Produkcija tripleta Higgsovih bozona na Velikom hadronskom sudarivaču

Bilandžija, Filip

Master's thesis / Diplomski rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Science / Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:591113

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2025-03-22**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
FIZIČKI ODSJEK

Filip Bilandžija

Produkcija tripleta Higgsovih bozona na velikom hadronskom sudarivaču

Diplomski rad

Zagreb, 2023.

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
FIZIČKI ODSJEK

INTEGRIRANI PREDDIPLOMSKI I DIPLOMSKI SVEUČILIŠNI STUDIJ FIZIKA; SMJER ISTRAŽIVAČKI

Filip Bilandžija

Diplomski rad

Produkcija tripleta Higgsovih bozona na velikom hadronskom sudarivaču

Voditelj diplomskog rada: dr. sc. Vuko Brigljević

Ocjena diplomskog rada: _____

Povjerenstvo: 1. _____

2. _____

3. _____

Datum polaganja: _____

Zagreb, 2023.

Zahvaljujem se cijeloj CMS grupi na Institutu Ruđer Bošković, a posebno izv. prof. dr. sc. Vuki Brigljeviću i dr. sc. Mateju Roguljiću na vođenju ovog rada i mentoriranju. U tandemu su se izvrsno nadopunjavali te odgovarali (ili bar pokušavali odgovoriti) na sva moja pitanja i nedoumice, uporno mi ponavljali posve netrivijalne koncepte dok ih nisam shvatio, ali i pitali me pitanja za čiji sam odgovor trebao dobro razmisliti. Upravo iz takvih sam pitanja najviše i naučio u ovome radu.
Zahvalio bih se i kolegi Ericu Andreasu Vivodi kojeg sam zamolio da provjeri ispravnost teorijskog uvoda, što je on bez pogovora učinio. Zahvalio bih mu se i što me je poput starijeg brata vodio kroz ovaj studij te nebrojeno puta pričao o zanimljivostima kvantne teorije polja.
Zahvaljujem se kolegici Noi Somun koja mi je pomogla da osposobim BibTeX format u ovome radu, no i za neumorno lektoriranje mojih radova, velikoj pomoći na raznim kolegijima, i, općenito, trpljenju mene tijekom cijelog ovog studija.
Na kraju, zahvalio bih se i svojoj obitelji - bratu Lovri, ocu Saši i majci Suzani - koji su mi bili podrška tijekom cijelog ovog studija, pogotovo tijekom razdoblja pandemije, i na tome što su se trudili ne ometati me pri pisanju ovog rada, u čemu su zamalo i uspjeli.

Sažetak

U fizici elementarnih čestica, standardni model čestica opisuje svo (ili skoro svo) naše znanje tog područja. Također, standardni model predviđa procese i njihova svojstva poput udarnih presjeka s iznimnom preciznošću koja je u skladu s mnogim eksperimentima. No, standardni model nije zaokružen kao teorija jer još uvijek postoje dijelovi fizike poput gravitacije ili tamne tvari koji njime nisu obuhvaćeni. Zbog toga postoji mnoštvo modela kojima je cilj proširiti standardni model i na ta područja. Jedno od jednostavnijih mogućih proširenja nalazi se u Higgsovom sektoru. U standardnom je modelu rješenje kojim se postiže Higgsov mehanizam, ključan za dobivanje masa čestica, najjednostavnije moguće. No, ništa ne sprječava postojanje nekog kompleksnijeg rješenja. Jedno takvo kompleksnije rješenje je u obliku dva dodatna skalarna polja u Higgsovom sektoru čime se predviđa postojanje dvije nove skalarne čestice, X i Y. Te čestice, u režimu masa $M_X > M_Y + M_H$ i $M_Y > 2M_H$, mogu se raspasti u 3 Higgsova bozona u kaskadi $X \to YH \to HHH$. Iako u Standardnom modelu postoje mogućnost produkcije 3 Higgsova bozona u sudaru, udarni je presjek na taj proces iznimno malen i iznosi oko 0.1 fb.

U ovome radu predstavljamo rezonantnu potragu za tim dvjema česticama u njihovom raspadu na 3 Higgsova bozona u kinematičkom režimu u kojem će producirani Higgsovi bozoni imati dovoljno veliki impuls da parovi b kvarkova iz njihovo raspada budu kolimirani. Prvo je dana analiza koristeći Monte-Carlo simulacije za pozadinu i dane su očekivane vrijednosti gornjih granica udarnog presjeka signalnog procesa. Zbog sistematskog neslaganja podataka sa Monte-Carlo simulacijama, dana je i alternativna, realističnija, analiza gdje je pozadina procjenjena iz podataka. Detaljno je objašnjena metoda procjene pozadine te su dani rezultati metode zajedno s rezultatima statističkih testova. Na kraju su dane i očekivane vrijednosti gornjih granica za udarni presjek signalnog procesa dobivene metodom podatkovne procjene pozadine. Te očekivane gornje granice udarnih presjeka su reda veličine 1 fb u režimima masa u kojima je svaki par b kvarkova kolimiran. U režimima gdje postoji velika mogućnost da jedan od parova b kvarkova nije kolimiran, naša analiza nije dovoljno osjetljiva te se očekivana gornja granica povećava za nekoliko redova veličine.

Ključne riječi: Model dva realna skalara, Higgsov bozon, debeli mlaz, podatkovna procjena pozadine, 2DAbecedna metoda

Production of Higgs triplets at LHC

Abstract

The Standard Model of Particles is describing all (or almost all) of our knowledge in the field of particle physics. Also, it is predicting processes and their properties, such as cross sections, with great precision that is in agreement with the experiment. But the Standard Model is incomplete as a theory because there are still parts of physics that are not covered by it such as gravity or dark matter. One of the simple possible ways to extend the Standard Model is found in its Higgs sector. In the Standard Model, the solution that achieves the Higgs mechanism, crucial for obtaining the masses of particles, is the simplest possible. However, nothing prevents the existence of a more complex solution. One such solution is in the form of two additional scalar fields in the Higgs sector, which predicts the existence of two new scalar particles, X and Y. Those particles, in the mass regime $M_X > M_Y + M_H$ and $M_Y > 2M_H$, can decay into 3 Higgs bosons in $X \to YH \to HHH$ cascade. Although in the Standard Model there is a possibility of producing 3 Higgs bosons in a collision, the expected cross-section for that process is extremely small and amounts to about 0.1 fb.

In this thesis, we present a resonant search for those two particles in their 3 Higgs boson decay in the kinematic regime in which the produced Higgs bosons are ultrarelativistic and, therefore, each pair of b jets from the decays is collimated. First, an analysis is given using Monte-Carlo simulation for the background and the expected values of the upper limits of the cross-section of the signal process are given. Due to the systematic disagreement of the data with the Monte-Carlo simulations, an alternative analysis is given where the background is estimated from the data. The data-driven background estimation method is explained in detail and the results of the method are given together with the results of statistical tests. In the end, the expected values of the upper limits for the cross-section of the signal process, obtained by the data-driven background estimation method, are given. Those expected upper limits on the cross-sections are of the order of 1 fb in mass regimes where each pair of b jets is collimated. In regimes where there is a high possibility of a b jet pair not being collimated, our analysis is not sensitive enough, and the expected upper limit increases by several orders of magnitude.

Keywords: Two real singlets model, Higgs boson, fat jet, data-driven background estimation, 2DAlphabet method

Sadržaj

1 Teorijski uvod i motivacija **1**

1.1 Pregled standardnog modela čestica 1

1.2 Higgsov mehanizam 4

1.3 Fizika izvan standardnog modela 8

1.3.1 Dodatni skalari u Higgsovom sektoru 9

2 CMS detektor na LHC-u **12**

2.1 Veliki hadronski sudarivač 12

2.2 Geometrija detektora 13

2.3 Detektiranje čestica 16

2.4 Particle flow algoritam 17

2.5 Identificiranje hadronskih mlazova 18

2.6 Identifikacija b mlazova 21

3 Analiza **23**

3.1 Analiza pomoću uzoraka Monte Carlo simulacija 23

3.1.1 Selekcija događaja 24

3.1.2 Gornji limesi na udarni presjek novih procesa 29

3.2 Pregled metoda podatkovne procjene pozadine 31

3.2.1 ABCD metoda 32

3.2.2 Abecedna metoda 33

3.2.3 Primjena abecedne metode na HHH analizu 34

3.3 Rezultati podatkovne procjene pozadine 35

3.3.1 Usporedba oblika pozadine 36

3.3.2 Primjena na validacijsku regiju 38

3.3.3 F-test i GoF 44

3.3.4 Primjena na signalnu regiju 46

3.3.5 Gornji limesi na udarni presjek novih procesa 52

4 Zaključak **54**

1 Teorijski uvod i motivacija

Pitanje "Od čega se svijet sastoji?" staro je tisuće godina. Još od vremena starogrčkih filozofa poput Demokrita, preko novovjekovnih filozofa poput Ruđera Boškovića, pa sve do današnjeg vremena ono nije potpuno razriješeno. Današnje shvaćanje daje odgovor na to pitanje u obliku standardnog modela čestica koji se sastoji od 17 elementarnih čestica: 12 fermiona, čestica materije, 4 vektorska bozona, nositelja sile, i 1 skalarnog (Higgsovog) bozona, čije polje daje ostalim česticama masu kroz Higgsov mehanizam.

Standardni je model čestica među najtočnijim modelima današnjice te daje teorijska predviđanja koja se jako dobro slažu s brojnim eksperimentima, poput anomalnog magnetskog momenta miona. No, on ipak ima svoje nedorečenosti i ne objašnjava sve pojave u svemiru, poput gravitacije, tamne materije ili mase neutrina. Zbog toga postoji niz modela čiji je cilj nadopuniti ga postulirajući nove čestice, poput supersimetričnih modela, ili ga žele zamijeniti još elementarnijim česticama, poput teorije struna. Ovaj je rad motiviran takvim teorijama izvan standarnog modela, posebice gotovo minimalnim supersimetričnim modelom (engl. next-to-minimal supersymmetric standard model, NMSSM), koje postuliraju nove čestice.

U ovome ćemo radu predstaviti potragu za dvjema novim skalarnim česticama, X i Y, koje predviđa jedan od takvih modela te dati očekivane gornje granice na udarne presjeke njihove produkcije. U toj potrazi kao potpis produkcije čestica X i Y koristit ćemo proces $X \to HY \to HHH$, gdje je H Higgsov bozon. Pritom ćemo raditi u kinematičkom režimu u kojem su Higgsovi bozoni producirani s vrlo visokim impulsom tako da se produkti njihovog raspada, b kvark-antikvark par, nalaze u jednom mlazu.

1.1 Pregled standardnog modela čestica

Standardni model čestica opisuje sve poznate elementarne čestice te interakcije među njima. Time opisuje tri od četiri poznate sile - elektromagnetsku, jaku i slabu silu - dok gravitacija nije obuhvaćena standardnim modelom. Standardni je model baziran na kvantnoj teoriji polja, teoriji koja čestice opisuje kao pobuđena stanja kvantnih polja koja zadovoljavaju odgovarajuću jednadžbu gibanja. Dinamika kvantnih polja i interakcije među njima opisana je u obliku gustoće Lagranžijana.

U kvantnoj teoriji polja, interakcije između polja zamišljamo kao izmjenu virtualnih čestica, a to prikazujemo pomoću Feynmanovih dijagrama. Virtualne čestice su matematički alat koji nam omogućuje računanje amplituda različitih procesa, no njih nikada nećemo moći

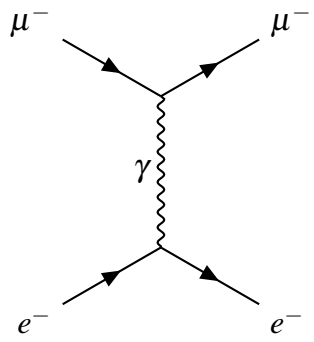

Slika 1.1: Feynmanov dijagram raspršenja miona na elektronu putem izmjene virtualnog fotona.

izravno detektirati. U vrhovima Feynmanovih dijagrama vrijede zakoni očuvanja impulsa i energije, dok virtualne čestice ne moraju zadovoljavati Einsteinovu relaciju mase i impulsa $E^2 = p^2 + m^2$. Drugim riječima, one ne moraju imati masu koja bi odgovarala realnoj čestici - ne moraju biti na ljusci mase. Na slici 1.1 prikazan je primjer jednog Feynmanovog dijagrama koji opisuje interakciju elektrona i miona putem izmjene virtualnog fotona.

Čestice u standarnom modelu (slika 1.2) podijeljene su u dvije skupine: bozone i fermione. Fermioni su čestice polucjelobrojnog spina i zadovoljavaju Fermi-Diracovu statistiku. Za njih vrijedi Paulijev princip isključenja koji govori da dva fermiona ne mogu biti u istome kvantnom stanju, te zbog toga predstavljaju čestice materije. Fermioni se dijele na kvarkove i leptone s obzirom na to interagiraju li jakom silom. Kvarkovi interagiraju jakom silom te posjeduju električni naboj koji iznosi ili $-\frac{1}{3}e$ (donji, strani i dubinski) ili $\frac{2}{3}e$ (gornji, šarmantni i vršni), gdje je e elementarni (električni) naboj. Leptoni, s druge strane, ne interagiraju jakom silom te posjeduju električni naboj koji iznosi ili $-1e$ (elektron, mion i tau) ili 0 (elektronski, mionski i tau netrino).

