bi pronašli par i završili igru.




Igra „Memori“ - I

Za vrijeme igre, shvatili su da je „Memori“ igra u kojoj je najvažnije pomagati jedni drugima. Benny je dobro vidio kartice, Lucy ih je pronalazila brzo, Sammy je dobro pamtio, a Molly slušala pažljivo. Zajedno, bili su najbolji Memori tim.

Od tog dana, igrali su Memori i ostale igre, uvijek pomažući jedni drugima i pritom se zabavljajući. Znali su da biti prijatelj i raditi zajedno znači biti još bolji u zajedničkoj igri i avanturama.

Detektivi zvuka



U ugodnoj šumi prepunoj prijateljskih životinja, postojala je mala grupa posebnih prijatelja: zec Benny, vjeverica Lucy, rakun Sammy i mišica Molly. Oni su bili poznati kao „Detektivi za zvukove“ jer su imali odličan sluh i voljeli su slušati zvukove šume.


Jednog sunčanog dana, prijatelji su odlučili upustit se u avanturu. Htjeli su riješiti zagonetku slušanjem različitih zvukova u šumi.

Hodajući kroz šumu, čuli su mnogo različitih zvukova. Ptice su pjevale prekrasne pjesmice, lišće je šuštalalo na vjetru, a voda u obližnjem potoku je žuborila veselo.

Kadgod bi čuli neki zvuk, oni bi stali i slušali pažljivo. Benny, sa svojim dugim ušima, mogao je čuti pjesmu ptica visoko u krošnjama drveća. Sammy, pametan rakun, mogao je reći kad je neka životinja u blizini, samo slušajući. Molly, s njenim ostrim mišjim ušima, mogla je čuti najmekanije zvukove u šumi.



Detektivi zvuka - I



Prijatelji su slijedili zvukove i otkrivali prijateljske životinje u šumi, poput ptica, marljivih kukaca, čak su jednom otkrili i obitelj žaba kraj jezera. Slušali su njihove priče i smijali se zabavnim zvukovima koje su proizvodili.

Naši detektivi zvuka su naučili kako je svaki zvuk u šumi skrivena poruka prirode. Znali su da ako slušaju pažljivo, mogu otkriti sve prekrasne priče koje im priča šuma.

Od tog dana, prijatelji su postali čak i bolji slušači nego ranije. Istraživali su šumu, smijali se sa životinjskim prijateljima i pažljivo slušali prekrasne melodije prirode. Svaki da u šumi bila je nova avantura ispunjena predivnim zvukovima.

Robot koji priča priče

Nekad davno, u čarobnoj knjižnici, nio je jedan poseban robot koji se zvao Robot Pričalica. Robot Pričalica je volio pričati uzbudljive priče svoj djeci koja su ga došla posjetit.

Knjižnica je bila ugodno mjesto s mnoštvom knjiga, i djeca su voljela sjesti u krug oko Robota Pričalice i slušati njegove priče.


Jedno sunčanog jutra, djeca su se okupila u knjižnici, a Robot Pričalica je počeo pričati priču. Bila je to priča o hrabrom zecu koji je otišao na prekrasnu avanturu u šarenu šumu.

Kako je Robot Pričalica pričao, djeca su sa sjajem u očima slušala. Zamišljali su putovanje zeca kroz šumu, zamišljali su kako je susretao prijateljske životinje i savladavao izazove.

Nakon što je Robot Pričalice završio jednu priču, djeca su tražila novu. Robot Pričalica im je pričao priče o letećim zmajevima, o životinjama koje govore, o čarobnim dvorcima. Svaka je priča bila prepuna uzbuđenja i radosti.



Robot koji priča priče - I




Djeca su voljela priče Robota Pričalice, i shvatila da i sama mogu kreirati njihove vlastite priče. Tako su počeli pričati o svojim avanturama, smiješnim životinjama i čarobnim mjestima.

Od tada, djeca i Robot Pričalica postali su vješti u pričanju priča. Dijelili su svoje priče, slušali jedni druge i kreirali čudnovate avanture u svojoj mašti.



Čaroban uzorak



U šarenoj zemlji, živjela su četiri prijatelja koja su voljela kreirati prekrasne uzorke. Njihova imena su Benny, Lucy, Sammy i Molly.


