



Uporaba strojnega učenja pri odkrivanju nove fizike na LHC

Seminar

Simon Bukovšek

Oddelek za fiziko
Fakulteta za matematiko in fiziko
Univerza v Ljubljani

10. april 2024



UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

Pregled

1 Teoretični uvod

2 CERN in ATLAS

3 Zbiranje podatkov

4 Strojno učenje

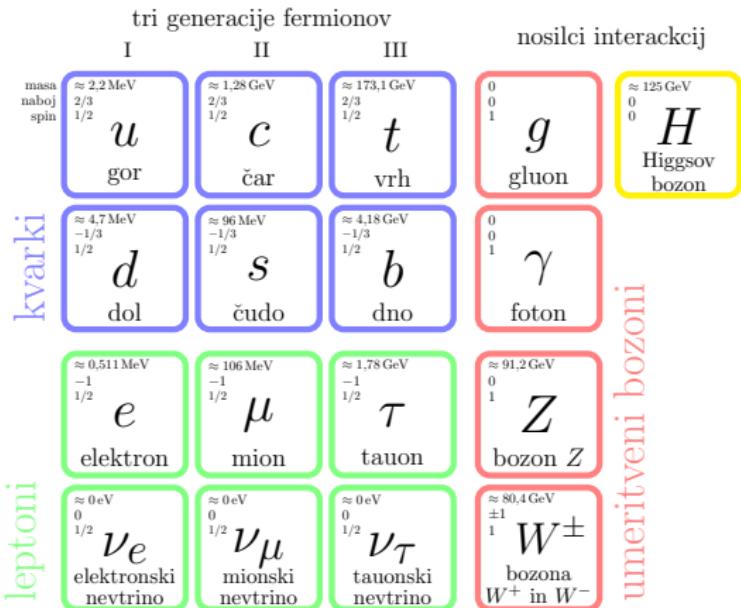
5 Avtoenkoderji



UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

Standardni model (SM)

- Leptoni, kvarki in umeritveni bozoni
- Polja in simetrije
- Tri vrste interakcij: šibka, močna in elektromagnetna
- Najnatančnejši fizikalni model, kar jih poznamo



Slika: Standardni model

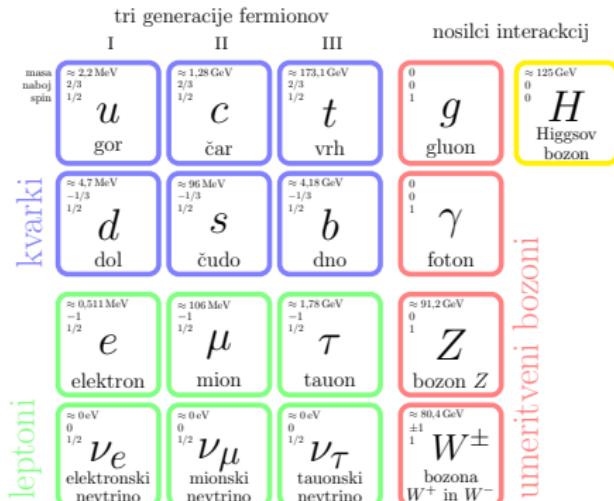
Standardni model (SM)

tri generacije fermionov			nosilci interakcij	
I	II	III		
masa naboj spin	$\approx 2,2 \text{ MeV}$ $2/3$ $1/2$ u gor	$\approx 1,28 \text{ GeV}$ $2/3$ $1/2$ c čar	$\approx 173,1 \text{ GeV}$ $2/3$ $1/2$ t vrh	kvarki leptoni umeritveni bozoni
			0 0 1 g gluon	
			$\approx 125 \text{ GeV}$ 0 0 H Higgsov bozon	
	$\approx 4,7 \text{ MeV}$ $-1/3$ $1/2$ d dol	$\approx 96 \text{ MeV}$ $-1/3$ $1/2$ s čudo	$\approx 4,18 \text{ GeV}$ $-1/3$ $1/2$ b dno	
			0 0 1 γ foton	
	$\approx 0,511 \text{ MeV}$ -1 $1/2$ e elektron	$\approx 106 \text{ MeV}$ -1 $1/2$ μ mion	$\approx 1,78 \text{ GeV}$ -1 $1/2$ τ tauon	
			0 1 Z bozon Z	
	$\approx 0 \text{ eV}$ 0 $1/2$ ν_e elektronski nevtrino	$\approx 0 \text{ eV}$ 0 $1/2$ ν_μ mionski nevtrino	$\approx 0 \text{ eV}$ 0 $1/2$ ν_τ tauonski nevtrino	
			$\approx 80,4 \text{ GeV}$ ± 1 1 W^\pm bozona W^+ in W^-	

Slika: Standardni model

Pomanjkljivosti Standardnega modela

- Gravitacija
- Materija – antimaterija
- Mase osnovnih delcev
- Temna snov in energija



Slika: Standardni model



FMF

UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko



Evropski center za jedrske raziskave

ALICE Experiment

ATLAS Experiment

ATLAS
EXPERIMENT

LHCb Experiment



UNIVERSITATIS LJUBLJANAE
Facultas Mathematico Naturalistica



Evropski center za jedrske raziskave

Conseil européen pour la Recherche nucléaire

ALICE Experiment

ATLAS Experiment

LHCb Experiment



FMF

UNIVERSITATIS LUBLIANAE
Facultas matematico et fizico



Evropski center za jedrske raziskave CERN

ALICE Experiment

ATLAS Experiment

ATLAS
EXPERIMENT



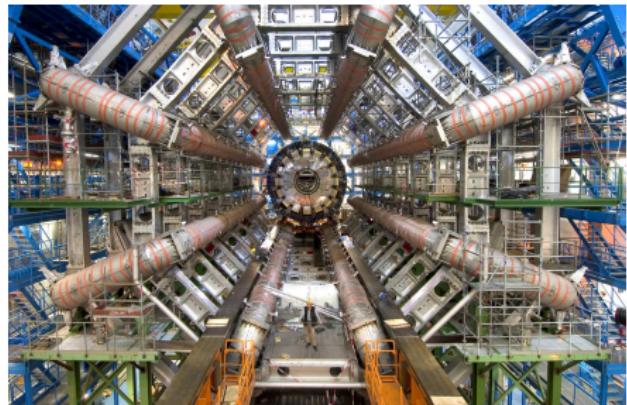
LHCb Experiment



UNIVERSITAT LJUBLJANA
Fakulteta za matematiko in fiziko

Veliki hadronski trkalnik (LHC)

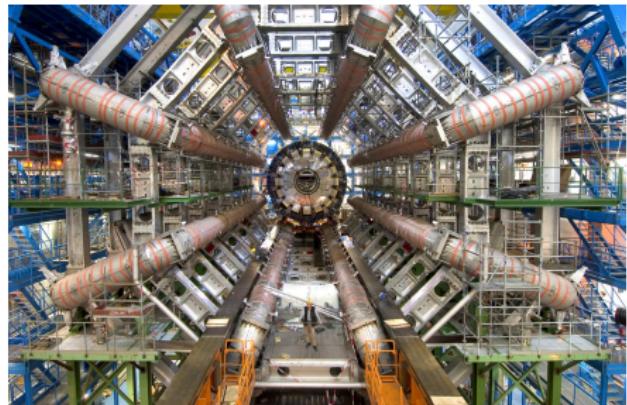
- Obseg 27 km
- Dve cevi z gručami protonov
- Razpoložljiva težiščna energija
 $\sqrt{s} = 13 \text{ TeV}$
- Več eksperimentov, med njimi
ATLAS
(A Toroidal LHC ApparatuS)



Slika: Ogrodje eksperimenta ATLAS

Veliki hadronski trkalnik (LHC)

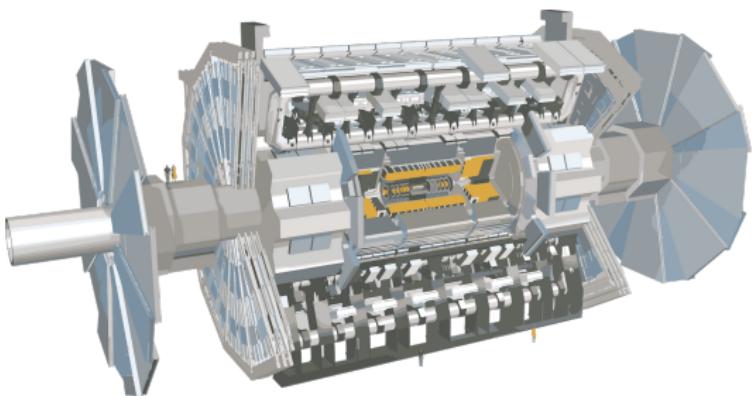
- Obseg 27 km
- Dve cevi z gručami protonov
- Razpoložljiva težiščna energija
 $\sqrt{s} = 13 \text{ TeV}$
- Več eksperimentov, med njimi
ATLAS
(A Toroidal LHC ApparatuS)