Fermioni se također mogu podijeliti na tri generacije od kojih se svaka generacija sastoji od po 2 kvarka i 2 leptona, te svaka sljedeća generacija sadrži čestice koje su teže od čestica iz prethodne generacije. Prva bi se generacija stoga sastojala od donjeg i gornje kvarka, elektrona i elektronskog neutrina, druga od stranog i šarmantnog kvarka, miona i mionskog neutrina, a treća od dubinskog i vršnog kvarka, tau leptona i tau neutrina. Svi fermioni (osim neutrina) posjeduju odgovarajuće antičestice koje su im jednake po svim svojstvima osim po aditivnim kvantnim brojevima poput naboja ili hipernaboja, koji su suprotni. Za neutrine još nije razjašnjeno imaju li svoje antičestice (Diracovi fermioni) ili su sami sebi antičestica (Majorana čestice).

Bozoni su čestice cjelobrojnog spina te zadovoljavaju Bose-Einsteinovu statistiku. U

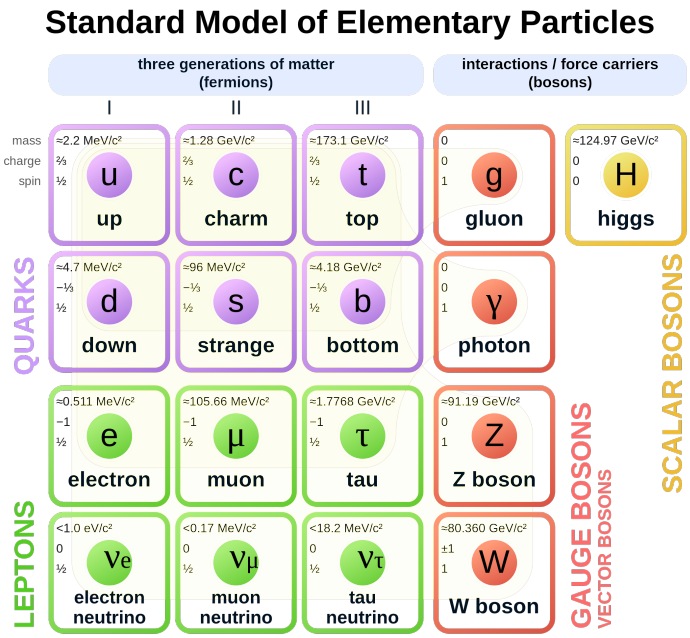

Slika 1.2: Prikaz čestica standardnog modela. Preuzeto iz [1].

standardnom modelu postoje 4 vektorska bozona - foton, gluon te W i Z bozoni - koji djeluju kao nosioci sile, te 1 skalarni bozon - Higgsov bozon - čije polje kroz Higgsov mehanizam daje masu ostalim česticama.

Foton je električni neutralan, bezmasen bozon koji služi kao nosioc elektromagnetske sile, a teorija koji opisuje elektromagnetske interakcije zove se kvantna elektrodinamika (engl. Quantum Electrodynamics, QED). Kvantna je elektrodinamika prva teorija koja je ujedinila specijalnu teoriju relativnosti i kvantnu mehaniku, te kao teorija električne interakcije opisuje kemiju, biologiju i većinu fizike. Zbog činjenice da je foton bezmasen, elektromagnetska interakcija nema ograničeni doseg.

Jaka sila nošena je pomoću gluona, koji su bezmaseni kao i fotoni. No, za razliku od fotona, gluoni posjeduju naboj sile koju nose te zbog toga mogu interagirati jedni s drugima. Naboj jake sile naziva se boja te ih ima tri koje su standardno označene crveno, plavo i zeleno. Teorija koja opisuje jaku sile se (prikladno) naziva kvantna kromodinamika (engl. Quantum Chromodynamics, QCD). Doseg jake sile je vrlo kratak ($R \approx 10^{-15}$m) zbog same prirode QCD-a [2, 3].[1]

Slaba interakcija posredovana je između čestica koje nose slabi izospinski naboj preko jednog električni neutralnog, Z, i dva električni nabijena, W^+ i W^-, bozona. Ti su bozoni

[1] QCD zadovoljava SU(3) lokalnu baždarnu simetriju čiji generatori čine oktet koji nije bojno neutralan. Kada bi QCD zadovoljavao U(3) simetriju, uz navedeni oktet, postojao bi još jedan gluon koji je bezbojni singlet. Tada bi jaka interakcija imala neograničeni doseg, a naš bi svijet izgledao potpuno drugačije [4].

relativno masivni ($\approx$ 80 GeV za W i $\approx$ 91 GeV za Z) i kratkoživući ($\approx 10^{-25}$ s) te stoga je i doseg slabe sile kratak (R $\approx 10^{-24}$m) [5–7].

Posljednja otkrivena elementarna čestica je Higgsov bozon. On je prvi puta opažen 2012. godine u eksperimentima CMS (Compact Muon Solenoid) i ATLAS (A Toroidal LHC Apparatus) na velikom hadronskom sudarivaču (engl. Large Hadron Collider, LHC) na CERN-u te se mjerenja njegovih svojstava nastavljaju do danas. Važnost njegovog otkrića je u tome što pripadni Higgsov mehanizam daje način na koji čestice u standardnom modelu dobivaju masu (posebice bozoni) te tako zaokružuje standardni model čestica kao teoriju čije su sve postulirane čestice i pronađene.

1.2 Higgsov mehanizam

U standardnom modelu, čestice dobivaju masu u interakciji s Higgsovim poljem kroz Higgsov mehanizam. Higgsov mehanizam počiva na spontanom lomu simetrije - konkretno lomu lokalne baždarne simetrije u elektroslabom sektoru standardnog modela [8, 9]. Standardni je model baždarna teorija i zahtjeva da Lagranžijan, matematički objekt kojim opisujemo čestice i njihove interakcije, bude invarijantan na lokalne transformacije:

$$\psi(x) \rightarrow \psi^{'}(x) = e^{i\alpha(x)}\psi(x) \tag{1.1}$$

gdje je $\psi(x)$ polje koje razmatramo [4].

Taj zahtjev na invarijantnost ima vrlo važne implikacije na masu baždarnih bozona. Primjerice, ako bi foton imao masu, njegov doprinos u Lagranžijanu bi imao oblik $\frac{1}{2}m_\gamma^2 A_\mu A^\mu$. Poznavajući činjenicu da se fotonsko polje transformira pod U(1) lokalnom transformacijom, koja ima oblik $A_\mu \rightarrow A_\mu^{'} = A_\mu + \partial_\mu \xi$, možemo lako doći do zaključka da taj doprinos nije baždarno invarijantan:

$$\frac{1}{2}m_\gamma^2 A_\mu A^\mu \rightarrow \frac{1}{2}m_\gamma^2 (A_\mu + \partial_\mu \xi)(A^\mu + \partial^\mu \xi) \neq \frac{1}{2}m_\gamma^2 A_\mu A^\mu, \tag{1.2}$$

te doći do zaključka da foton mora biti bezmasen. Iako je ovaj primjer za U(1), ista činjenica slijedi i za SU(2)$_L$ simetriju slabe interakcije te SU(3) simetriju jake interakcije [4]. Naravno, to je problem jer iz mjerenja znamo da W i Z bozoni imaju masu, i to relativno veliku u odnosu na ostale elementarne čestice. Ti bozoni su masivniji od svih ostalih elementarnih čestica, osim top kvarka i Higgsova bozona, barem za 1 red veličine.

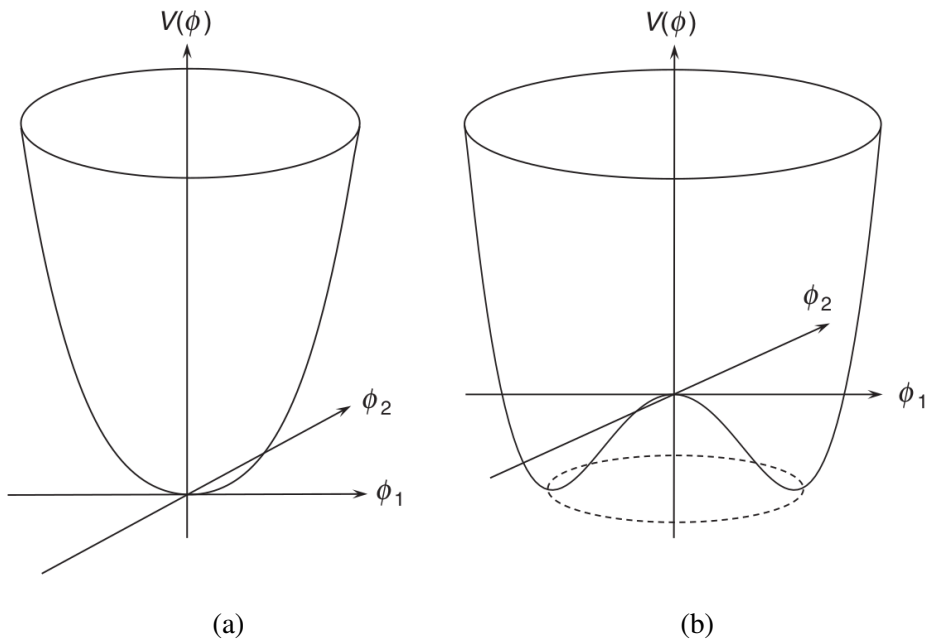

Slika 1.3: Izgled potencijala $V(\phi) = \mu^2(\phi^\dagger\phi) + \lambda(\phi^*\phi)^2$ za (a) $\mu^2 > 0$ i (b) $\mu^2 < 0$. Preuzeto iz [4].

Kako bismo riješili taj problem, promotrimo slučaj kompleksnog skalarnog polja $\phi = \frac{1}{\sqrt{2}}(\phi_1 + i\phi_2)$. Lagranžijan koji opisuje evoluciju tog polja je:

$$\mathscr{L} = \frac{1}{2}(\partial_\nu\phi)^\dagger(\partial^\nu\phi) - V(\phi) = \frac{1}{2}(\partial_\nu\phi)^\dagger(\partial^\nu\phi) - \mu^2(\phi^\dagger\phi) - \lambda(\phi^\dagger\phi)^2. \tag{1.3}$$

Ovaj izraz posjeduje globalnu U(1) simetriju zbog činjenice da je invarijantan na transformaciju $\phi \to \phi' = e^{i\alpha}\phi$ koja ne mijenja njegov oblik (jer je $\phi'^\dagger\phi' = \phi^\dagger\phi$). U ovome Lagranžijanu, član s $(\partial_\nu\phi)^*(\partial^\nu\phi)$ možemo interpretirati kao kinetički dio, član s $\mu^2(\phi^\dagger\phi)$ može predstavljati maseni dio, dok član s $(\phi^\dagger\phi)^2$ predstavlja interakciju polja sa samim sobom. Potencijal u ovom Lagranžijanu, $V(\phi) = \mu^2(\phi^\dagger\phi) + \lambda(\phi^\dagger\phi)^2$, ima minimum u ishodištu ukoliko je $\mu^2 > 0$ (slika 1.3a). No ako je $\mu^2 < 0$ (slika 1.3b), član s $\mu^2(\phi^\dagger\phi)$ se više ne može interpretirati kao masa, a potencijal ima minimum na kružnici u kompleksnoj ravnini definiranoj izrazom:

$$\phi_1^2 + \phi_2^2 = \frac{-\mu^2}{\lambda} = v^2, \tag{1.4}$$

gdje se v zove očekivana vrijednost vakuuma (engl. vacuum expectation value, vev)[2].

Fizičko stanje vakuuma može biti na bilo kojoj točki na danoj kružnici, no njegovim izborom spontano narušavamo simetriju. Najjednostavniji izbor stanja vakuuma je točka $(\phi_1, \phi_2) = (v, 0)$ koje nam omogućava da kompleksno skalarno polje ϕ zapišemo preko

[2]Ovaj potencijal se popularno naziva potencijalom meksičkog šešira jer oblikom podsjeća na sombrero.

$\phi_1(x) = v + \eta(x)$ i $\phi_2(x) = \xi(x)$ kao:

$$\phi(x) = \frac{1}{\sqrt{2}}(v + \eta(x) + i\xi(x)). \tag{1.5}$$

Uvrstimo li polje ϕ u ovom obliku u Lagranžijan (1.3), nakon sređivanja dobit ćemo sljedeći izraz:

$$\mathscr{L} = \frac{1}{2}(\partial_\nu \eta)^\dagger(\partial^\nu \eta) - \frac{1}{2}m_\eta^2 \eta^2 + \frac{1}{2}(\partial_\nu \xi)^\dagger(\partial^\nu \xi) - V_{int}(\eta, \xi), \tag{1.6}$$

gdje je $m_\eta = \sqrt{2\lambda v}$ masa polja η, a $V_{int}(\eta, \xi)$ dio koji sadrži interakcijske članove. Iz tog se izraza može vidjeti da se pri narušenju simetrije javilo jedno masivno skalarno polje η te jedno bezmaseno polje ξ, što stoji u osnovi Higgsovom mehanizma.

U Higgsovom mehanizmu, spontani se lom simetrije događa pri lokalnoj (a ne globalnoj) baždarnoj simetriji. Zbog činjenice da Lagranžijan (1.3) nije invarijantan na transformaciju $\phi \to \phi' = e^{i\alpha(x)}\phi$, moramo mu uvesti dodatno baždarno polje B_μ koje se transformira kao $B_\mu(x) \to B'_\mu(x) = B_\mu(x) - \frac{1}{g}\partial_\mu \alpha(x)$, te zamijeniti derivacije s kovarijantnim derivacijama $\partial_\mu \to D_\mu = \partial_\mu + igB_\mu$. Nakon tih promjena, Lagranžijan poprima sljedeći oblik:

$$\mathscr{L} = -\frac{1}{4}F^{\mu\nu}F_{\mu\nu} + (D_\mu \phi)^\dagger(D^\mu \phi) - \mu^2(\phi^\dagger \phi) + \lambda(\phi^\dagger \phi)^2, \tag{1.7}$$

gdje je $F^{\mu\nu}F_{\mu\nu}$ kinetički dio baždarnog polja B_μ, a za $F^{\mu\nu}$ vrijedi $F^{\mu\nu} = \partial^\mu B^\nu - \partial^\nu B^\mu$.

