

Analiza svojstava čestičnih snopova pomoću neuralnih mreža

Ivan Jerčić

Fizički odsjek, Prirodoslovno-matematički fakultet, Bijenička 32, Zagreb

28. siječnja 2021.

Pregled

Uvod

Teorijska pozadina

Opis simuliranog sustava

Eksperimentalna metoda

Opis metode pomoću primjera

Generator jetova

Klasifikator

Ispravljanje vjerojatnosnih distribucija

Opis algoritma

Rezultati i rasprava

Raspad čestice mase 25

Raspad čestice mase 18.1

Zaključak


Teorijska pozadina

Hipoteza zatočenja - Sva izolirana kvantna stanja su bojno neutralna


- kvarkove pronalazimo samo unutar hadrona

U sudarima visokih energija nastaju kvarkovi

- Primjer: $e^+e^- \rightarrow q\bar{q}$
- Kvark $\xrightarrow{\text{hadronizacija}}$ jet
- jet = nabijene čestice i fotoni
- ne opažamo sve čestice - mali vijek trajanja



Koraci hadronizacije




Opis simuliranog sustava

	A		B		C		D		E	
masa	0.1		0.6		1.3		1.9		4.4	
raspadi	1	A	0.7	B	1	C	0.3	AC	0.6	CC
			0.3	AA			0.3	AA	0.4	E
							0.4	D		
	F		G		H		I		J	
masa	6.1		8.4		14.2		18.1		25	
raspadi	0.5	AA	0.9	BB	0.6	DD	1	FG	0.5	FI
	0.5	BC	0.1	AF	0.25	DE			0.4	GH
					0.15	EF			0.1	EE

Opis simuliranog sustava

- 3 iteracije
- lista 4-vektora impulsa i energije



Eksperimentalna metoda

Generirane podatke smatramo nepoznatim, predstavljaju stvarne podatke

Cilj:

- reproducirati skrivene rezonance
- reproducirati vjerojatnosti pojedinih raspada


Generator jetova

- U svakom koraku za masu M biramo (a, b) iz distribucije $\rho_M : \mathbb{R}^2 \rightarrow \mathbb{R}$
- Nove mase računamo kao:

$$\begin{aligned}\frac{aM}{2} &= E_1, & \frac{abM}{2} &= p_1 \\ p_2 &= -p_1, & \left(1 - \frac{a}{2}\right) M &= E_2 \\ m_1^2 &= M^2 \left(\frac{a^2}{4} - \frac{a^2 b^2}{4} \right) \\ m_2^2 &= M^2 \left(\left(1 - \frac{a}{2}\right)^2 - \frac{a^2 b^2}{4} \right)\end{aligned}$$

- Uniformna distribucija kuteva

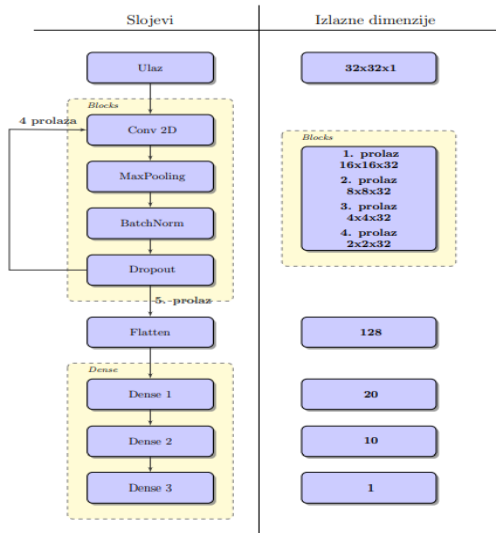
Generator jetova



- Proces ponavljamo 3 puta
→ najviše 8 čestica - 'jet'
- Parametri pojedinog raspada vezan sa sustav mirovanja pojedine čestice
- Jet je određen sa 7 parova (a,b)

Jet prikazujemo histogramom (slikom) energije s osima (θ, ϕ)

Klasifikator



Ispravljanje vjerojatnosnih distribucija

Gustoća vjerojatnosti za pojedini jet $\rho(z)$:

$$\rho(z) = \frac{C(z)}{1 - C(z)} q(z),$$

Nazavisnost raspada \rightarrow jednađba (2) postaje:

$$\prod_{i=1}^7 \rho(a_i, b_i | m_i) = \frac{C(z)}{1 - C(z)} \prod_{i=1}^7 q(a_i, b_i | m_i).$$

Logaritmiranje:

$$\sum_{i=1}^7 \ln \rho(a_i, b_i | m_i) = \ln C(z) - \ln (1 - C(z)) + \sum_{i=1}^7 \ln q(a_i, b_i | m_i).$$

Rješavanje linearnog sustava jednađbi?