Slika: Ogrodje eksperimenta ATLAS

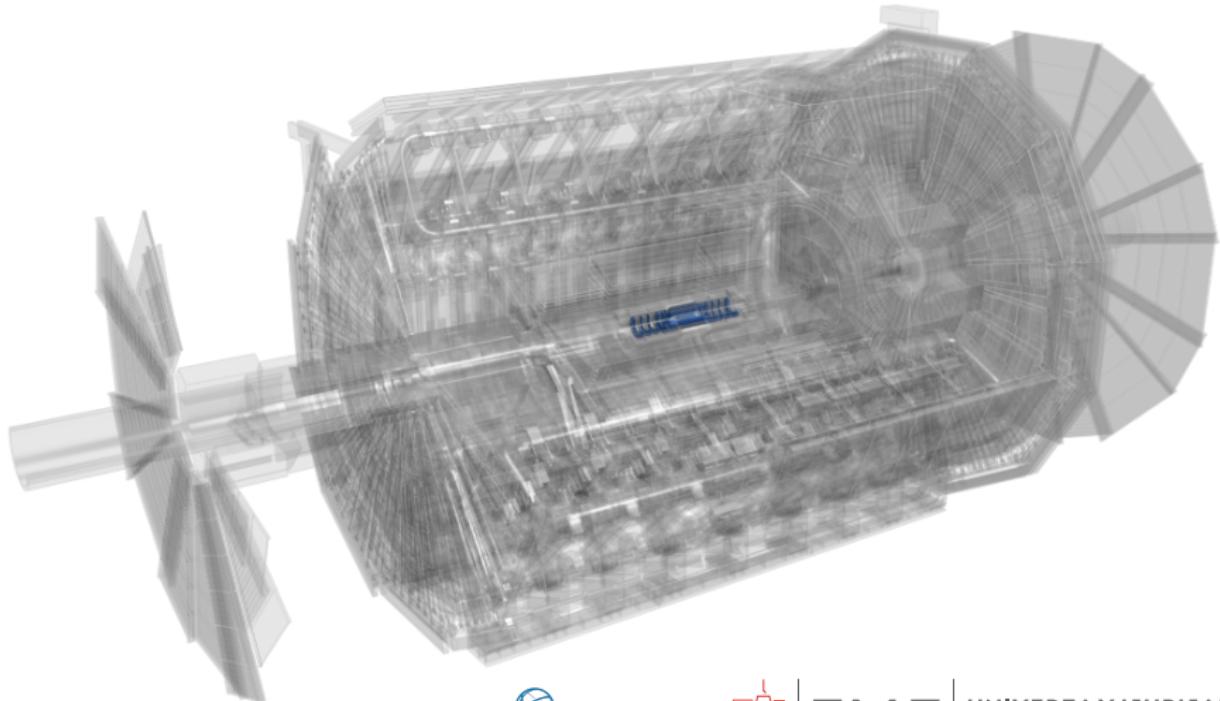
Sestava detektorja ATLAS

- Čebulna struktura
- Detekcija različnih delcev
- Zajem podatkov



Slika: Sestava detektorja ATLAS

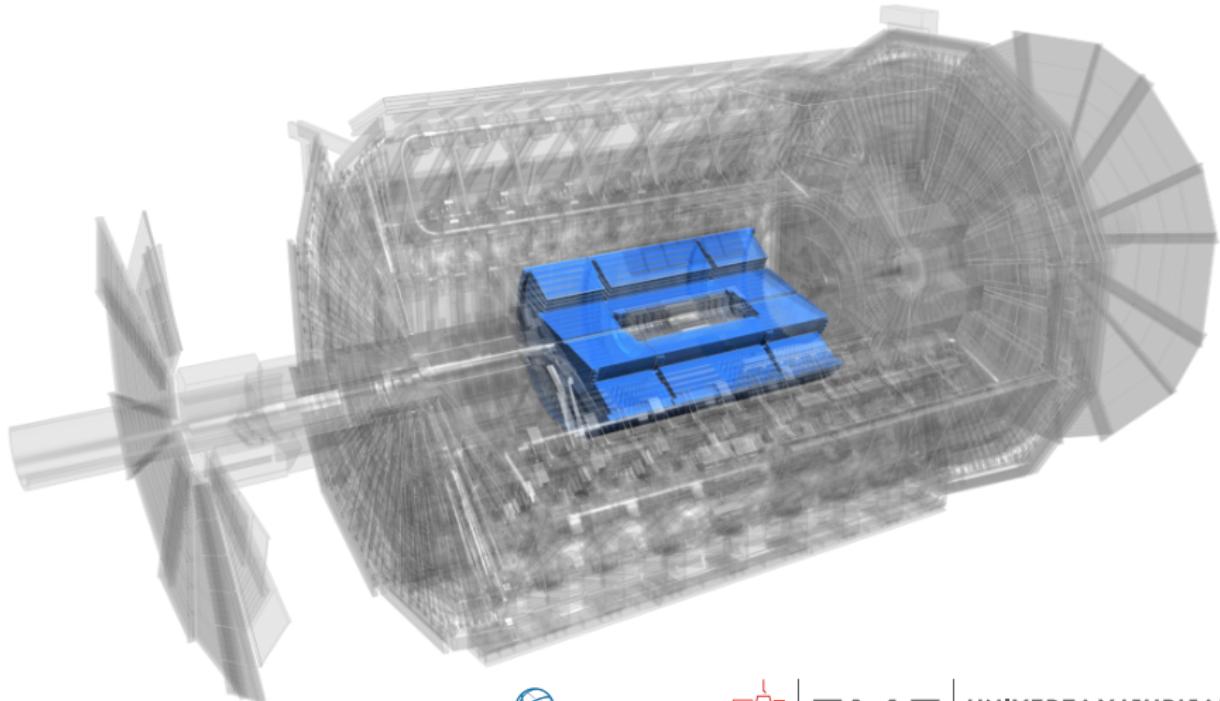
Sledilni detektor



FMF

UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

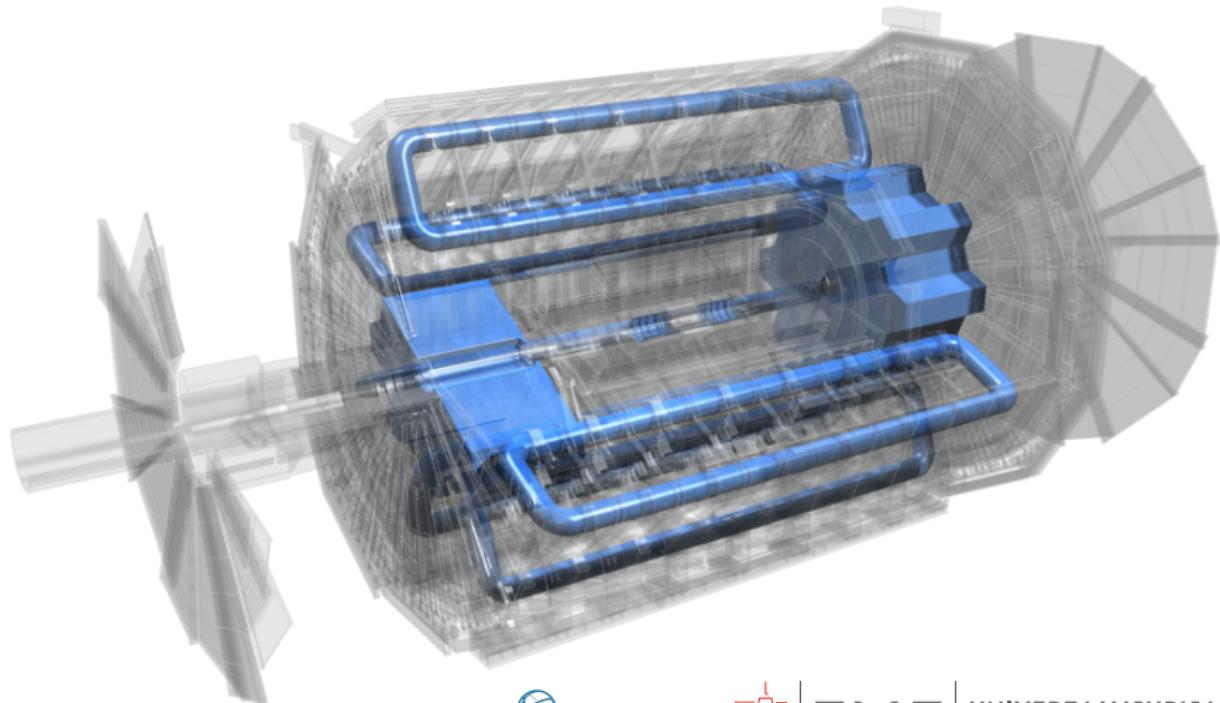
Hadronski in EM kalorimeter



FMF

UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

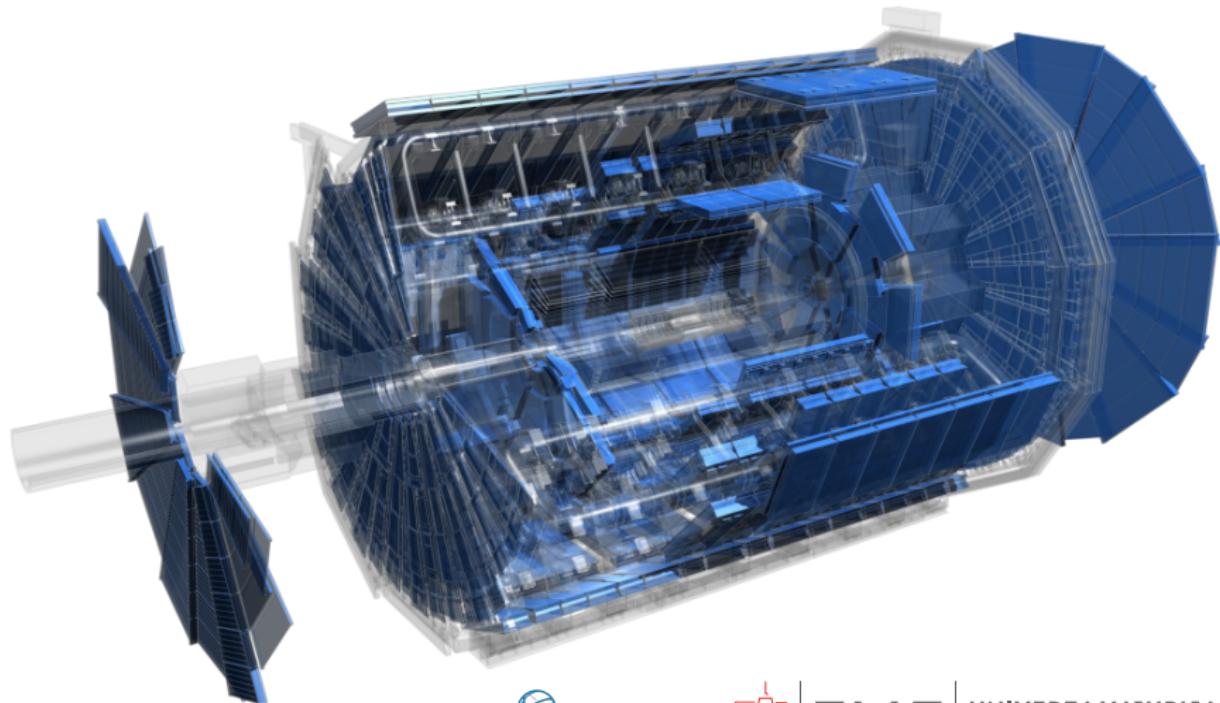
Magnetni sistem



FMF

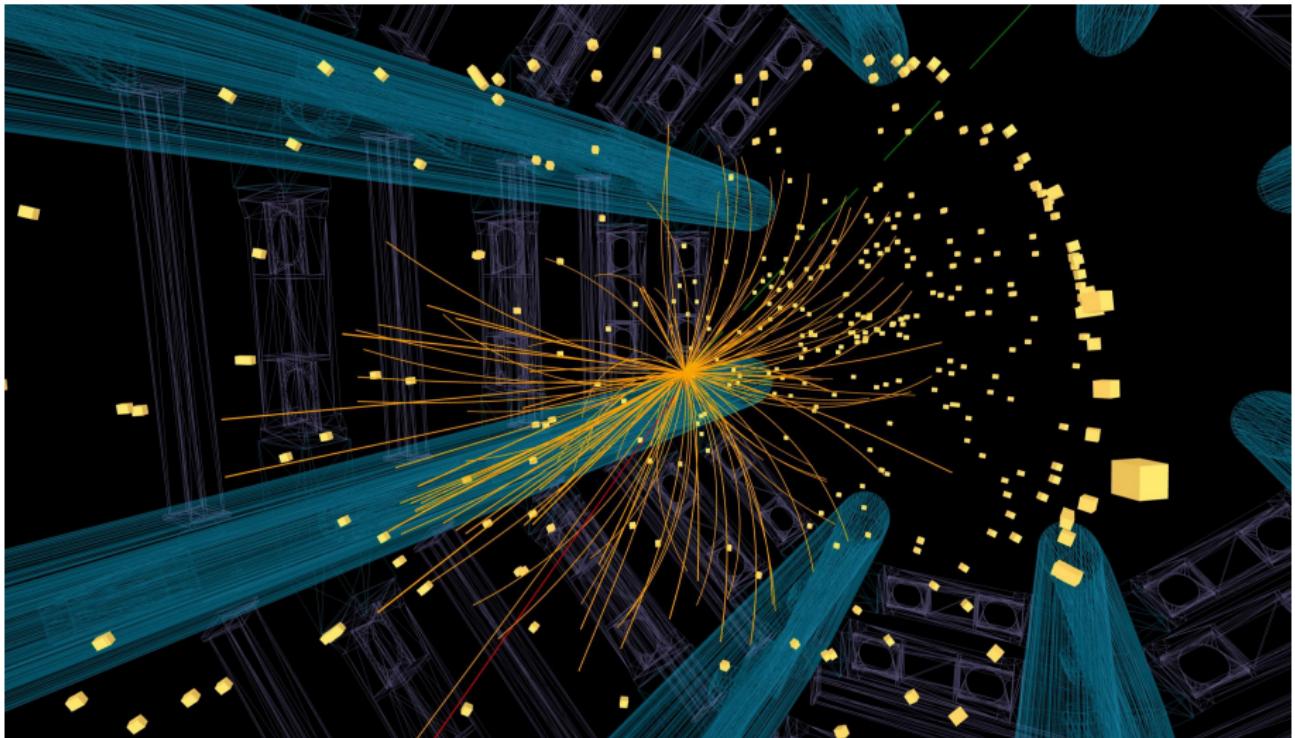
UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