Ako raspišemo Lagranžijan preko $\phi(x) = \frac{1}{\sqrt{2}}(v + \eta(x) + i\xi(x))$ dobivamo izraz:

$$\begin{aligned}\mathscr{L} = &\underbrace{\frac{1}{2}(\partial_\mu \xi)^\dagger(\partial^\mu \xi)}_{\text{bezmaseni } \xi} + \underbrace{\frac{1}{2}(\partial_\mu \eta)^\dagger(\partial^\mu \eta) - \lambda v^2 \eta^2}_{\text{masivni } \eta} - \underbrace{\frac{1}{4}F^{\mu\nu}F_{\mu\nu} + \frac{1}{2}g^2 v^2 B_\mu B^\mu}_{\text{masivno baždrano polje}} + \\ &+ gvB_\mu(\partial^\mu \xi) + V_{int}(\eta, \xi, B),\end{aligned} \tag{1.8}$$

gdje je V_{int} član koji predstavlja interakcije tri ili četiri čestice između polja η, ξ i B. Iako vidimo da smo dobili masene članove u Lagranžijanu, što smo i tražili, imamo i nekoliko problema u njemu:

- Pojavio se dodatni stupanj slobode - bezmaseni B_μ s 2 transverzalna stupnja polarizacije postao je masivan i dobio dodatni longitudinalni stupanj polarizacije,
- Pojavljuje se miješani član $gvB_\mu(\partial^\mu \xi)$ koji sugerira da se baždarno polje spina 1 može transformirati u skalarno polje (spina 0).

No, tim problemima možemo doskočiti ako tražimo da je zadovoljena tzv. unitarna baždarna

transformacija:

$$B_\mu(x) \to B'_\mu(x) = B_\mu(x) + \frac{1}{gv}\partial_\mu \xi(x). \tag{1.9}$$

Naime, za kompleksno skalarno polje $\phi(x) = \frac{1}{\sqrt{2}}(v + \eta(x) + i\xi(x)) \simeq \frac{1}{\sqrt{2}}[v + h(x)]e^{i\xi(x)/v}$ pripadna baždarna transformacija tada ima oblik $\phi(x) \to \phi'(x) = e^{-i\xi(x)/v}\phi(x)$. Primjenom unitarnog baždarenja, na kraju imamo samo jedno realno polje h - Higgsovo polje, a bezmaseni skalar ξ nestaje iz Lagranžijana ("biva pojeden od strane baždarnog polja"):

$$\mathscr{L} = \underbrace{\frac{1}{2}(\partial_\mu h)^\dagger(\partial^\mu h) - \lambda v^2 h^2}_{\text{masivni skalar}} - \underbrace{\frac{1}{4}F^{\mu\nu}F_{\mu\nu} + \frac{1}{2}g^2 v^2 B_\mu B^\mu}_{\text{masivno baždrano polje}} + V_{int}. \tag{1.10}$$

U standardnom modelu, Higgsov mehanizam koristimo kako bismo dali masu baždarnim bozonima u elektroslabom sektoru, konkretno W i Z bozonima [4]. Kako polja tih bozona zadovoljovaju $SU(2)_L$ lokalnu baždarnu simetriju, naš minimalni model treba se sastojati od dva kompleksna skalarna polja smještena u dublet:

$$\Phi = \begin{pmatrix} \phi^+ \\ \phi^0 \end{pmatrix} = \begin{pmatrix} \phi_1 + i\phi_2 \\ \phi_3 + i\phi_4 \end{pmatrix}. \tag{1.11}$$

Lagranžijan za taj dublet dan je izrazom:

$$\mathscr{L} = (D_\mu \Phi)^\dagger (D^\mu \Phi) - \mu^2(\Phi^\dagger\Phi) - \lambda(\Phi^\dagger\Phi)^2, \tag{1.12}$$

gdje je D_μ kovarijantna derivacija za elekroslabu teoriju. Ona je pak dana izrazom $D_\mu = \partial_\mu + ig\tau^i W^i_\mu + ig'\frac{Y}{2}B_\mu$, gdje su g i g' konstante vezanja za polja W i B, a Y slabi hipernaboj. Zahtjevajući unitarno baždarenje, dublet će nam na kraju poprimiti oblik:

$$\Phi = \frac{1}{\sqrt{2}}\begin{pmatrix} 0 \\ v + h \end{pmatrix}. \tag{1.13}$$

Primjenjujući taj oblik dubleta na kinematički dio Lagranžijan (1.12), možemo pronaći mase

baždarnih bozona:

$$
\begin{aligned}
m_W^2 &= \frac{1}{4} g^2 v^2, \\
m_Z^2 &= \frac{1}{4} (g^2 + g'^2) v^2, \\
m_\gamma^2 &= 0.
\end{aligned}
$$

Dakle, uključivanjem Higgsovog dubleta i zahtjevajući da očekivana vrijednost vakuuma nije nula, u Lagranžijanu su se pojavili maseni članovi za W i Z bozone, dok je foton ostao bezmasen. Razlika u ovome primjeru i u primjeru opisanom jednadžbom (1.3) je da maseni članovi u ovome primjeru dolaze primjenom kovarijantne derivacije na novo polje, dok u prethodnom primjeru oni dolaze iz potencijala [4, 9, 10].

1.3 Fizika izvan standardnog modela

Standardni je model jedna od najuspješnijih teorija današnjice koja posjeduje vrlo visoko slaganje s različitim eksperimentima. No, iako je kao model vrlo precizan, već danas znamo da nam ne može objasniti neka opažanja te zbog toga postoji cijeli niz proširenja koji pokušavaju to učiniti.

Prvi, i možda najvažniji, dio koji nedostaje standardnom modelu je gravitacija. Naime, standardni model ne uključuje gravitaciju kao jednu od fundamentalnih sila. Razlog zašto nije moguće uključiti gravitaciju kao dio standardnog modela je u tome da opća teorija relativnosti, koja opisuje gravitaciju, nije kompatibilna s kvantnom teorijom polja na kojoj se bazira standardni model. Iako postoje neki modeli koji postuliraju postojanje gravitona, dodatnog bozona spina 2 i nositelja gravitacijske sile, ti modeli nisu uključeni u standardni model niti postoje eksperimentalni rezultati koji izravno ukazuju na postojanje gravitona.

Drugi veliki problem standardnog modela je postojanje tamne tvari i tamne energije. Kozmološka su istraživanja otkrila da samo 5% energije u svemiru dolazi iz čestica opisanih standardnim modelom. Oko 26% energije u svemiru dolazi od tamne tvari koja interagira samo gravitacijski, te možda putem još jedne sile koja treba biti relativno slaba (slaba nuklearna ili neka još neotkrivena sila). Ekstenzije standardnog modela prirodno u sebi sadrže čestice koji su kandidati za tamnu tvar. Preostalih 69% energije dolazi od tamne energije, za koju nismo ni sigurni što je točno, no vjeruje se da bi trebala doći od energetske gustoće vakuuma, čija izmjerena vrijednost odstupa od teorijskih predviđanja za stotinjak redova

veličine.

Još jedan od problema standardnog modela je postojanje asimetrije tvari i antitvari. Standardni model predviđa da su tvar i antitvar trebale nastati otprilike u istim količinama pri velikom prasku, no danas je potpuno jasno da je svemir gotovo u cijelosti izgrađen od tvari. Iako u standardnom modelu postoji mehanizam koji bi narušio simetriju tvari i antitvari - CP-narušenje - taj mehanizam ne može objasniti toliku asimetriju [11]. Dakle, postoje drugi mehanizmi koji narušavaju simetriju tvari i antitvari ili su postojeći mehanizmi bili znatno naglašeniji na višim energijama nego što bismo to mogli očekivati.

1.3.1 Dodatni skalari u Higgsovom sektoru

U poglavlju 1.2 uveli smo Higgsov mehanizam u standardni model kao dubletno skalarno polje, no to je najjednostavnije moguće rješenje za realizaciju mehanizma. Ne postoji razlog zašto ne bi postojalo i kompleksnije rješenje te postoje modeli, odnosno ekstenzije, koji predviđaju bogatiju fenomenologiju u skalarnom sektoru. Jedno od najjednostavnijih proširenja je proširenje s dodatnim singletnim skalarnim poljima koji potencijal skalara u standardnom modelu proširuje kao:

$$V(\Phi,\phi_i) = V_{singleti}(\Phi,\phi_i) + V_{SM}(\Phi), \tag{1.14}$$

gdje je $V_{singlet}(\Phi,\phi_i)$ najopćenitiji mogući potencijal singletnih skalara dan izrazom

$$\begin{aligned} V_{singlet}(\Phi,\phi_i) =& a_i\phi_i + m_{ij}\phi_i\phi_j + T_{ijk}\phi_i\phi_j\phi_k + \lambda_{ijkl}\phi_i\phi_j\phi_k\phi_l + \\ &+ T_{iHH}\phi_i(\Phi^\dagger\Phi) + \lambda_{ijHH}\phi_i\phi_j(\Phi^\dagger\Phi), \end{aligned} \tag{1.15}$$

gdje su m, T i λ pripadne konstante vezanja između singletnih polja te singletnih polja i Higgsovog dubleta [12].

U ovome ćemo radu obratiti posebnu pažnju na jedno od takvih proširenja koje daje dodatna dva skalara S i P u Higgsovom sektoru, model dva realna singleta (engl. "Two Real Singlet Model", TRSM) [13]. U tom se modelu zahtjeva da vrijede dvije diskretne simetrije - Z_2^S i Z_2^P - koje ograničavaju broj slobodnih parametara u modelu. Čestice standardnog modela su invarijantne na te transformacije dok za čestice S i P vrijedi:

$$\begin{aligned} Z_2^S &: S \to -S,\ P \to P, \\ Z_2^P &: P \to -P,\ S \to S. \end{aligned} \tag{1.16}$$

Primjene tih simetrija ograničavaju potencijal skalara na sljedeći izraz:

$$\begin{aligned} V(\Phi,S,P) =& \mu_\Phi^2 \Phi^\dagger \Phi + \lambda_\Phi (\Phi^\dagger \Phi)^2 + \mu_S^2 S^2 + \lambda_S S^4 + \mu_P^2 P^2 + \lambda_P P^4 + \\ &+ \lambda_{PH} (\Phi^\dagger \Phi) S^2 + \lambda_{PH} (\Phi^\dagger \Phi) P^2 + \lambda_{SP} S^2 P^2, \end{aligned} \tag{1.17}$$

u kojem se nalazi 9 konstantni vezanja. Možemo vidjeti da taj izraz, uz masene članove, sadrži i interakcijske članove za skalarna polja u parovima. Fizička svojstvena stanja tih polja možemo razviti oko pripadnih očekivanih vrijednosti vakuuma v, v_S i v_P:

$$\Phi = \frac{1}{\sqrt{2}} \begin{pmatrix} 0 \\ v + \phi_h \end{pmatrix}, \; S = \frac{1}{\sqrt{2}} (\phi_S + v_S), \; P = \frac{1}{\sqrt{2}} (\phi_S + v_P). \tag{1.18}$$

Ako su sve od navedenih očekivanih vrijednosti vakuuma različite od nule, dolazi do spontanog loma diskretnih simetrija Z_2^S i Z_2^P te se stanja ϕ_h, ϕ_S i ϕ_P miješaju u stanja H, X i Y:

$$\begin{pmatrix} H \\ X \\ Y \end{pmatrix} = R \begin{pmatrix} \phi_h \\ \phi_S \\ \phi_P \end{pmatrix}, \tag{1.19}$$

gdje je R matrica rotacije.

Miješanjem u stanja H, X i Y u Lagranžijanu javljaju se interakcije između tri polja. Promatramo li slučaj gdje vrijedi hijerarhija masa $M_X > M_Y + M_H$ i $M_Y > 2M_H$, to nam

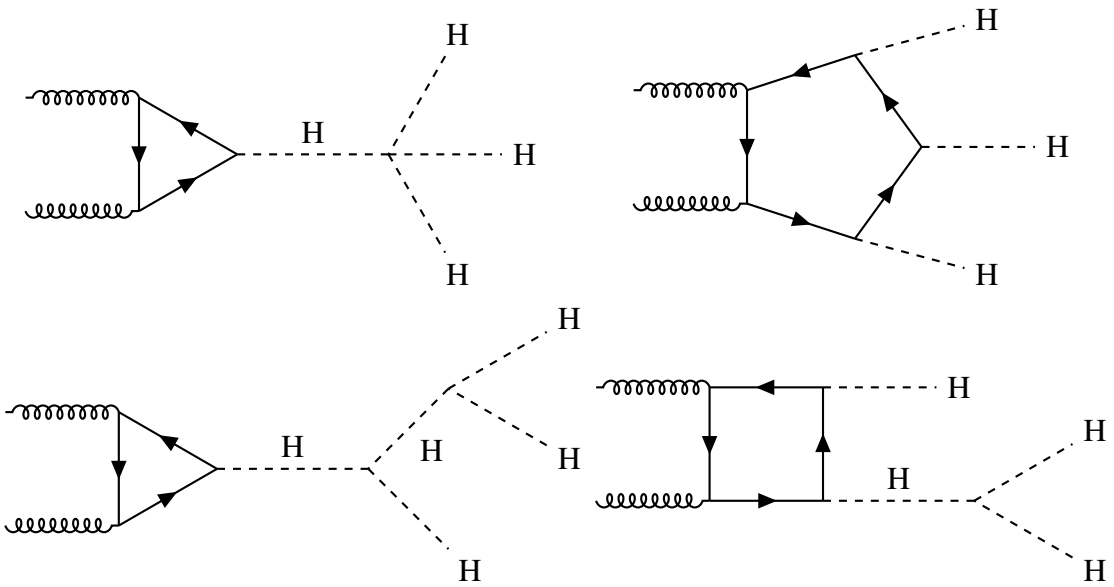

Slika 1.4: Neki od Feynmanovih dijagrama gluon-gluon interakcije koji rezultiraju konačnim stanjem 3 Higgsova bozona u standardnom modelu.