Ispravljanje vjerojatnosnih distribucija

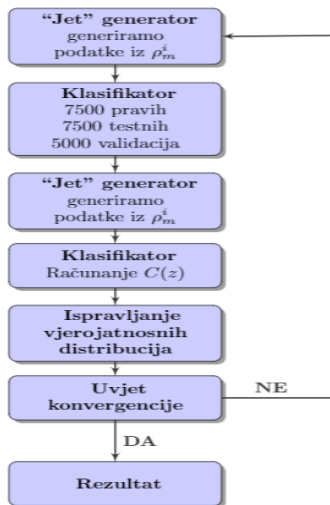
- Visoka dimenzionalnost
 - Klasifikator nije optimalan
-
- nestabilnost
 - numerički zahtjevno

Gustoća vjerojatnosti $\rho(a_i, b_i | m_i)$ - aproksimirana novom neuralnom mrežom $f(a, b, m)$

$$\rho(a, b | m) = \frac{e^{f(a, b, m)}}{\sum_{jk} e^{f(a_j, b_k, m)}},$$

- Gustoće vjerojatnosti su sad glatke
- minimiziranje L_2 udaljenosti → učenje neuralne mreže


Opis algoritma



Rezultati i rasprava

- Analiza → gustoća vjerojatnosti čestica masa 25 i 18.1
- 936 iteracija
 - nije istražen uvjet konvergencije
 - Pažnja posvećena prilagođavanju mreže i dokazivanju koncepta
- 100 000 pravih podataka
- 100 000 testnih podataka

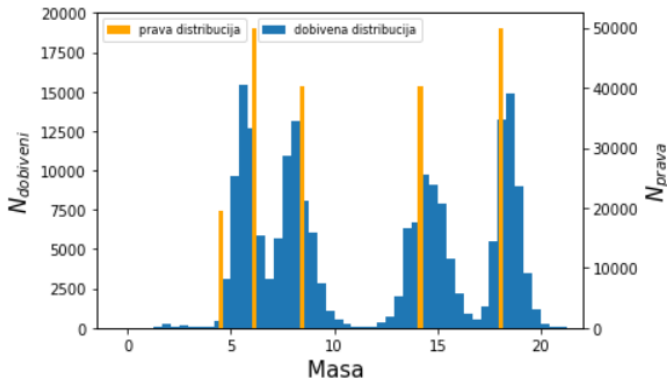
Raspad čestice mase 25



Prava distribucija:

- (0.54, 0.41) → 50%
 - (0.79, 0.53) → 40%
 - (1.00, 0.94) → 10%
-
- 2 grupacije oko točaka (0.51, 0.41) i (0.79, 0.51)


Raspad čestice mase 25



očekivane mase: 4.4, 6.1, 6.4, 14.2, 18.1

Raspad čestice mase 25


$$\frac{dN}{NdM} = C \sum_{i=1}^4 \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{1}{2} \left(\frac{M - M_{0i}}{\sigma_i}\right)^2\right),$$



Dobivene mase:

- 5.6 ± 0.7
- 8.2 ± 0.7
- 14.6 ± 0.8
- 18.5 ± 0.6

Raspad čestice mase 18.1



- Pravi raspad -
 $(a, b) = (0.90, 0.66)$
- Jedna grupacija oko točke
 $(0.90, 0.63)$

Rezultati analiza daljnih čestica - pokazuju istu uspješnost

Zaključak

Nova metoda za nalaženje distribucija raspada čestica pojedinih masa analizom jetova

Prednosti:

- Uspješna identifikacija rezonantnih čestica
- Neovisnost o reprezentaciji → primjenjiva na prave podatke (LHC)
- Primjenjivo na neprekidne distribucije
- Primjenjivo na širi spektar problema u kojima procjenjujemo nepoznatu vjerojatnosnu gustocu

Zaključak

Nedostaci:

- Ograničena razlučivost zbog diskretizacije
- Finija diskretizacija → puno kompliciraniji izračuni

Budućnost:

- Optimizacija hiperparametara
- Poboljšanje generatora
- Uvjet konvergencije
- Primjena na stvarne podatke

Literatura

- [1] Modern Particle Physics - Thomson. Jack Praill.
- [2] Jercic, M.; Poljak, N. Exploring the Possibility of a Recovery of Physics Process Properties from a Neural Network Model. Entropy 2020, 22, 994
- [3] Nielsen, M.A. Neural Networks and Deep Learning. Available online: neuralnetworksanddeeplearning.com/
- [4] Kingma, D.; Ba, J. A Method for Stochastic Optimization. In Proceedings of the International Conference on Learning Representations, Banff, AB, Canada, 14–16 April 2014.

Hvala na pažnji!