Mionski spektrometer



FMF

UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

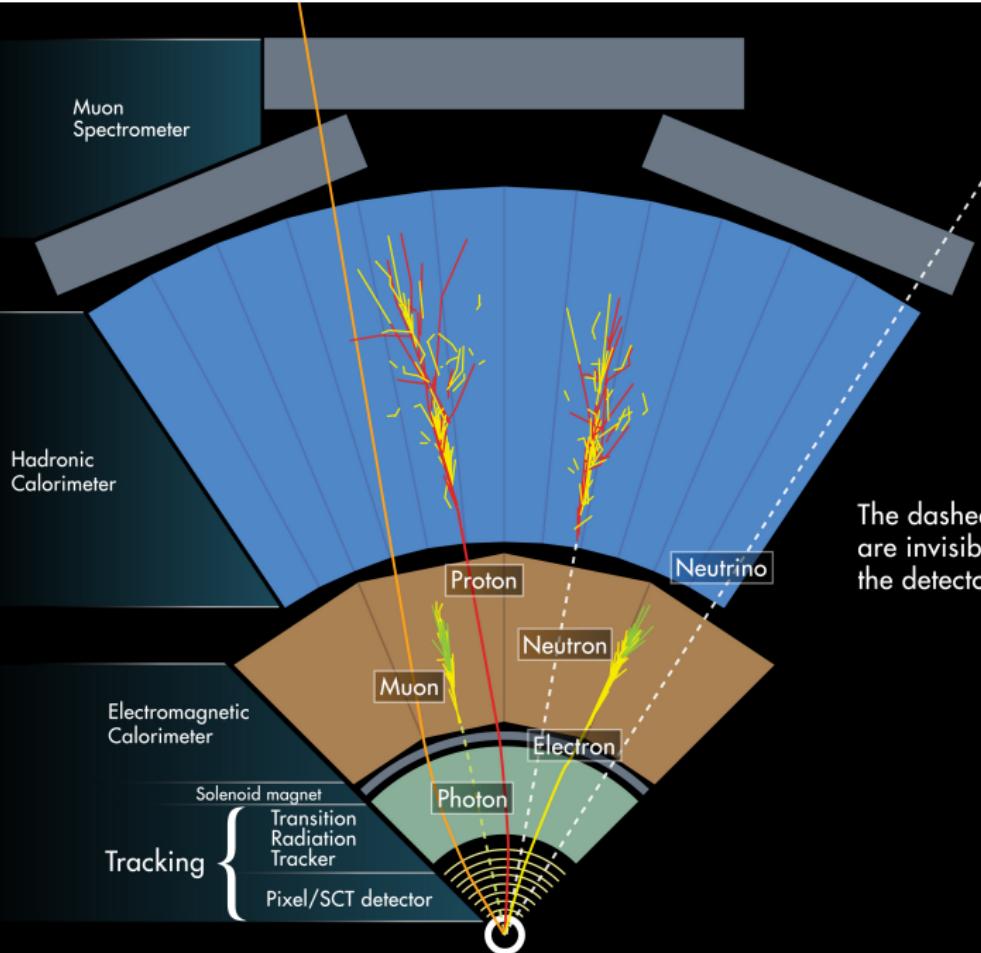


Slika: Primer dogodka v detektorju ATLAS



FMF

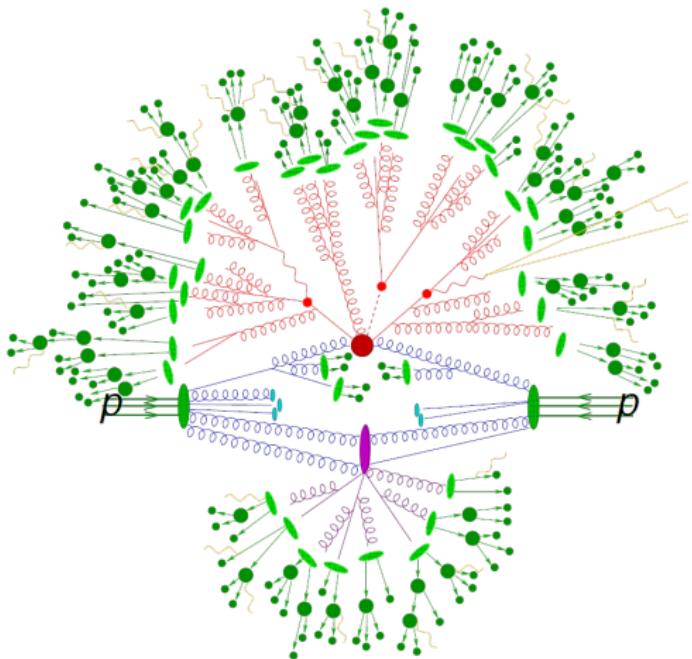
UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko



The dashed tracks
are invisible to
the detector

Simulacije dogodkov

- Monte Carlo simulacije
- Generiranje dogodkov v več korakih
- Simuliranje interakcije med delci in detektorjem
- Lahko simulirajo tudi hipotetične procese