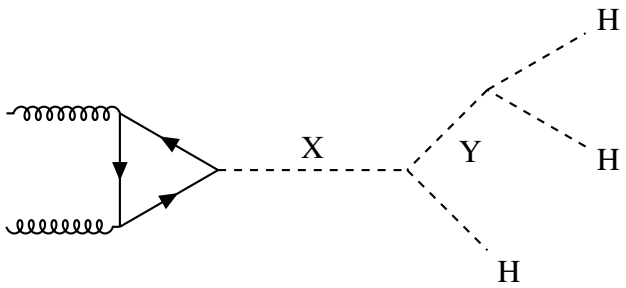

Slika 1.5: Feynmanov dijagram procesa produkcije tri Higgsova bozona u kojem sudjeluju dva dodatna skalara.

daje mogućnost produkcije 3 Higgsova bozona u sudaru, gdje bi se čestica X raspadala u česticu Y i Higgsov bozon, a čestica Y raspadala u dodatni par Higgsovih bozona (slika 1.5). Ovaj je kanal pogodan za testiranje ovog modela jer standardni model, iako dozvoljava produkciju 3 Higgsovih bozona u sudaru (slika 1.4), predviđa da će udarni presjek te reakcije biti svega oko 0.1 fb za energiju centra mase proton-proton sudara $\sqrt{s} = 14$ TeV [14, 15]. S tim udarnim presjekom vidjet ćemo svega nekolicinu takvih događaja i upitno je možemo li uopće primijetiti takav kanal sa dovoljnom statističkom signifikantnošću, čak i s ukupnim integriranim luminozitetom koji se očekuje do kraja rada velikog hadronskog sudarivača (engl. Large Hadron Collider, LHC). Postojanje dodatnih skalara X i Y povećalo bi udarni presjek za produkciju 3 Higgsova bozona za nekoliko redova veličine, dovoljno da taj kanal možemo jasno vidjeti. U ovome radu predstavljamo rezonantnu potragu za tim procesom, gdje invarijantna masa para Higgsovih bozona iz raspada $Y \to HH$ daje M_Y, a invarijantna masa triju Higgsovih bozona daje M_X. Konačni nam je cilj procijeniti očekivane gornje limese za rezonantnu produkciju 3 Higgsova bozona koji se mogu dobiti s luminozitetom od 138 fb^{-1}.

2 CMS detektor na LHC-u

U sklopu ovog rada, radit ćemo s podacima koje je prikupio CMS detektor na LHC-u tijekom perioda između 2016. i 2018. godine (razdoblje poznatije pod imenom Run 2). CMS je detektor čestica opće namjene čiji je jedan od prvotnih zadataka bio potraga za Higgsovim bozonom. U ovome ćemo poglavlju predstaviti veliki hadronski sudarivač (LHC) i kako on radi, te ćemo opisati geometriju CMS detektora i objasniti kako on detektira čestice, s time da ćemo posebnu pažnju obratiti na detekciju i rekonstrukciju hadronskih mlazova.

2.1 Veliki hadronski sudarivač

Veliki hadronski sudarivač (engl. Large Hadron Collider, LHC) je najveći i najsnažniji ubrzivač čestica na svijetu te je zadnja nadogradnja akceleratoskog kompleksa na CERN-u (slika 2.1) [16]. LHC ubrzava protone u kružnom akceleratoru dugom 27 km u opsegu i sudara ih na 4 točke, gdje se nalaze eksperimenti CMS, ATLAS, LHCb i ALICE, s energijom centra mase koja je iznosila $\sqrt{s} = 13$ TeV tijekom Run 2 [17].

No prije nego li se protoni uopće injektiraju u LHC, oni se prvo ubrzavaju u linearnom akceleratoru LINAC 2[3], te zatim u sinkotronima Proton Synchotron Boosteru (PSB), Proton Synchotronu (PS) te napokon u Super Proton Synchotronu (SPS) odakle dolaze u LHC. U svakom od navedenih akceleratora, protonima se postepeno diže energija prije negoli prijeđu u sljedeći akcelerator. Ciklus započinje skidanjem elektrona s atoma vodika pomoću električnog polja iz boce vodika koja se nalazi na jednom kraju LINAC 2. U LINAC-u 2, protoni se ubrzavaju do 50 MeV, te zatim odlaze u PSB gdje im se energija diže na 1.4 GeV nakon čega se injektiraju u PS. U PS-u protoni dosežu energiju od 26 GeV te potom idu na zadnji stupanj ubrzanja prije LHC-a, SPS, gdje postižu energiju od 450 GeV [18].

Snopovi protona u LHC-u ne kruže kontinuirano, nego u "paketima", kojih je obično 2808 u snopu, a u svakom od tih "paketa" nalazi se $\approx 10^{11}$ protona. Snopovi putuju u dvjema cijevima visokog vakuuma u akceleratoru, pri čemu je smjer putanje snopa u jednoj cijevi suprotan od smjera u drugoj cijevi. Putanje snopova presjecaju se na 4 lokacije koje odgovoraju mjestima 4 eksperimenta na LHC-u te se tamo događaju sudari svakih 25 ns [16].

Protoni se ubrzavaju u LHC-u radiofrekventim šupljinama (engl. radiofrequency (RF) cavities) električnim poljem koje oscilira u vremenu pri frekvenciji od 400 MHz. Radiofrekventne šupljine su metalne komore posebno oblikovane kako bi rezonirale na potrebnoj

[3] Tijekom Run 2. Nakon 2018. godine zamjenjen je novim linearnim akceleratorom, LINAC 4.

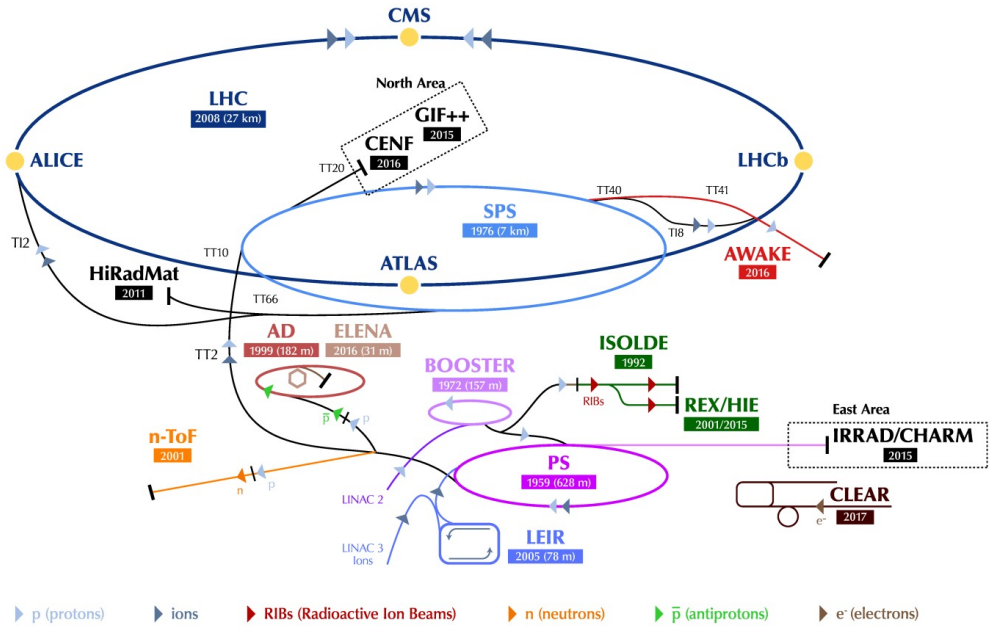

Slika 2.1: Akceleratorski kompleks na CERN-u tijekom 2018. godine. Preuzeto s [20].

frekvenciji i time omogućile najbolji mogući transfer energije na protone. Svaka od šupljina pogonjena klistronom, cijevi s elektronskim zrakama, a energija se u šupljinu transportira valovodom, što rezultira time da svaka od šupljina može postići maksimalni napon od 2 MV. Na LHC-u radi 16 RF šupljina smještenih u 4 kriomodula, koji ih hlade i omogućuju da rade u supravodljivom stanju, a to omogućava da se postigne maksimalni napon od 16 MV po snopu protona [19].

Kako bi čestice pratile kružnu putanju u LHC-u, koriste se supravodljivi dipolni magneti napravljeni od niti niobij-titanija, njih 1292. Ti magneti postižu magnetsko polje 8.3 T unutar vakuumske cijevi za što je potrebna struja od 11080 A. Kako bi to postigli, potrebno ih je hladiti helijem na temperaturu od 1.9 K. Osim zakretanja, potrebno je snopove i fokusirati kako bi sudari bili što učestaliji, a za to se koriste kvadrupolni magneti. Osim dipolni i kvadrupolnih magneta, koriste se i sekstapoli, oktapoli te dekapoli za ispravljanje nesavršenosti magnetskog polja na rubovima dipola.

2.2 Geometrija detektora

CMS (Compact Muon Solenoid) eksperiment, kao i pripadni detektor, osmišljen je kao eksperiment opće namjene, a program istraživanja koje se tamo izvode je jako širok te seže od mjerenja svojstava Higgsova bozona preko proučavanja fizike top kvarka do potrage fizike izvan standardnog modela [21]. Detektor je cilindričnog oblika s ciljem da pokrije gotovo ci-

jeli prostorni kut (skoro 4π). Iako mu u imenu stoji kompaktan, detektor nipošto nije malen: dug je 21 m, promjera 15 m, te težak oko 14000 tona. Poprečni presjek detektora prikazan je na slici 2.2. Na njemu je prikazan poprečni presjek dijela detektora koji se naziva bačva (engl. barrel), i on čini većinu detektora. Taj dio se naziva bačva jer je izgrađen u obliku koncentričnih cilindara oko mjesta sudara. Osim bačve, detektor da svakom od krajeva ima dijelove koji se nazivaju čepovi (engl. endcaps), a detektorski podsustavi u njima slijede istu hijerarhiju kao i u bačvi, s iznimkom da nema solenoida.

U središtu detektora nalazi se mjesto na kojem se sudaraju protoni te je detektor građen u slojevima oko mjesta sudara. U prvom sloju, najbližem centru sudara, nalazi se Pixel detektor kojemu je cilj precizno pratiti tragove koje nabijene čestice ostavljaju. Taj detektor se Pixel detektorom jer je napravljen od mnoštva silicijskih pločica segmentiranih u piksele, dimenzija $100 \times 150\ \mu\text{m}^2$ [22]. Tijekom 2016 i prve polovice 2017. godine, te pločice su bile smještene u tri koncentrična plašta cilindra polumjera 44, 73 i 102 mm u bačvi i dva diska u čepovima udaljenim 345 i 465 mm od točke interakcije. Tijekom 2017. godine, Pixel detektor je nadograđen te njegovu novu konfiguraciju čine 4 koncentrična plašta cilindra polumjera 29, 68, 109 i 160 mm te 3 diska u čepovima udaljenim 291, 396 i 516 mm od točke interakcije. Prolaskom nabijene čestice kroz silicij, kao poluvodički materijal, nastaju parovi elektron-šupljina te se pomoću narinutog napona može dobiti električni puls koji se pojačava i registrira [23]. Zbog visoke gustoće piksela, s Pixel detektorom dobivamo jako dobru prostornu osjetljivost koja nam omogućuje određivanje položaja iz kojeg su čestice došle.

Nakon Pixel detektora, slijedi sloj u kojem se nalazi detektor sastavljen od silicijskih traka [25]. Sastoji se od deset slojeva silicijskih traka u bačvi te četiri sloja u čepovima. Taj detektor nema toliku prostornu osjetljivost kao Pixel detektor, no ona nije ni potrebna jer je tok čestica znatno manji. Primarni zadatak ovog detektora je registriranje putanja nabijenih čestica iz čega možemo doći do impulsa čestice pomoću zakrivljenosti putanje te određivanje verteksa iz kojeg dolaze čestice, a oba ta zadatka odrađuje u tandemu s Pixel detektorom.

Nakon silicijskih detektora, slijedi sloj u kojem se nalaze kalorimetri - elektromagnetski i hadronski. Elektromagnetski kalorimetar (ECAL) nalazi se bliže mjestu sudara i napravljen je od prozirnih kristala olovnog volframata ($PbWO_4$), a njegov je cilj detekcija energije elektrona i fotona. Hadronski kalorimetar (HCAL) nalazi se iza ECAL-a, a njegov je zadatak mjerenje energije hadrona. Za potpuno zaustavljanje hadrona potrebna je velika količina materijala, pa se HCAL sastoji od velikog broja naizmjeničnih slojeva apsorbera i scintilatora.