Jednog sunčanog jutra odlučili su zajedno napraviti čaroban uzorak. Benny je napravio uzorak sa šarenim krugovima, Lucy cik cak uzorak s petljama, Sammy je iskoristio pametne trikove za izradu uzorka, a Molly je stavila sićušne točkice na svoj uzorak.

Radili su zajedno, miješali boje i oblike, i napravili su najljepši uzorak. Njihov uzorak je bio poput duge, prepun sjajnih boja i beskrajno lijep.

Kad su kreirali postali su svjesni kako njihov uzorak izgleda poput skrivene šifre. Linije su išle prema gore i dolje, i uokolo, baš poput čarolije.




Čaroban uzorak - I




Prijatelji su se toliko zabavljali pri ukrašavanju svog doma. Pretvorili su potpuno obično okruženje u čarobno mjesto prepuno boja i oblika.

Od tog dana, postali su umjetnici za izradu uzoraka. Kreirali su uzorke za svoju odjeću, za igračke, čak i za nebo u njihovoj mašti. Oni znaju da uzorci mogu svijet učiniti uzbudljivim i prekrasnim.



Avantura brojavanja



U sretnoj šumi bila su četiri najbolja prijatelja: zec Benny vjeverica Lucy, rakun Sammy i mišica Molly. Oni su uživali u zajedničkim avanturama.

Jednog sunčanog dana, prijateljicu odlučili napraviti avanturu brojavanja u šumi. Brojali su drveće u šumi, šareno cvijeće, čak i male otiske šapa na tlu.

Benny je brojao pomoću svojih zečjih skokova, Lucy je mjerila penjanjem na drveće, Sammy je koristio pametne trikove za brojavanje, a Molly je brojala pomoću svojih sićušnih koraka. Svatko je imao svoj poseban način brojavanja.

Kako su istraživali, tako su otkrili da je šuma prepuna brojeva. Brojali su prekrasne leptire šarenih krila, jabuke i drveće, čak i oblake na nebu.

Prijatelji su naučili da je brojavanje poput zabavne igre, i smijali su se kad su brojali zajedno. Naučili su da su brojevi svuda, i da ih možemo koristiti za igru i učenje.



Čarobnjak za vrijeme

U prijateljskom selu živio je mudri čarobnjak po imenu Will. Bio je poznat kao Čarobnjak vremena jer je mogao predvidjeti kakvo će vrijeme biti pomoću čarolija.

Jednog sunčanog jutra djeca iz sela su se okupila oko Čarobnjaka Willa. Bila su znatiželjna da saznaju kako on može znati kakvo će vrijeme biti svakog dana.


Čarobnjak Will se nasmijao i počeo objašnjavati. Rekao je djeci da on koristi posebne čarolije kako bi razumio vrijeme. Promatra oblake, sluša vjetar i osjeća toplinu sunca kako bi predvidio vrijeme.

Djeca su bila oduševljena i željela su još naučiti o vremenu. Tako im je Čarobnjak Will pokazao kako osjetiti zrak, kako gledati u oblake i kako pronaći dugu na nebu poslije kiše.

Naučili su da je sunčan dan kad je nebo čisto i svijetlo i to je vrijeme za igru na dvorištu. Kad se skupe pahuljasti oblaci na nebu, bit će kiše i treba ponijeti kišobran.



Čarobnjak za vrijeme - I



Čarobnjak Will i djeca su zajedno postali promatrači vremena. Primijetili su da se mijenjaju godišnja doba i naučili puno o kiši, snijegu i suncu. Vidjeli su i prekrasnu dugu i osjetili nježan mraz na licu.

Od tog dana, Čarobnjak Will i djeca su postali stručnjaci za prognozu vremena. Saznali su da je razumijevanje vremene poput čarobne avanture, i upravo vrijeme čini njihovo selo zabavnim i uzbudljivim mjestom za život.