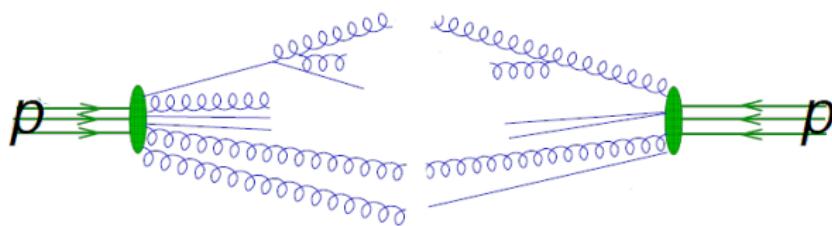


Slika: Primer simulacije dogodka – vsaka barva predstavlja svoj korak

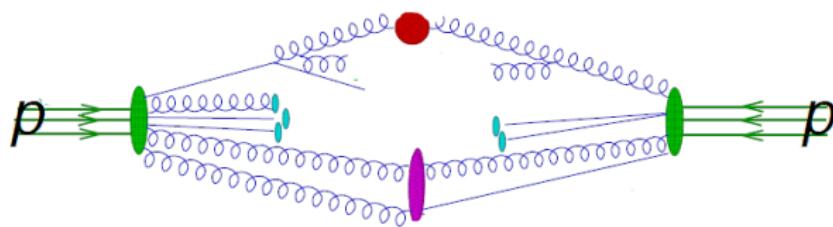


UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

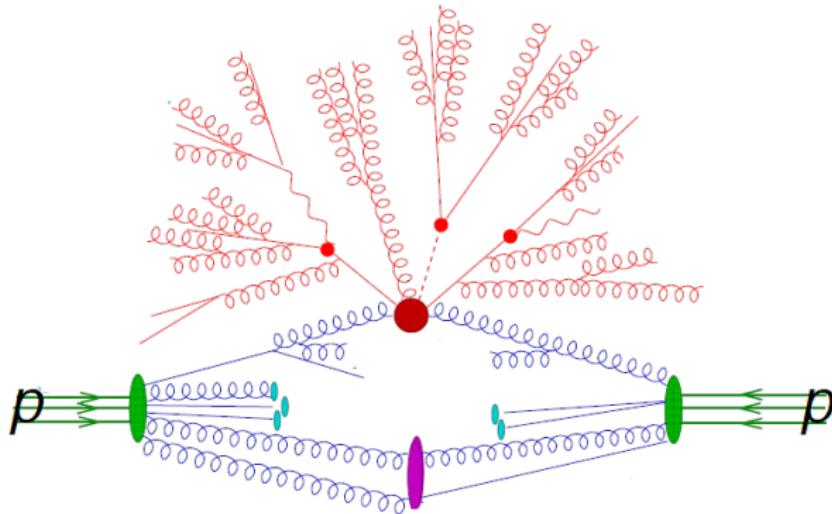


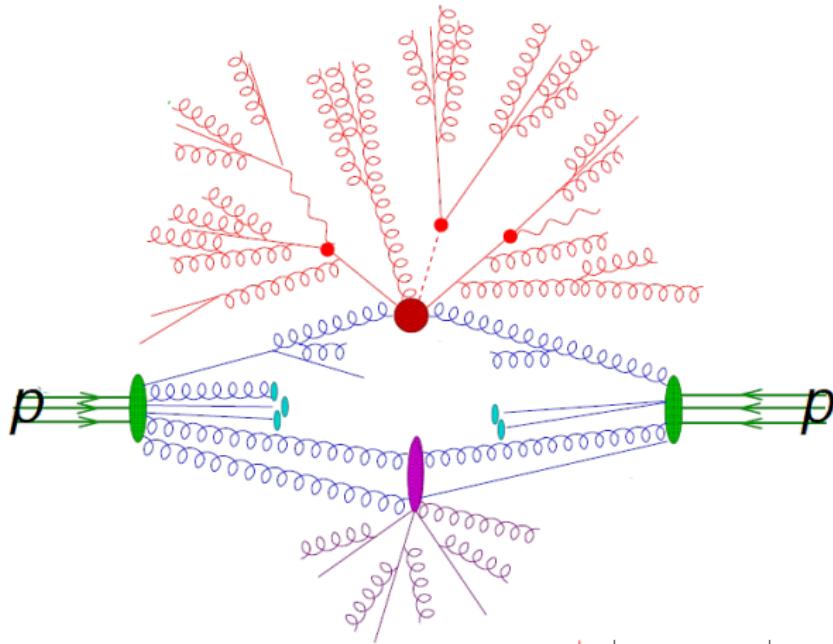


UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko



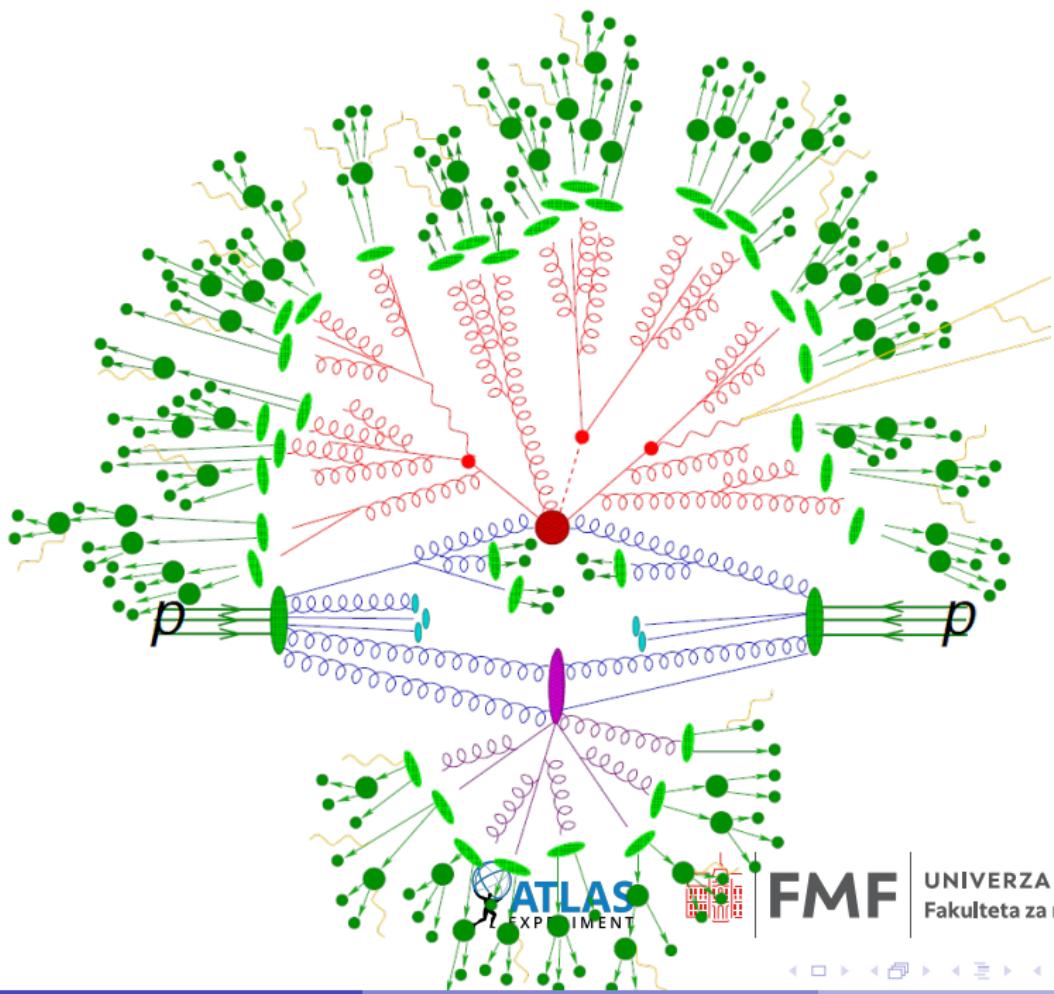
UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko





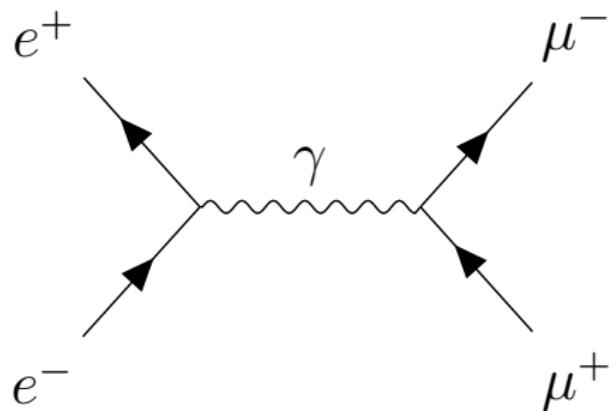
FMF

UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

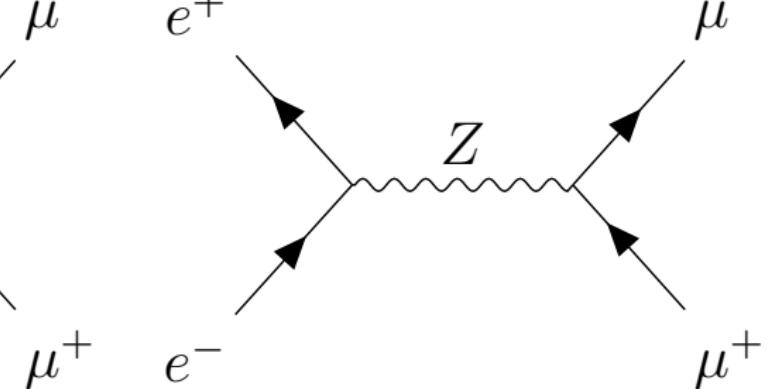


Signal in ozadje

Iščemo iglo (signal) v kopici sena (ozadje).



Slika: Primer ozadja za proces
 $e^+e^- \rightarrow Z \rightarrow \mu^+\mu^-$



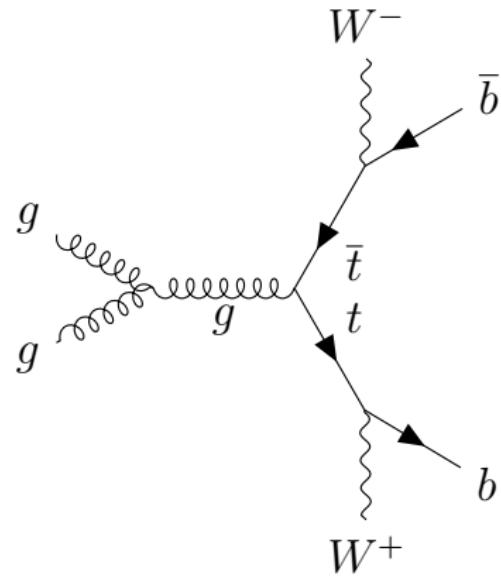