Prolaskom hadrona kroz apsorber nastaje hadronski pljusak u kojem nastaje velika količina čestica, a energija nastalih čestica se potom mjeri u scintilatorskom sloju kalorimetra.

U sljedećem sloju nalazi se supravodljiva zavojnica (solenoid) promjera 6 m, koja generira magnetsko polje od 3.8 T u središtu [21]. Cilj zavojnice je zakretanje putanja nabijenih čestica, čime omogućujemo mjerenje njihovih impulsa. Za postizanje navedenog magnetskog polja, zavojnica se hladi na temperaturu od 4.9 K, te njome teče struja jakosti 18164 A.

U zadnjem sloju detektora nalazi se sustav za detekciju miona. U CMS stavljen je naglasak na preciznu detekciju miona jer potencijalne produkcije novih čestica mogu sadržavati mione (posebice visokoenergetske) u konačnom stanju, npr. za Higgsov bozon postoji kanal raspada koji ima konačno stanje 4 miona. Mioni su gotovo isključivo jedine čestice[4] koje mogu proći kroz cijeli detektor (a da ih možemo detektirati), pa se njihova energija ne može mjeriti u kalorimetru. Sama spoznaja da je neka čestica prošla kroz dosad navedene dijelove detektora, snažno ukazuje da je ta čestica mion te nas zanima kako mu što preciznije izmjeriti impuls. Iako se impuls dijelom mjeri i u Pixel detektoru i detektoru traka, kod visokoenergetskih miona, preciznost je ograničena zbog relativno malene veličine tih detektora. Stoga, postoji sustav za detekciju miona koji je puno veći kako bi upravo to omogućio. Sustav za detekciju mioni bilježi tragove koje ostavljaju miona prolaskom kroz njega. Sastoji

[4]Postoji vrlo malena šansa da hadron prođe kroz HCAL bez da bude zaustavljen.

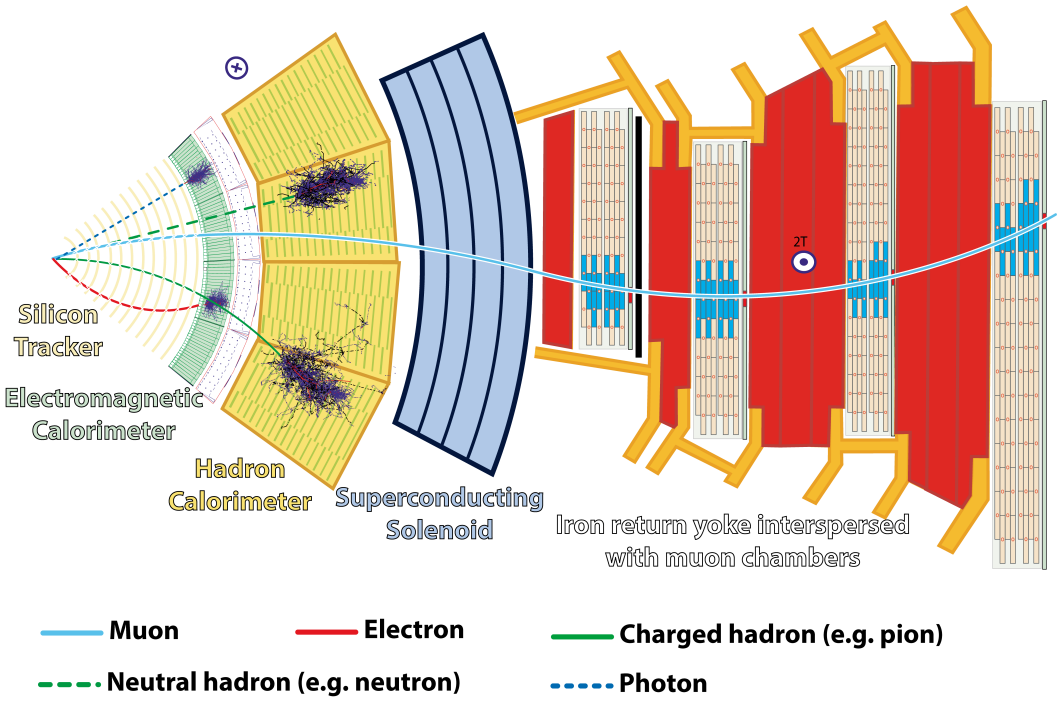

Slika 2.2: Transverzalni presjek CMS detektora. Preuzeto iz [24].

se od četiri mionske postaje koje u sebi sadrže driftne cijevi i komore s katodnim trakama u bačvi, dok u čepovima postaje sadrže u sebi komore s katodnim trakama i komore s pločastim otpornicima. Sve komore funkcioniraju na sličan način, a to je da prolaskom nabijene čestice kroz komoru, plin u komori se ionizira te se to može detektirati kao električni puls. Driftne cijevi su cijevi ispunjene plinom u kojima se nalazi žica, komore s katodnim trakama se sastoje od niza žica na pozitivnom naponu koje se križaju s negativno nabijenim bakrenim trakama, a komore s pločastim otpornicima sastoje se od dvije paralelne ploče visoke otpornosti [26].

2.3 Detektiranje čestica

Čestice, koje nastaju u sudaru ili raspadom iz drugih čestica, pri prolasku kroz detektor ostavljaju različite tragove u podsustavima detektora - svoj potpis - prema kojem možemo odrediti o kojem je tipu čestice riječ. Uz stabilne čestice - elektrone, fotone i protone - možemo izravno detektirati i neke nestabilne čestice s dovoljno dugim vremenom poluživota, a to su neutroni, mioni, pioni te kaoni. Od stabilnih čestica, ne možemo detektirati jedino neutrine (bar ne izravno). Sve ostale čestice koje nisu navedene, ne možemo detektirati izravno jer im je vrijeme života prekratko da bi uopće stigle do prvog detektora. Stoga, kod tih čestica možemo zaključiti o kojoj čestici se radi mjereći produkte njihovih raspada. Primjerice, možemo zaključiti da je pri sudaru vjerojatno nastao Z bozon ako u događaju detektiramo dva miona ili elektrona čija invarijantna masa iznosi oko 90 GeV. Da bismo točno znali o kojoj je čestici riječ, moramo joj poznavati masu i naboj. Naboj znamo iz smjera zakrivljenost putanje, dok informaciju o masi dobivamo mjereći energiju i impuls čestice. No, za fiziku koju proučava CMS, energija je vrlo bliska količini impulsa te, zbog raznih nesigurnosti kod mjerenja, mjerenje mase je gotovo nemoguće. Stoga, čestice prepoznajemo prema mjestu detekcije i tragu koji ostavljaju u detektoru i svrstavamo ih u 5 klasa: elektrone, fotone, mione, te nabijene i neutralne hadrone.

Elektrone (i pozitrone) u CMS detektoru prepoznajemo po tome da ostavljaju trag samo u silicijskim detektorima te ECAL-u, gdje ostavlja karakteristični oblik signala - relativno uski pljusak čestica. Njihovu energiju izravno mjerimo pomoću ECAL-a, dok informaciju o impulsu dobivamo iz zakrivljenosti njihove putanje. Fotone prepoznajemo jer ostavljaju trag samo u ECAL-u, gdje im mjerimo energije te time i impuls [27].

Hadroni ostavljaju tragove primarno u HCAL-u, ali i također i u ECAL-u, a nabijeni hadroni ostavljaju i tragove u silicijskim detektorima. Energija im se izravno mjeri u HCAL-

u, ali relativno neprecizno s nesigurnošću oko 10%. Kombinirajući sve informacije iz svih navedenih detektora, dolazi se o informaciji o njihovom impulsu [28].

Mioni su jedine čestice koje mogu proći kroz kalorimetre, pa njima ne možemo izravno odrediti energiju. Zbog toga im pokušavamo precizno izmjeriti impuls mjereći im zakrivljenost putanje i u silicijskim detektorima i u sustavu za detekciju miona. Time posredno dobivamo informaciju o energiji jer znamo njihov impuls i masu zbog činjenicu da znamo da su to mioni [26].

2.4 *Particle flow algoritam*

U detektoru, nakon sudara, čestice ostavljaju mnoštvo individualiziranih signala u točkama u kojima interagiraju s detektorom. Iz tih signala je potrebno izvući informaciju o kojim (ili kakvim) se česticama radi i pronaći četveroimpuls za svaku od njih. U CMS-u, za to nam služi tzv. particle flow algoritam [29]. On signale iz detektora rekonstruira u pojedine fizikalne objekte - rekonstruirane čestice - i svrstava ih u jednu od 5 kategorija - elektrone, fotone, mione, nabijene hadrone te neutralne hadrone.

Particle flow algoritam prvo rekonstruira mione, uzimajući signale iz sustava za detekciju miona. Tim signalima pokušava pridružiti signale iz ostalih poddetektora po osnovi bliskosti po kutu te one signale koje uspije pridružiti izuzima iz daljnje rekonstrukcije. Zatim rekonstruira fotone i elektrone paralelno uzimajući podatke iz ECAL-a i detektora tragova. Elektrone razlikuje od fotona po prisutnosti tragova u silicijskim detektorima koji su u skladu s energijom deponiranom u kalorimetru. Općenito, nabijene čestice ostavljaju trag u silicijskom detektoru iz čega se ekstrapolira putanja. Ako ta ekstrapolirana putanja prolazi kroz grupu signala u kalorimetru ili je blizu u η-ϕ prostoru[5], energija deponirana u toj grupi signala u kalorimetru pridružuje se toj nabijenoj čestici. Elektroni često emitiraju fotone zbog zakočnog zračenja (Bremsstrahlunga) pa se koristi poseban algoritam koji pridružuje energiju tih fotona elektronu koji ih je emitirao. Time se postiže još bolja rezolucija na energiju elektrona. Zadnji objekti koji se rekonstruiraju su nabijeni i neutralni hadroni. Oni se razlikuju slično kao i što se razlikuju elektron i foton - nabijeni hadroni ostavljaju trag u silicijskom detektoru koji je u slaganju s energijom koja je deponirana u HCAL-u, dok neutralni hadroni ne ostavljaju takav trag.

[5]Definicija η i ϕ bit će dana kasnije u tekstu.

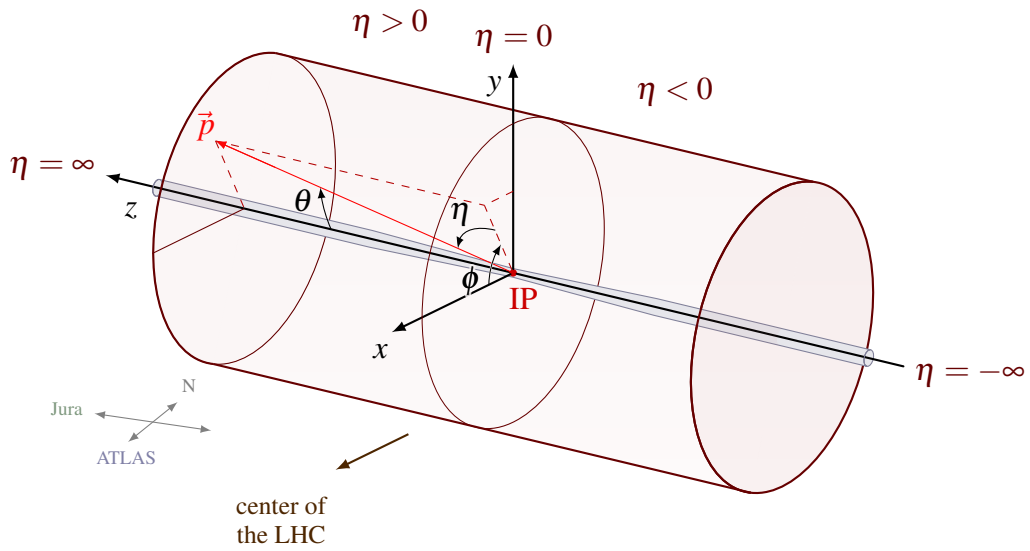

Slika 2.3: Koordinatni sustav CMS-a. Preuzeto i modificirano iz [30].

2.5 *Identificiranje hadronskih mlazova*

U ovome radu posebno smo zainteresirani kako detektirati čestice nastale iz raspada b kvarka. Naime, Higgsov bozon se pretežito raspada u par b kvarkova, s omjerom grananja od oko 57%. Kvarkove, kao i gluone, ne vidimo same u prirodi nego u bezbojnim vezanim stanjima zbog bojnog zatočenja. Kvarkovi, nastali u sudaru, su inicijalno slobodni te interagiraju međusobno i zrače gluonima, no zbog bojnog zatočenja ne mogu se propagirati slobodno. Stoga nakon produkcije, oni brzo povlače par kvark-antikvark iz vakuuma i tako formiraju hadron[6]. Taj hadron je često nestabilan, pa nakon njegovog formiranja slijedi lavina raspada, tijekom koje nastaje mnoštvo lakših hadrona. Ako je inicijalni hadron imao vrlo visoki impuls, lakši hadroni koje mi detektiramo pojavit će se u uskom konusu te tada govorimo o mlazu hadrona [4].