Izvori

Poglavlje 1

- Fazlagić Jan (scientific editor), Artificial intelligence (AI) as a megatrend shaping education. How to prepare for socio-economic opportunities and challenges related to artificial intelligence?, Educational Research Institute, Warsaw 2022.
- Leżańska Wiesława, Płóciennik Elżbieta, Pre-school pedagogy with methodology, University of Lodz Publishing House, Lodz 2021.
- Różycka Ewa (lead editor), Pedagogical Encyclopedia of the 21st Century, volume VI, Wydawnictwo Akademickie "Żak", Warsaw 2007.
- www.sas.com.pl

Poglavlje 2

- European Commission
- <https://blog.solides.com.br/inteligencia-artificial-e-o-mercado-de-trabalho/>
- <https://digital-strategy.ec.europa.eu/en/policies/european-approach-artificial-intelligence>

Poglavlje 3

- Наръчник за защита на личните данни за малки и стартиращи предприятия, <https://duncheva.bg/2019/06/01/oisр-прие-принципи-за-изкуствен-интел/>
- Правни ценности и етични измерения в технологичното развитие на XXI век /Изкуственият интелект и етичните принципи/, Сибел Хасан, http://www.bili-bg.org/cdir/bili-bg.org/files/Сибел_Хасан.pdf
- OECD AI Principles overview, <https://oecd.ai/en/ai-principles>

Poglavlje 4

Inspirirani smo knjigama:

- *CODEWEEK LEKCE PRO 1. – 3. TŘÍDU.* (23. 11. 2022). Načteno z <https://digikoalice.cz/wp-content/uploads/2021/08/cw21-metodika-lekce-1-3-trida.pdf>

Poglavlje 5

- Što se događa na tržištu rada u regiji i EU. preuzeto 21.11.2022. sa <https://www.moj-posao.net/Vijest/82568/Sto-se-dogadja-na-trzistu-rada-u-regiji-i-EU/>
- Most in-demand jobs. Preuzeto 21.11.2022. sa <https://business.linkedin.com/talent-solutions/recruiting-tips/thinkinsights-emea/most-in-demand-jobs-and-industries-in-europe-middle-east-and-latin-america>.
- Božiković, N. *Tržište rada u Europskoj uniji i Republici Hrvatskoj* preuzeto 19.11.2022. sa <https://hrcak.srce.hr/file/374576>
- Ključni izazovi za Europska tržišta rada. Preuzeto 9.11.2022. sa <http://erc-online.eu/wp-content/uploads/2014/04/2008-01866-E.pdf>
- *Umjetna inteligencija: prilike i prijetnje*. Europski parlament. Preuzeto 15.11.2022. sa <https://www.europarl.europa.eu/news/hr/headlines/society/20200918STO87404/umjetna-inteligencija-prilike-i-prijetnje>

Poglavlje 6

- Lead Your School's Curriculum Process With A Strategic Plan - Atlas. (2018, February 28). Retrieved November 25, 2022, from <https://www.onatlas.com/blog/lead-your-schools-curriculum-process-with-a-strategic-plan>
- 7 curriculum planning tips that will make your school year easier - Classcraft Blog. (2019, December 19). Retrieved November 25, 2022, from <https://www.classcraft.com/resources/blog/curriculum-planning-tips/>
- Elements of Curriculum – Educare. (2021, May 24). Retrieved November 25, 2022, from <https://educarepk.com/elements-of-curriculum.html>
- Vontz, T., & Goodson, L. (n.d.). Module 6: Curriculum Planning – EDCI 702: Curriculum, Instruction, and Assessment. Retrieved November 25, 2022, from <https://kstatelibraries.pressbooks.pub/EDCI702/chapter/module-6-curriculum-planning/>
- <https://www.onatlas.com/wp-content/uploads/2019/02/componentscurriculumplan.pdf>
- <https://chiefsforchange.org/wp-content/uploads/2020/07/Curriculum-Implementation-Guide.pdf>
- https://www.pivotlearning.org/curriculum-implementation-planning-toolkit/?utm_source=c-website&utm_medium=core&utm_term=curriculum-implementation-showcase&utm_content=curriculum_instruction&utm_campaign=c-website-curriculum-implementation-showcase
- <https://www.education.vic.gov.au/PAL/fiso-curriculum-planning-and-assessment-implementation-guide.pdf>
- <https://www.niet.org/assets/1da4c1fbd6/high-quality-curriculum-implementation.pdf>
- kosovotpd.eu/wp-content/uploads/2019/12/planning-for-curriculum-implementation-1.pdf

Ostanite u toku!



info@eurasiavision.eu



<https://dear4future.eu/>

**Stay
tuned**