Slika: Primer signala za proces
 $e^+e^- \rightarrow Z \rightarrow \mu^+\mu^-$



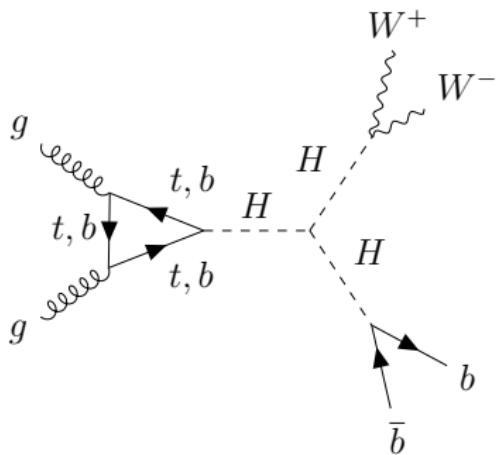
FMF

UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

Signal in ozadje



Slika: Primer ozadja za proces
 $gg \rightarrow HH \rightarrow b\bar{b}WW$



Slika: Primer signala za proces
 $gg \rightarrow HH \rightarrow b\bar{b}WW$



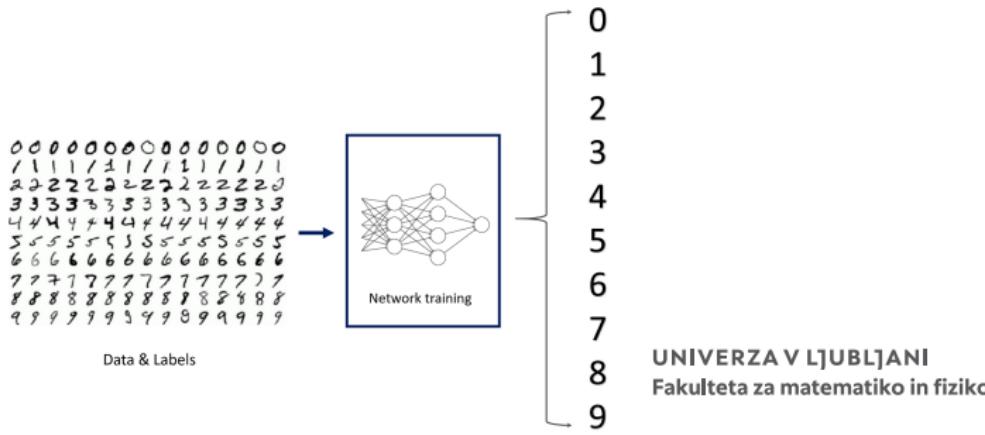
UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

Strojno učenje

"Strojno učenje je področje, ki se ukvarja z omogočanjem računalnikov, da se učijo, ne da bi jih za to eksplicitno programirali."

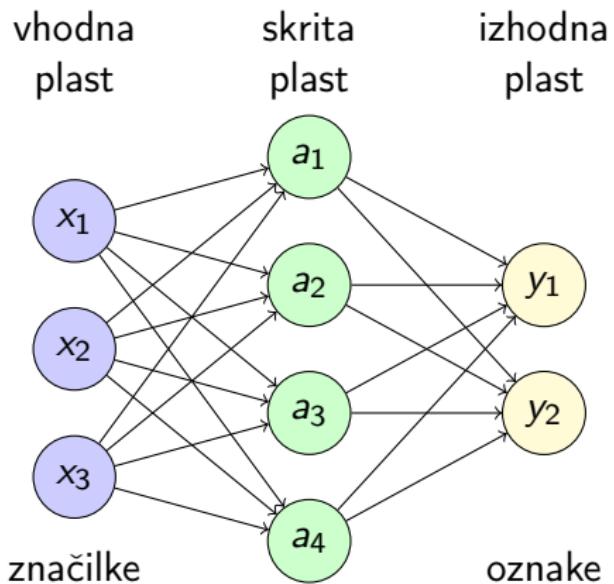
Arthur Samuel, 1959

- Vhodni podatki – značilke
- Izhodni podatki – oznake ali napovedi
- Primer spodaj: značilke so "slike številk", oznake pa števila od 0 do 10.