U CMS-u, hadroni se detektiraju primarno u HCAL-u, gdje ostavljaju najveći dio svoje energije. Hadroni se rekonstruiraju pomoću particle-flow algoritma koji određuje jesu li nabijeni ili neutralni i koji je njihov impuls. Drugim riječima, hadronske mlazove vidimo kao nakupinu hadrona koji su "blizu" jedan drugome u HCAL-u. Da bismo prepoznali hadronski mlaz, trebamo definirati što "blizu" znači. Zbog toga, prvo definiramo kartezijanski sustav CMS detektora. Središte tog sustava je u točki sudara u CMS detektoru, os z se nalazi u smjeru putanje protona, os x pokazuje prema središtu LHC-a, a y-os pokazuje prema površini Zemlje. No, češće se koristi koordinatni sustav definiran transverzalnim impulsom p_T,

[6]Svi osim top kvarka. Top kvark ima srednje vrijeme života za tri reda veličine manje od vremena koje je potrebno da se formira hadron, pa ga ne vidimo u obliku hadrona.

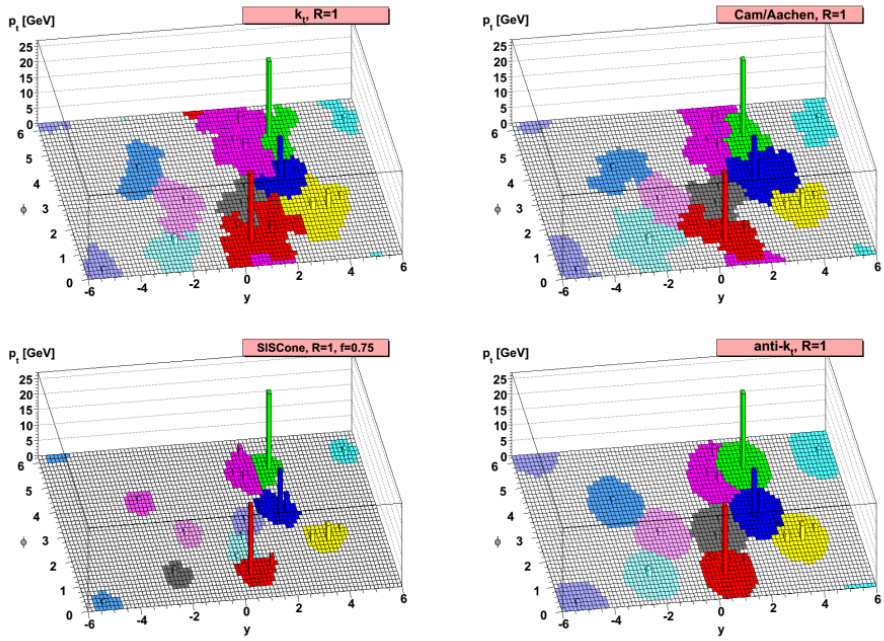

Slika 2.4: Usporedba rada algoritama za grupiranja hadrona. Preuzeto iz [31].

pseudorapiditetom η i azimutalnim kutom ϕ (slika 2.3) jer posjeduje simetrije na potiske niz z-os koje su bitne kod definiranja algoritama. Transverzalni impuls p_T je impuls koji čestica posjeduje u smjeru koji je okomit na smjer strujanja protona, azimutalni kut ϕ se mjeri od pozitivne x-osi u x-y ravnini, dok je pseudorapiditet, η, aproksimacija rapiditeta, y, u limesu kada impuls čestice puno veći od njene mase (što je slučaj u velikoj većini fizike koju CMS) promatra. Pseudorapiditet je definiran kao:

$$\eta = -\ln\left[\tan\left(\frac{\theta}{2}\right)\right], \tag{2.1}$$

gdje je θ polarni kut mjeren od pozitivne z-osi [10].

Kod prepoznavanja hadronskog mlaza bitna nam je kutna udaljenost između čestica koju definiramo kao:

$$\Delta_{ij} = \sqrt{(\eta_i - \eta_j)^2 + (\phi_i - \phi_j)^2}, \tag{2.2}$$

gdje i i j označavaju i-tu i j-tu česticu. Nakon što smo definirali kutne udaljenost između čestica, hadronske mlazove možemo dobiti grupiranjem hadrona na temelju te udaljenosti. Postoji mnoštvo algoritama za grupiranje hadrona, no mi ćemo samo spomenuti grupu onih koji rade na sličan način. Prvo, definiramo težinsku udaljenosti u algoritmu:

$$d_{ij} = \min(p_{T,i}^{2\alpha}, p_{T,j}^{2\alpha})\frac{\Delta_{ij}^2}{R^2}, \tag{2.3}$$

gdje je d_{ij} mjera udaljenost između hadrona i i j, R parametar radijusa, a α parametar specifičan za algoritam grupiranja. Primjerice, k_T algoritam koristi $\alpha = 1$, dok je $\alpha = 0$ svojstven Cambridge/Aachen algoritmu. CMS koristi anti-k_T algoritam kod kojeg je $\alpha = -1$. Definirajući R i α, mi definiramo točno algoritam za grupiranje hadrona [31, 32].

Da demonstriramo kako anti-k_T algoritam radi, zamislimo događaj u kojem imamo nekoliko "tvrdih" čestica, čestica s visokim impulsom, te puno "mekih" čestica, čestica s relativno niskim impulsom. Algoritam će tražiti čestice međusobno s minimalnim d_{ij}, grupirati ih i ići dalje dok god je ta težinska udaljenost manja od nekog praga. Težinska udaljenost d_{ij} između jedne tvrde i jedne meke čestice, bit će određena isključivo impulsom tvrde čestice i kutnom udaljenošću. Ista ta težinska udaljenost između dvije meke čestice stoga će biti puno veća. Zbog toga meke čestice imaju tendenciju grupirati se oko jedne tvrde čestice umjesto da se grupiraju međusobno. U slučaju da oko jedne tvrde čestice nema nijedne druge tvrde čestice unutar kutne udaljenosti $2R$, oko tvrde čestice će se grupirati sve meke čestice u konusu polumjera R. Ako postoji još jedna tvrda čestica na kutnoj udaljenosti $R < \Delta_{ij} < 2R$, formirat će se dva konusa čija će granica ovisiti o omjeru impulsa tvrdih čestica. Ako pak postoji još jedna tvrda čestica na kutnoj udaljenosti manje od R mogu se dogoditi dva slučaja. U prvom slučaju, jedna od tvrdih čestica ima znatno veći impuls od druge te se oko nje grupira mlaz u obliku konusa. U drugom slučaju, tvrde čestice imaju usporedive impulse te se mlaz formira u nešto kompleksnijem obliku koji izgleda kao unija dva konusa. Rezultati rada algoritma i njihova usporedba s ostalim algoritmima prikazani su na slici 2.4 [31].

U CMS-u za rekonstrukciju običnih mlazova koristi se tzv. AK4 algoritam - anti-k_T algoritam radijusa $R = 0.4$. Taj se algoritam koristi za grupiranje hadrona u mlaz koji je potekao iz jednog kvarka ili gluona. No, osim toga koristi se i jedan algoritam koji grupira nešto šire mlazove. Naime, postoje procesi koji produciraju kvark-antikvark parove, u kojima su u određenim kinematičkim režimima kvark i antikvark kolimirani. Jedna od takvih situacija će nas zanimati u ovome radu - promatrat ćemo proces u kojem se producira ultrarelativistički Higgsov bozon čijim su raspadom 2 mlaza iz b kvark-antikvark para kolimirana. Takav širi mlaz se zove debeli mlaz, a on se rekonstruira s tzv. AK8 algoritmom, anti-k_T algoritam radijusa $R = 0.8$. Dakle, debeli mlazovi su širi mlazovi koji se sastoje od barem 2 podmlaza koji su kolimirani.

Svaki od hadrona koji je grupiran u mlazu ima pridruženi četveroimpuls. Masu mlaza dobivamo iz invarijantne mase svih hadrona u mlazu. No, masa mlazova nije precizna zbog okruženja u kojem detektor radi. Naime, prilikom prolaska jednog snopa protona kroz drugi

bude oko 60 neelastičnih sudara, od kojih je možda 1 s tvrdim procesom koji je nama zanimljiv. Čak i u svim nezanimljivim neelastični procesima, dezintegrira se proton te pri tome nastaju laki hadroni koji se "nakupljaju" u detektoru (engl. pile-up). Osim toga, i kod sudara koji nam je zanimljiv, samo jedan parton po protonu interagira pri tvrdom procesu, dok ostali partoni se raspršuju i hadroniziraju (engl. underlying event). Oba ova načina generiranja hadrona koji nisu povezani sa zanimljivim sudarom mogu se detektirati u blizini stvarnog mlaza, time kvareći rezultat za masu mlaza. Problem je još izraženiji za debele mlazove čiji je konus širi, te je time i šansa da će se takvi hadroni naći u debelom mlazu veća. Zbog toga postoje algoritmi koji pokušavaju isključiti takve hadrone iz mlazova i što bolje mu procijeniti masu. Skup takvih algoritama se zove algoritmi za dotjeravanje mlazova (engl. jet grooming), a nama najvažniji je tzv. softdrop algoritam. Softdrop algoritam degrupira čestice iz mlaza i isključuje meke čestice koje su relativno daleko od tvrde čestice, a da njihovim izbacivanjem se masa mlaza ne mijenja znatno te tako procjenjuje masu [33].

2.6 Identifikacija b mlazova

Osim samog grupiranja hadrona, mlazovi su nam i bitni jer želimo dobiti informaciju iz koje čestice u početnom stanju su nastali. Specifično, za ovu analizu želimo odrediti jesu li mlazovi nastali iz b kvarka ili nisu. Detektiranjem mlazova ne možemo direktno zaključiti iz kojeg je procesa on potekao, niti kakvog je okusa bio kvarka (ili gluon) koji ga je producirao. No, mlazovi u sebi mogu sadržavati mnoštvo svojstava koji ukazuju na to koji su to procesi bili ili okuse kvarkova iz kojih su potekli. Jedno od svojstava koje razlikuje b mlazove (mlazove koji su potekli iz b kvarka) od ostalih je to da hadroni koji su nastaju hadronizacijom b kvarka - B hadroni - imaju relativno dugo vrijeme života, $\tau \approx 10^{-12}$ s. Iako je to prekratko vrijeme da B hadron doleti do detektora da ga izravno detektiramo, dovoljno je dugo da prijeđe nekoliko milimetara prije nego što se raspadne. Tih nekoliko milimetara je sasvim dovoljno da možemo detektirati tu točku raspada - sekundarni verteks - mjereći tragove čestica koje su nastale raspadom iz B hadrona (slika 2.5) [34].

Iako je postojanje sekundarnog verteksa dobra indikacija da se B hadron pojavio, ta informacija nije definitivna. Postoje i neke druge informacije koje razlikuju B hadrone od ostalih poput relativno velike mase od 5 GeV i veliki multiplicitet tragova. Stoga, za identifikacija je li mlaz nastao iz b kvarka ili nije potrebno je kombinirati brojne informacije, a to se postiže metodama strojnog učenja kombinirajući razna izmjerena svojstva mlaza, poput broja hadrona u mlazu, mase mlaza i postojanje sekundarnog verteksa iz kojeg je mlaz nas-

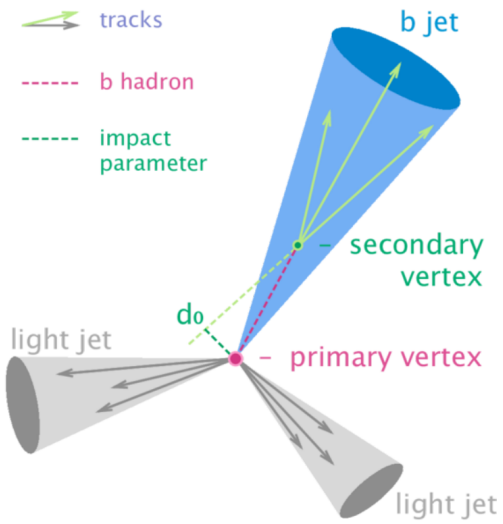

Slika 2.5: Usporedba b mlaza s mlazovima poteklih iz lakših kvarkova ili gluona. Na slici je istaknut sekundarni verteks, gdje se raspada B hadron nastao hadronizacijom b kvarka, čija je udaljenost od primarnog verteksa (točke sudara) mjerljiva pomoću detektora tragova. Preuzeto iz [34].

tao. Jedan od takvih algoritama je i ParticleNet koji nam ocjenjuje koliko je vjerojatno da je jedan debeli mlaz nastao iz para b kvarkova i kakvim raspadom. ParticleNet je algoritam koji vraća nekoliko varijabli, sve u rasponu od 0 do 1, koje možemo interpretirati kao vjerojatnost da je debeli mlaz nastao određenim raspadom, npr. raspadom masivne rezonance $P(R \to b\bar{b})$ ili raspadom nekog lakšeg kvarka ili gluona $P(QCD)$. U ovoj ćemo analizi koristiti diskriminantu definiranu putem izraza $P(R \to b\bar{b}) / (P(R \to b\bar{b}) + P(QCD))$ [10, 34, 35].

3 Analiza

U potpoglavlju 1.3.1, spomenuli smo da se u standardnom modelu čestica nalazi najjednostavnije rješenje za Higgsov mehanizam. Također smo spomenuli i da ne postoji razlog zašto to rješenje ne može biti nešto kompleksnije te prikazali primjer modela dva realna singleta koji predviđa postojanje još dva skalara u Higgsovom sektoru, X i Y. Ti skalari, pod uvjetom da su dovoljno masivni, kroz raspad mogu generirati 3 Higgsova bozona u konačnom stanju iz kojeg mi možemo pokušati pronaći događaje koji upućuju na postojanje tog procesa ili odrediti gornje limese na udarni presjek tog procesa. Stoga ćemo se u ovoj analizi posvetiti jednom od mogućih kinematičkih scenarija - scenarija gdje su X i Y dovoljno masivni da se raspadaju u ultrarelativističke Higgsove bozone koji vlastitim raspadom produciraju kolimirane parove b mlazova (slika 3.1). U ovome ćemo poglavlju prvo predstaviti analizu u kojoj smo koristili Monte Carlo simulacije kako bi procijenili pozadinu te usporediti simulacije sa stvarnim podacima u faznom prostoru gdje ne očekujemo signal. Nakon toga, predstavit ćemo alternativnu metodu procjene pozadine baziranu na podacima, koja je motivirana s ciljem boljeg modeliranja QCD pozadine te na kraju ćemo tu metodu i primijeniti na podatke. S obje metode procjene pozadine, dat ćemo očekivanja za gornje limese procesa produkcije tripleta Higgsovih bozona.

3.1 Analiza pomoću uzoraka Monte Carlo simulacija

U fizici elementarnih čestica, u većini slučajeva ne postoje jednostavni izrazi pomoću kojeg možemo eksperimentalne rezultate usporediti s teorijskom vrijednošću. Zbog toga, ekspe-

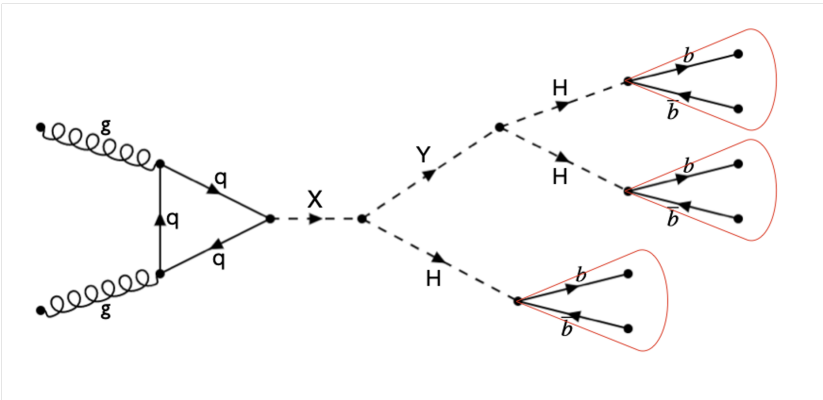

Slika 3.1: Kinematički režim u kojem se masivna skalarna rezonanca raspada u tri ultrarelativistička Higgsova bozona. Svaki od Higgsovih bozona raspadaju se u par b kvarkova koji imaju dovoljan potisak da 2 rezultirajuća hadronska mlaza su kolimirana te vidimo jedan debeli mlaz.

rimentalne podatke uspoređujemo sa simulacijama koje uzimaju u obzir teorijski dobivene veličine poput udarnih presjeka ili kutne distribucije čestica. Simulacije, pritom, ne generiraju samo događaje s česticama u konačnom stanju, nego i simuliraju kako se te čestice propagiraju kroz detektor te kakve signale ostavljaju u detektoru. Simulacije se, dakle, odvijaju na tri razine od kojih je prva generiranje čestica u sudaru. Druga je razina simulacija hadroniziranje kvarkova i gluona te simuliranje raspada svih nestabilnih čestica. Posljednja razina simulacije je propagiranje čestica u konačnom stanju kroz detektor pri čemu se simulira interakcija čestice s detektorom i signal koji ta interakcija ostavlja. I iz stvarnih i iz simuliranih signala u detektoru, rekonstruiraju se događaji, te, naposljetku, možemo statističkom analizom usporediti kako se naša mjerenja slažu sa simulacijama. Iz te statističke analize doznajemo učestalosti određenih procesa, pomoću nje se testiraju hipoteze, daju procjene na granice teorija i, općenito, dolazi se do novih spoznaja. U ovoj analizi uzet ćemo u obzir uzorke simulacija QCD procesa lakih kvarkova i gluona koji bi mogli generirati debele mlazove i sudare u kojima se generira par top kvarkova kao pozadinu. Potpis signalnog procesa, koji je već objašnjen i dan na slici 3.1, tražit ćemo u području masa čestica X i Y: $800 < M_X < 4000$ GeV, $300 < M_Y < 2000$ GeV i $M_Y < M_X$, a za početak ćemo uzeti da su mase X i Y čestice $M_X = 2000$ GeV i $M_Y = 1100$ GeV.

3.1.1 Selekcija događaja

Kao što smo već naveli u uvodu, u ovome ćemo se radu fokusirati na kinematički režim u kojem producirani Higgsovi bozoni imaju dovoljan impuls da su mlazovi iz para b kvarkova,

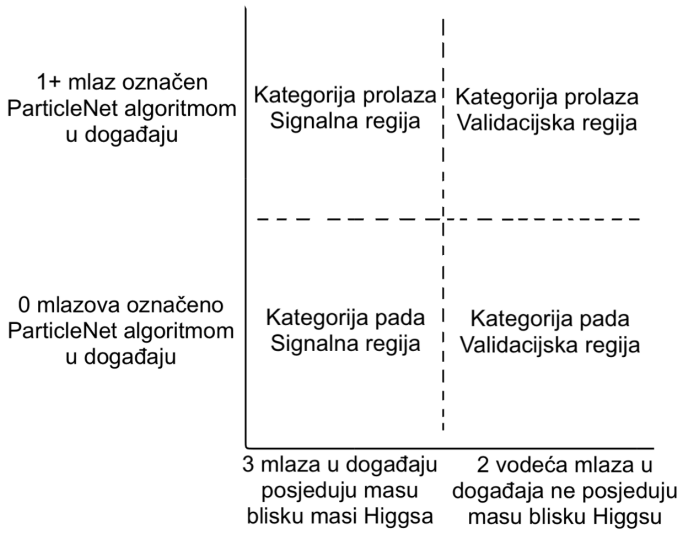

Slika 3.2: Zone u analizi.

nastalih raspadom Higgsa, kolimirani. To znači da ćemo, umjesto 6 mlazova, imati 3 tzv. debela mlaza. U ovoj analizi tražimo događaje koji imaju najmanje 3 debela mlaza i zadovoljavaju određene uvjete. Analizu smo pritom podijelili u dvije regije: validacijsku i signalnu regiju. U validacijskoj regiji ne očekujemo doprinos signalnog procesa, dok se u signalnoj regiji on može pojaviti. Pozadina u objema regijama dolazi iz raznih QCD procesa te iz produkcije para top kvarka i antikvarka.

U signalnoj regiji tražimo događaje s 3 ili više debelih mlazova koji zadovaljavaju sljedeće uvjete:

- Njihov je transverzalni impuls $p_T > 250$ GeV,
- Za pseudorapiditet vrijedi $|\eta| < 2.5$,
- Masa dobivena uklanjanjem širokokutnog zračenja, tzv. softdrop masa, je u danom rasponu 100 GeV $< m_{sd} <$ 150 GeV; drugim riječima, masa debelog mlaza je bliska masi Higgsovog bozona.

Nadalje, signalnu regiju dijelimo na dvije kategorije s obzirom na ParticleNet diskriminantu: kategoriju pada i kategoriju prolaza. U kategoriji prolaza tražimo da barem jedan od debelih mlazova ima ParticleNet diskriminantu veću od vrijednost koja odgovara labavoj radnoj točki (engl. loose working point), dok za kategoriju pada tražimo da nijedan od debelih mlazova ne zadovoljava odabranu radnu točku. Labava radna točka je definirana tako da je na njoj šansa da se krivo prepozna mlaz koji nije potekao iz b kvarka kao b mlaz (tzv. mistag rate) oko

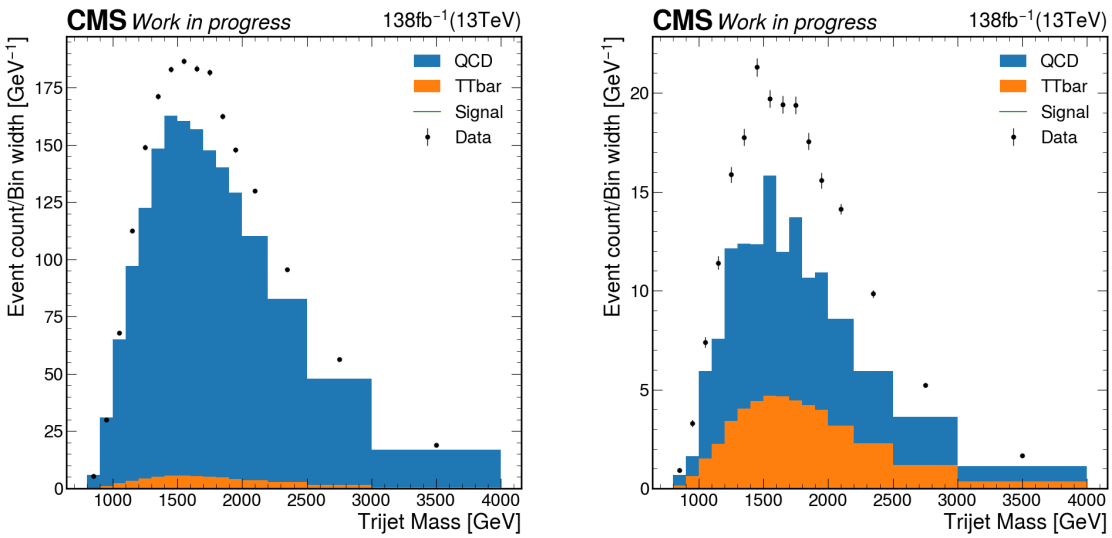

Slika 3.3: Raspodjela invarijantne mase tri hadronska mlaza za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u validacijskoj regiji.

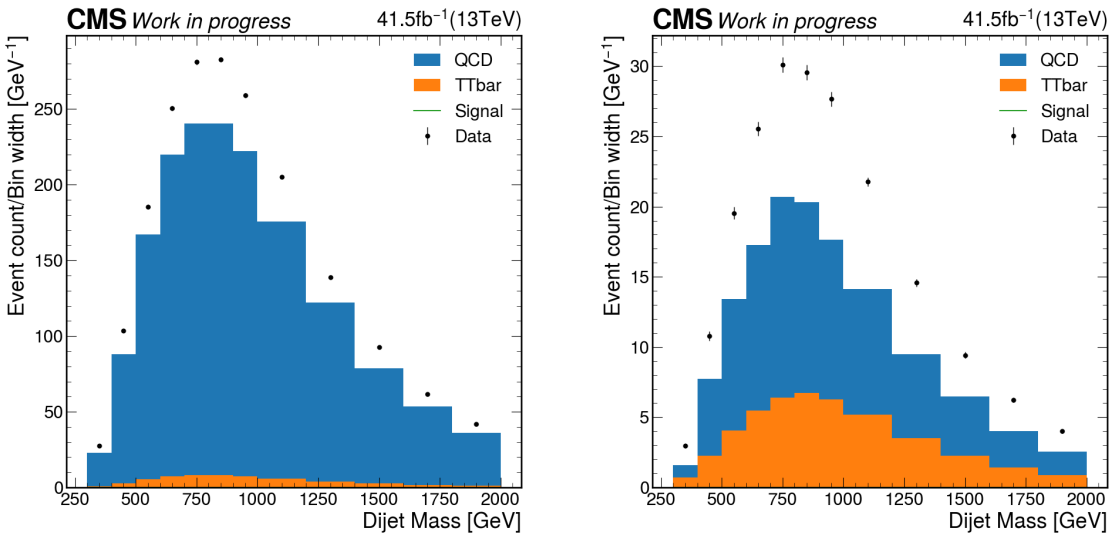

Slika 3.4: Raspodjela invarijantne mase dva hadronska mlaza za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u validacijskoj regiji.

10% [36]. Ta je radna točka definirana testovima na uzorku mlazova lakog okusa (mlazovi potekli iz u, d i s kvarkova) gdje je prosječni transverzalni impuls mlaza lakih okusa 80 GeV. Mistag rate ovisi o transverzalnom impulsu, te on općenito raste s transverzalnim impulsom. U našem slučaju mistag rate za QCD procese iznosi oko 1.5%, dok za $t\bar{t}$ produkciju iznosi 14%. Efikasnost ovog algoritma za signal - omjer mlazova koji algoritam ispravno prepozna kao b mlazove i ukupnog broja b mlazova - iznosi 79% za labavu radnu točku.

U validacijskoj regiji namećemo iste uvjete na događaje kao i u signalnoj regiji, ali s jednom bitnom razlikom: tražimo da 2 debela mlaza s najvećim transverzalnim impulsom u događaju ne zadovoljavaju uvjet sa softdrop masom. Drugim riječima, njihova je softdrop masa ili u rasponu od 50 GeV $< m_{sd} <$ 100 GeV ili veća od 150 GeV. Donja granica od 50 GeV je zahtijevana kako bi osigurali da softdrop algoritam ispravno radi. Kao i signalnu regiju, validacijsku regiju dijelimo na kategorije pada i prolaza. Stoga, u analizi imamo sveukupno 4 zone (slika 3.2).