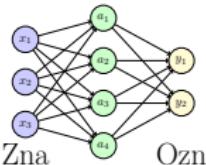


Nevronske mreže

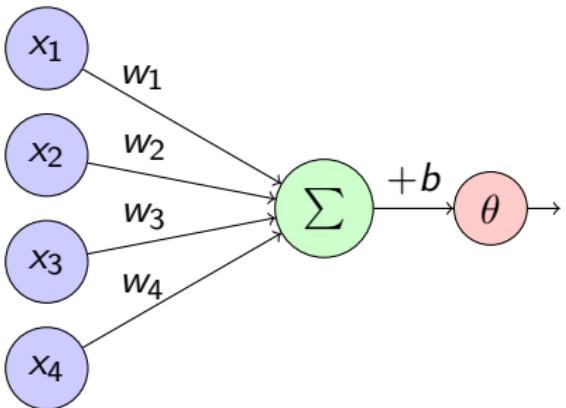
- Povezani sloji nevronov
- Značilke aktivirajo prvi sloj (x).
- Vsak sloj vpliva na aktivacijo naslednjega sloja.
- Zadnji sloj predstavlja napoved modela – oznake (y).



Aktivacije



- Aktivacija nevrona odvisna od aktivacij v prejšnjem sloju.
- Linearna kombinacija z utežmi w
- Statistična pristranskost b
- Nelinearna *aktivacijska funkcija* θ
- $a = \theta(x_1 w_1 + \dots + x_n y_n + b)$



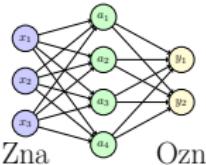
x_i : aktivacije prvega sloja;

w_i : uteži;

b : statistična pristranskost;

θ : aktivacijska funkcija

Učenje nevronskeih mrež



- Velika količina naborov značilk s podanimi oznakami (\mathbf{y})

L : funkcija izgube;

W : nabor uteži in pristranskosti;

\mathbf{y} : podane oznake;

$\hat{\mathbf{y}}$: napovedane oznake;

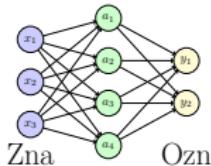
α : korak učenja



UNIVERZA V LJUBLJANI

Fakulteta za matematiko in fiziko

Učenje nevronskeih mrež



- Velika količina naborov značilk s podanimi oznakami (\mathbf{y})
- Oznake, ki jih model napove: $\hat{\mathbf{y}}$

L : funkcija izgube;

W : nabor uteži in pristranskosti;

\mathbf{y} : podane oznake;

$\hat{\mathbf{y}}$: napovedane oznake;

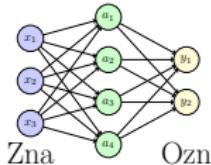
α : korak učenja



FMF

UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

Učenje nevronskeih mrež



- Velika količina naborov značilk s podanimi oznakami (\mathbf{y})
- Oznake, ki jih model napove: $\hat{\mathbf{y}}$
- Funkcija izgube: $L = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \sum_i (y_i - \hat{y}_i)^2$

L : funkcija izgube;

W : nabor uteži in pristranskosti;

\mathbf{y} : podane oznake;

$\hat{\mathbf{y}}$: napovedane oznake;

α : korak učenja

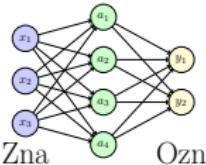


FMF

UNIVERZA V LJUBLJANI

Fakulteta za matematiko in fiziko

Učenje nevronskeih mrež



- Velika količina naborov značilk s podanimi oznakami (\mathbf{y})
- Oznake, ki jih model napove: $\hat{\mathbf{y}}$
- Funkcija izgube: $L = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \sum_i (y_i - \hat{y}_i)^2$
- Funkcija izgube je odvisna od vseh uteži in pristranskosti (\mathbf{W}) v mreži.

L : funkcija izgube;

\mathbf{W} : nabor uteži in pristranskosti;

\mathbf{y} : podane oznake;

$\hat{\mathbf{y}}$: napovedane oznake;

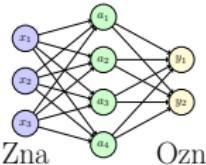
α : korak učenja



UNIVERZA V LJUBLJANI

Fakulteta za matematiko in fiziko

Učenje nevronskeih mrež



- Velika količina naborov značilk s podanimi oznakami (\mathbf{y})
- Oznake, ki jih model napove: $\hat{\mathbf{y}}$
- Funkcija izgube: $L = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \sum_i (y_i - \hat{y}_i)^2$
- Funkcija izgube je odvisna od vseh uteži in pristranskosti (\mathbf{W}) v mreži.
- Spreminjanje \mathbf{W} , da se minimizira funkcija izgube – učenje.

L : funkcija izgube;

\mathbf{W} : nabor uteži in pristranskosti;

\mathbf{y} : podane oznake;

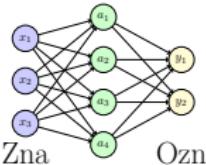
$\hat{\mathbf{y}}$: napovedane oznake;

α : korak učenja



UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

Učenje nevronskeih mrež



- Velika količina naborov značilk s podanimi oznakami (\mathbf{y})
- Oznake, ki jih model napove: $\hat{\mathbf{y}}$
- Funkcija izgube: $L = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \sum_i (y_i - \hat{y}_i)^2$
- Funkcija izgube je odvisna od vseh uteži in pristranskosti (\mathbf{W}) v mreži.
- Spreminjanje \mathbf{W} , da se minimizira funkcija izgube – učenje.
- $\mathbf{W}_{\text{nove}} = \mathbf{W}_{\text{stare}} + \alpha \nabla L(\mathbf{W})$

L : funkcija izgube;

\mathbf{W} : nabor uteži in pristranskosti;

\mathbf{y} : podane oznake;

$\hat{\mathbf{y}}$: napovedane oznake;

α : korak učenja



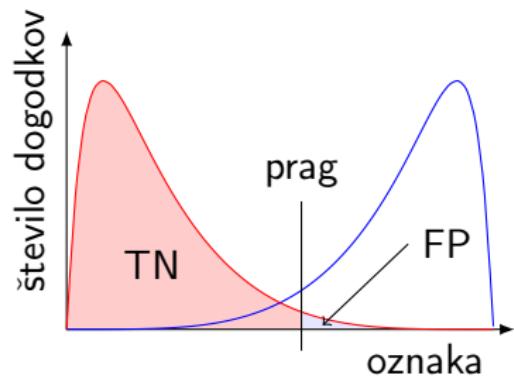
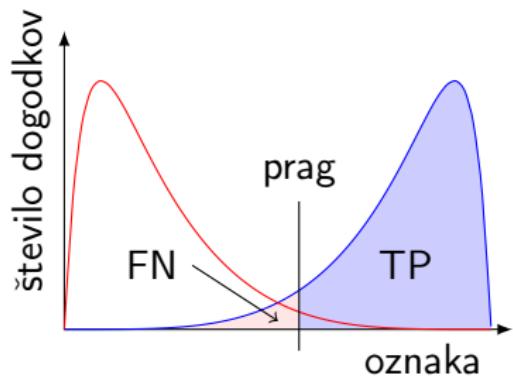
UNIVERZA V LJUBLJANI

Fakulteta za matematiko in fiziko

Mere za uspešnost modelov

Skozi natrenirano mrežo pošljemo veliko naborov značilk z znanimi označkami. Ločimo štiri vrste dogodkov:

- *pravilno pozitivni* (TP): model je pravilno napovedal prisotnost bozona,
- *lažno pozitivni* (FP): model je napovedal prisotnost bozona, v resnici pa ga ni bilo,
- *pravilno negativni* (TN): model je pravilno napovedal odsotnost bozona,
- *lažno negativni* (FN): model je napovedal odsotnost bozona, v resnici pa je bil.



Mere za uspešnost modelov

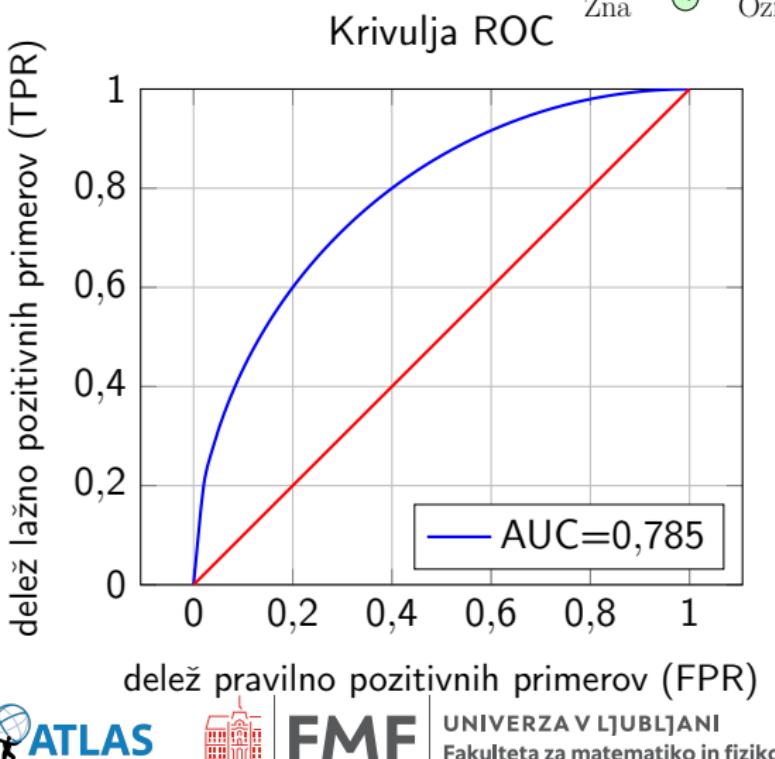
- Delež pravilno pozitivnih primerov (občutljivost)

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

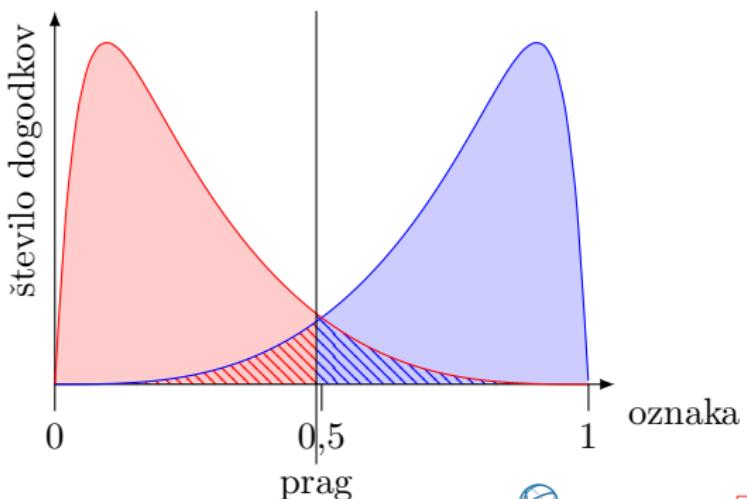
- Delež lažno pozitivnih primerov

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}}$$

- Parametrična krivulja ROC
- Ploščina pod krivuljo (AUC)



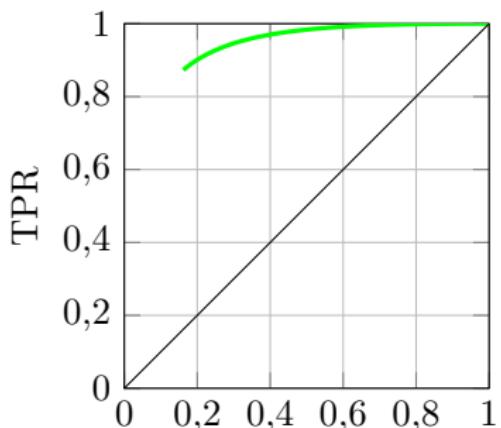
- FP: lažno pozitivni primeri
- FN: lažno negativni primeri
- TN: pravilno negativni primeri
- TP: pravilno pozitivni primeri



prag = 0,490

$$TPR = \frac{TP}{TP + FN} = \frac{\text{blue}}{\text{blue} + \text{red}} = 0,865$$

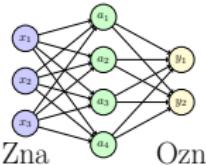
$$FPR = \frac{FP}{FP + TN} = \frac{\text{blue}}{\text{blue} + \text{red}} = 0,153$$



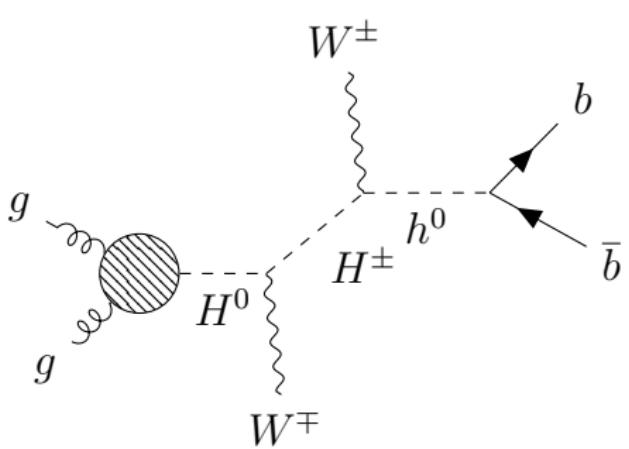


UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

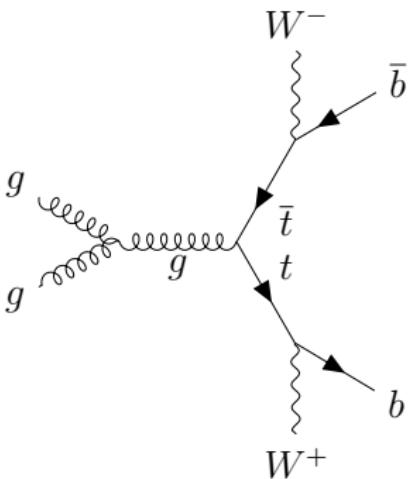
Primer uporabe: globoke mreže



Nastanek hipotetičnih težkih Higgsovih bozonov H^0, H^+, H^- .



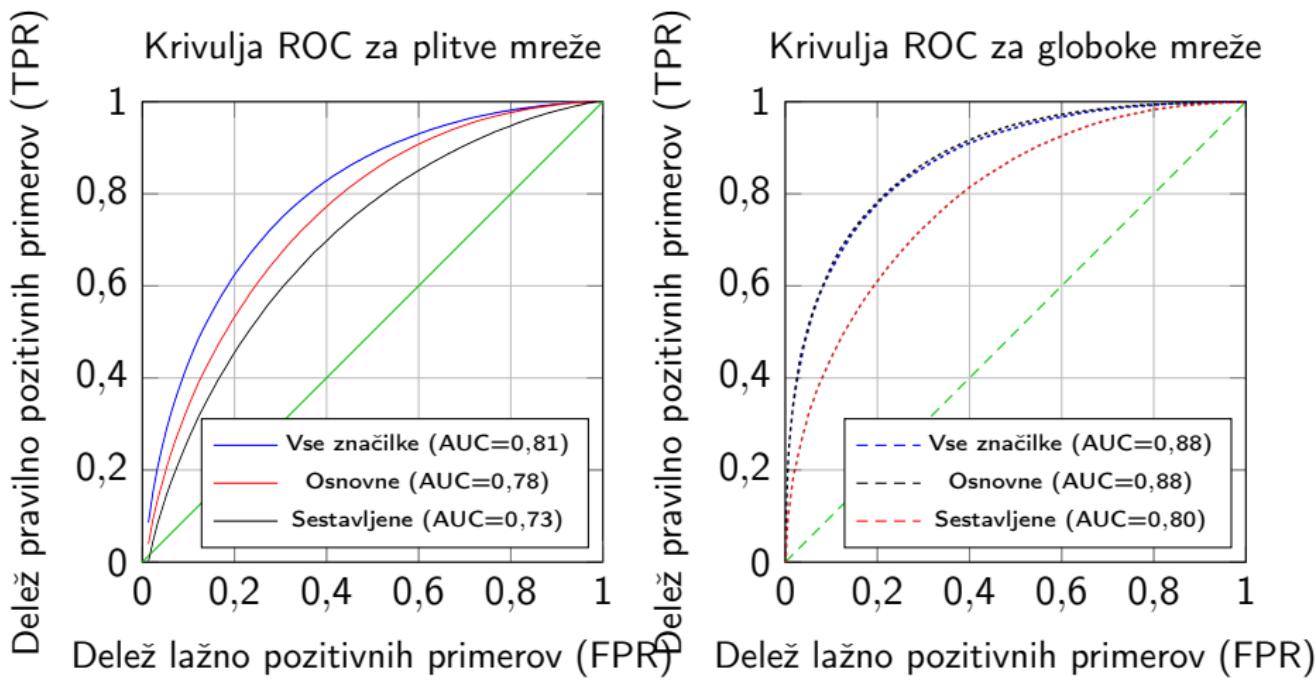
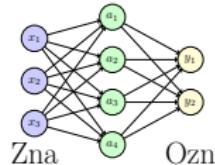
Slika: Proses signala.



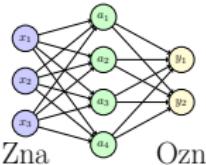
Slika: Proses ozadja.

Primer uporabe: globoke mreže

- Uporabljene značilke: 21 osnovnih in 7 sestavljenih.
- Dve vrsti mrež: plitve in globoke.

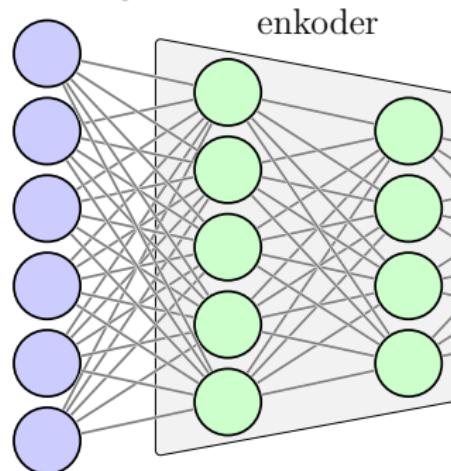


Avtoenkoderji



Poseben primer nevronske mreže. Učenje na ozadju in zaznavanje odstopenj.

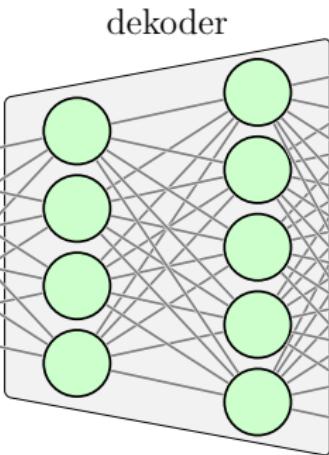
vhodni sloj



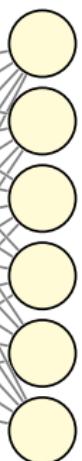
latentni
sloj



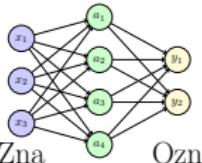
izhodni sloj



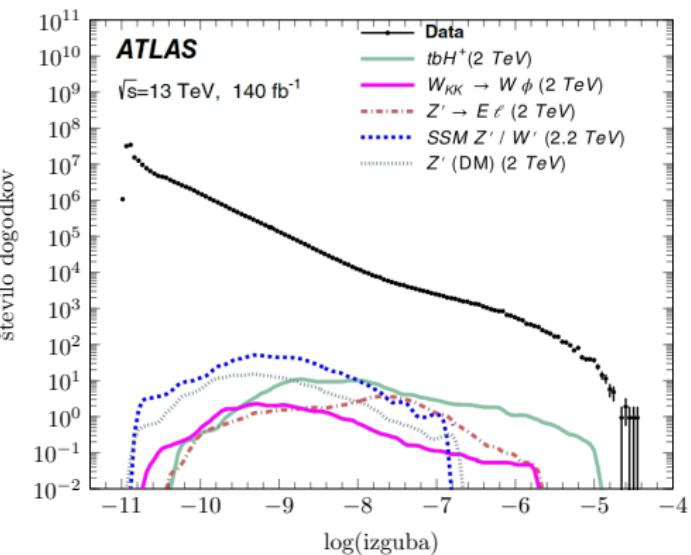
izhodni sloj



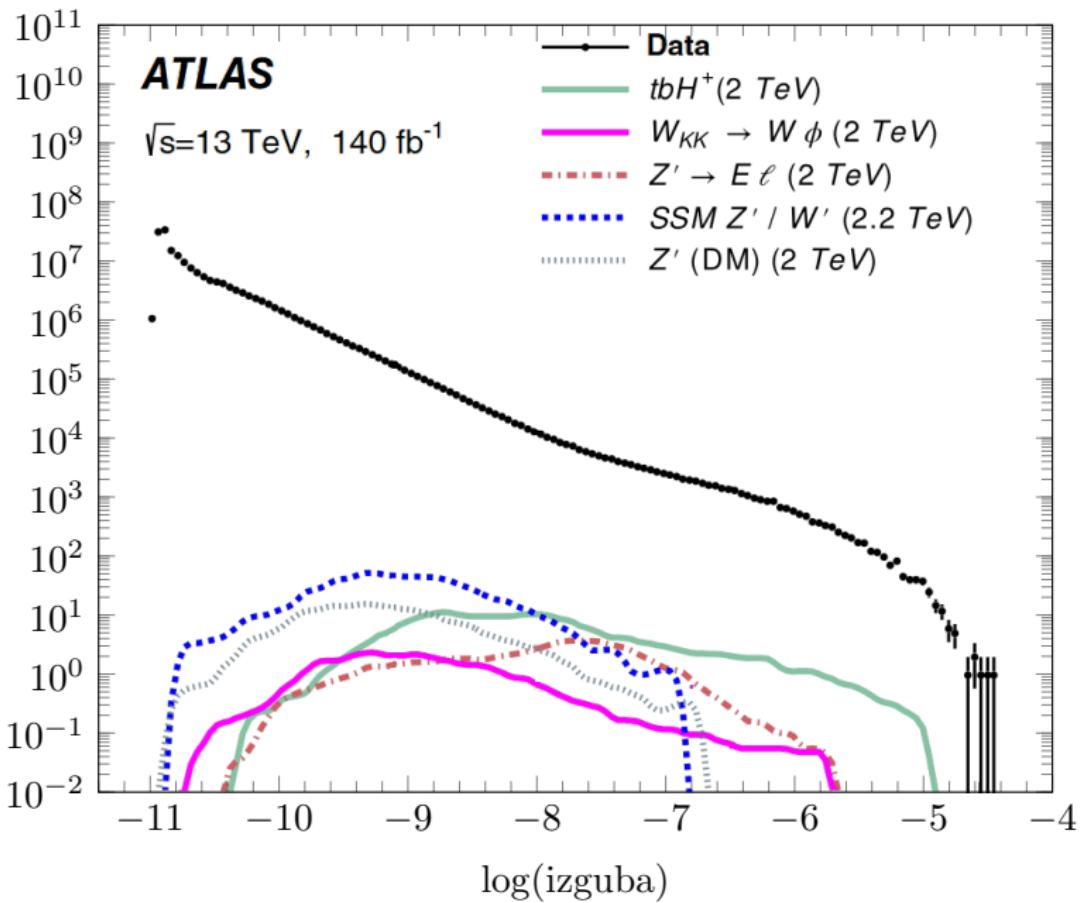
Primer uporabe avtoenkoderjev



- 1278 značilk x , 1278 oznak y
- Latentni sloj dimenzije 200
- Funkcija izgube
 $L = \text{izguba} = \|x - y\|^2$
- Treniranje na simulacijah Standardnega modela
- Preizkus na pravih meritvah.
- Premalo meritev za statistično dovolj gotovo potrditev.



UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko



Zaključek

- Obetavno področje.
- Deluje v principu, ni še veliko uporabnih rezultatov.
- Zelo hitre razvoj tehnologij in metod.
- Potrebnih več meritev ali višje energije.
- Na voljo vedno bolj izpopolnjena orodja.
- S tem se ukvarjajo tudi na IJS (F9).



UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko



Hvala za pozornost!



FMF

UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

Dodatek: luminoznost

Pričakovano število dogodkov (trkov) N za določen proces:

$$N = \sigma \int \mathcal{L} dt = \sigma L,$$

kjer je \mathcal{L} luminoznost, L pa integrirana luminoznost.

$$\mathcal{L} = \frac{\mathcal{N}^2 n_b f}{A},$$

kjer je \mathcal{N} število protonov v gruči, n_b število gruč, A pa efektiven presek žarka na mestu trka.



UNIVERZA V LJUBLJANI
Fakulteta za matematiko in fiziko

Dodatek: nevronske mreže bolj matematično

Nevronska mreža je funkcija $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$, ki pretvori značilke $\mathbf{x} \in \mathbb{R}^n$ v oznake $\mathbf{y} = \mathbb{R}^m$. Aktivacije i -tega sloja $\mathbf{a}^{(i)}$ se lahko zapišejo kot aktivacije $i - 1$ -tega sloja $\mathbf{a}^{(i-1)}$ kot

$$\mathbf{a}^{(i)} = \theta(\mathbf{W}\mathbf{a}^{(i-1)} + \mathbf{b}) = \sigma_n(\mathbf{a}^{i-1}).$$

Vektor \mathbf{b} so pristranskosti, matrika \mathbf{W} so uteži, θ pa je aktivacijska funkcija. Prehod med slojema označimo s σ_i . Celotno mrežo lahko zapišemo kot

$$\mathbf{y} = f(\mathbf{x}) = (\sigma_j \circ \sigma_{j-1} \circ \cdots \circ \sigma_2 \circ \sigma_1)(\mathbf{x}),$$

kjer je j število slojev.



FMF

UNIVERZA V LJUBLJANI

Fakulteta za matematiko in fiziko