U svakoj od regija i kategorija, promatrat ćemo distribucije invarijantne mase tri debela mlaza, za koju će signal imati rezonantni vrh na M_X, te invarijantne mase para debela mlaza gdje ćemo imati tri točke po svakom događaju jer imamo tri moguće permutacije, gdje će jedna od tih točaka odgovarati M_Y. Naime, mi ne znamo a priori koja dva debela mlaza dolaze iz raspada čestice Y pa moramo sve točke uzeti u obzir. U validacijskoj regiji ćemo promatrati rezultate koje nam simulacije daju i usporediti ih s mjerenjima, dok ćemo u signal regiji pogledati samo izgled simulacija jer ne želimo uvesti bilo kakvu pristranost, bilo

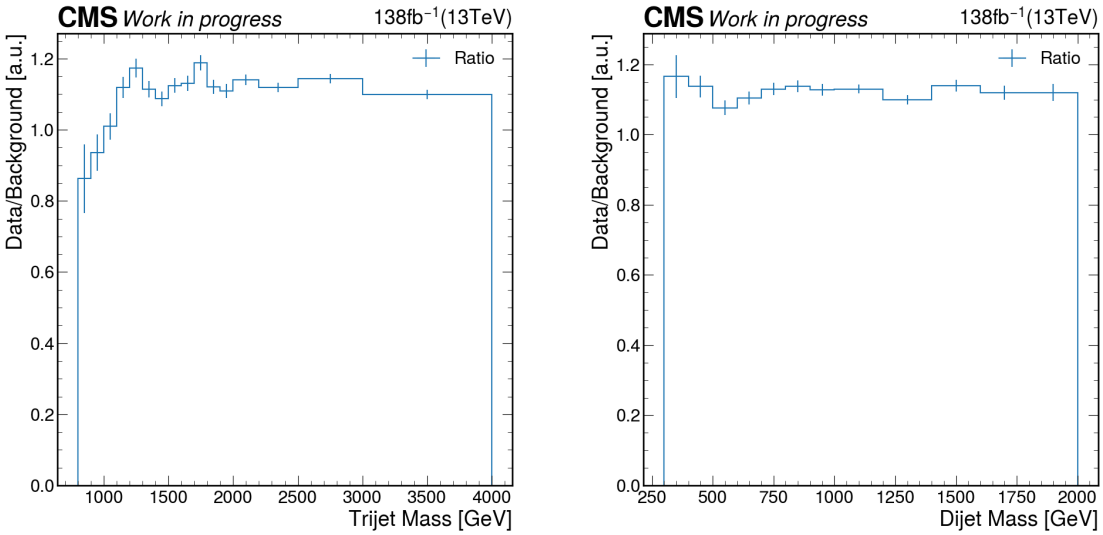

Slika 3.5: Omjer količine podataka i pozadine iz Monte Carlo simulacija u histogramu invarijantne mase (lijevo) triju mlazova i (desno) para mlazova u kategoriji pada u validacijskoj regiji.

namjernu ili nenamjernu, u analizu što će biti detaljnije opisano kasnije.

Distribucije invarijantne mase tri debela mlaza za kategoriju prolaza i kategoriju pada u validacijskoj regiji nalaze se na slici 3.3, dok se iste te distribucije za invarijantnu masu para debelih mlazova nalaze na slici 3.4. Iz tih četiriju distribucija, možemo izvući nekoliko zaključaka. Prvi je da se doprinos signalnog procesa ni u jednoj kategoriji ne vidi. Drugi je da se u kategoriji pada, simulacije dobro slažu s podacima u obliku, ali ne i u normalizaciji, što

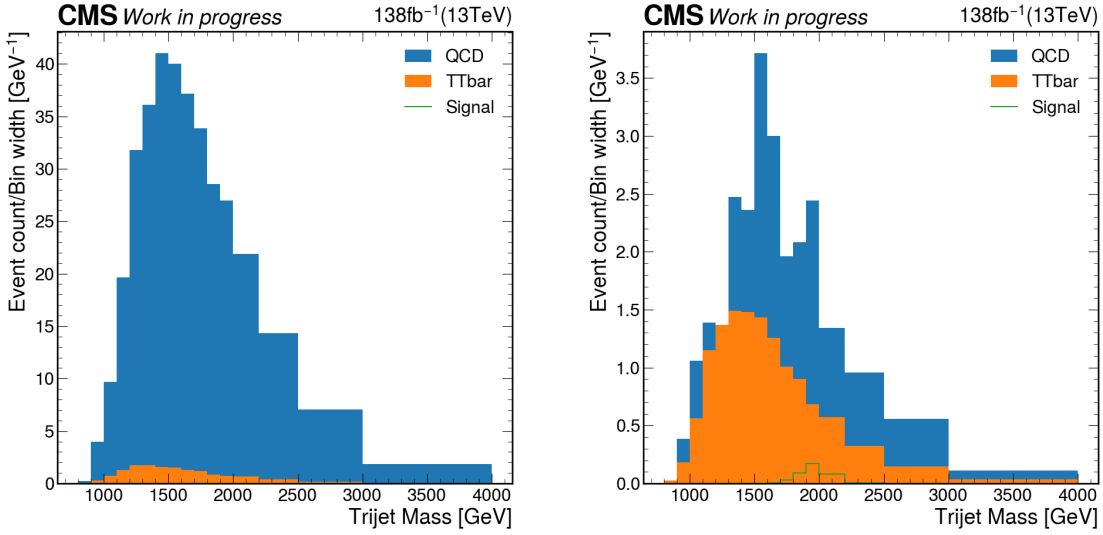

Slika 3.6: Raspodjela invarijantne mase tri hadronska mlaza za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u signalnoj regiji.

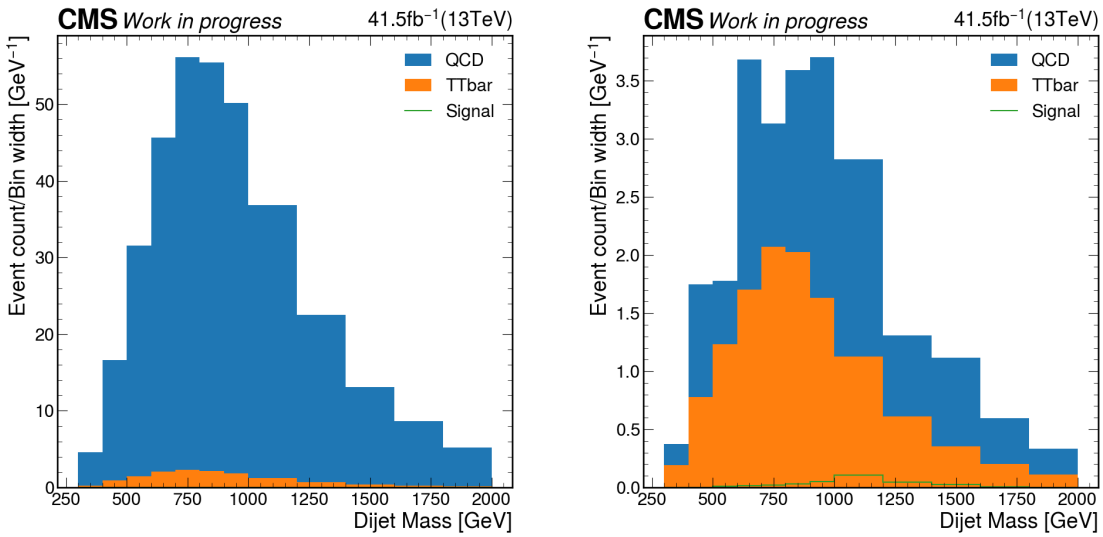

Slika 3.7: Raspodjela invarijantne mase dva hadronska mlaza za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u signalnoj regiji.

je djelomično potvrđeno i na slici 3.5, na kojoj je dan omjer između podataka i pozadine. Na toj slici vidimo da je omjer u distribuciji masa triju mlazova približno konstantan oko 1.1 (ne pokazuje tendenciju rasta ili pada), osim na vrijednostima masa manjim od 1200 GeV, gdje vidimo tendenciju rasta s masom. Za distribuciju masa para mlazova, omjer nam je također približno konstantan oko 1.1, ali na cijelom spektru. Treći je zaključak, pak, da zahtjev na ParticleNet diskriminantnu jako suzbija QCD procese i "kvari" izgled te distribucije na način da imamo velike statističke fluktuacije, što jasno vidimo u distribuciji mase triju mlazova u kategoriji prolaza. Zadnji je zaključak da se u kategoriji prolaza neslaganje mjerenja i simulacija povećava te da imamo sistematsko neslaganje.[7] QCD procesi su općenito teški za modelirati; problem su neperturbativnost QCD na niskim energijama, ali i količina QCD procesa koja se događa pri sudarima. Naime, pri sudarima na LHC-u se događa ogromna količina QCD procesa koja je redovima veličine veća od onoga što smo mi u stanju simulirati. Zbog toga, u kombinaciji s našom strogom selekcijom događaja koja gleda relativno maleni fazni prostor i činjenicom da se teorijska predviđanja za QCD procese računaju samo u vodećem redu računa smetnje, imamo velike statističke nesigurnosti.

U signalnoj regiji gledamo distribucije masa para mlazova i mase triju mlazova dobivene analizom samo simulacija. Namjerno ne gledamo distribucije dobivene analizom eksperimentalnih mjerenja jer ne želimo uvesti pristranost, bilo namjernu ili nenamjernu, u našu analizu u području u kojem smatramo da bi se signal mogao pojaviti. Taj se postupak naziva

[7] U nekim analizama se uvode dodatni faktori skaliranja koji "popravljaju" normalizaciju QCD procesa.

zaslijepljenost (engl. blinding). Kada bismo bili zadovoljni s rezultatima analize, i sa selekcijom događaja te sa tretiranjem sistematskih nesigurnosti, u validacijskom području, onda bismo mogli našu analizu "zamrznuti". Tek zamrzavanjem analize bismo se mogli odslijepiti (engl. unblind) te pogledati mjerenja i u tom području što bi nam dalo konačni rezultat naše cjelokupne analize.

Distribucije invarijantne mase triju mlazova i parova mlazova za kategoriju pada i prolaza prikazane su na slikama 3.6 i 3.7, respektivno. Za kategoriju pada možemo primijetiti da distribucije imaju sličan oblik kao i validacijskoj regiji, s nešto nižim integralom. U kategoriji prolaza, pak, doprinos QCD-a je opet jako suzbijen te njegova distribucija nije glatka ni kod invarijante mase triju mlazova ni kod mase para mlazova zbog statističkih fluktuacija. Signal, sa udarnim presjekom normaliziranim na $\sigma = 1$ fb, nije još jasno vidljiv, ali se počinje nazirati.

3.1.2 Gornji limesi na udarni presjek novih procesa

Modeli koji proširuju standardni model čestica često ovise o velikom broju parametara koji izravno ili neizravno utječu na udarne presjeke procesa od interesa, a ti parametri imaju veliki raspon mogućih vrijednosti. U praksi, to znači da ako ne pronađemo potpis signalnog procesa u podacima, ne možemo izravno opovrgnuti cijeli model kao nevaljao, nego samo staviti gornju granicu na udarni presjek signalnog procesa od interesa. Stavljanjem te granice, posredno ograničavamo vrijednosti parametara modela koji predviđaju takav proces.

Proces kojim stavljamo granice na udarne presjeke sastoji se od podosta koraka i u njemu pokušavamo obuhvatiti sve nesigurnosti koje imamo u eksperimentu - od luminoziteta do efikasnosti pojedinih dijelova detektora [37]. U analizama, obično se sa s označava signalni proces, a s b pozadinu. Uz to, dodaje se još jedna varijabla, snaga signala μ, čime očekivana vrijednost broja događaja postaje $b + \mu \cdot s$. I pozadina i signal ovise o parametrima (i teorijskim i eksperimentalnim) koje znamo s određenim nesigurnostima i koje obuhvaćamo skupom parametara smetnje θ, tako da s i b postaju funkcije ovisne o parametru smetnje $s(\theta)$ i $b(\theta)$.

Sljedeće, uvodimo funkciju gustoće vjerojatnosti sistematskih grešaka $\rho(\theta|\tilde{\theta})$, gdje je $\tilde{\theta}$ početna vrijednost, koja predstavlja naše uvjerenje koja je stvarna vrijednost θ. No, zbog interpretacije vjerojatnosti i drugih suptilnih detalja, u daljnjem postupku ne koristimo izravno $\rho(\theta|\tilde{\theta})$ nego $p(\tilde{\theta}|\theta)$ dan po Bayesovu teoremu $p(\tilde{\theta}|\theta) \approx \rho(\theta|\tilde{\theta}) \cdot \pi_\theta(\theta)$.

Prvi korak određivanja gornjih granica udarnih presjeka je da konstruiramo funkciju iz-

glednosti (engl. likelihood function) $\mathscr{L}(podaci|\mu,\theta)$:

$$\mathscr{L}(podaci|\mu,\theta) = Poisson(podaci|b(\theta)+\mu\cdot s(\theta))\cdot p(\tilde{\theta}|\theta), \tag{3.1}$$

gdje *Poisson*, u ovom slučaju, označava produkt vjerojatnosti po Poissonovoj distribuciji da opazimo n_i događaja u i-tom razredu:

$$\prod_i \frac{(b_i+\mu s_i)^{n_i}}{n_i!} e^{-b_i-\mu s_i}. \tag{3.2}$$

Podaci ovdje mogu biti eksperimentalno opaženi ili umjetno generirani pomoću Monte-Carlo simulacija iz predložaka što ćemo koristiti u narednim koracima.

Drugi je korak definiranje testne statistike $\tilde{q}_\mu$ koja nam omogućuje da usporedimo hipotezu koja obuhvaća samo pozadinu s hipotezom koja obuhvaća i signal i pozadinu:

$$\tilde{q}_\mu = -2\ln\frac{\mathscr{L}(podaci|\mu,\hat{\theta}_\mu)}{\mathscr{L}(podaci|\hat{\mu},\hat{\theta})},\ 0<\hat{\mu}<\mu, \tag{3.3}$$

gdje $\hat{\theta}_\mu$ predstavlja vrijednost parametra θ za koju se postiže najveća izglednost za dani μ i podatke, dok par vrijednosti $\hat{\mu}$ i $\hat{\theta}$ predstavlja vrijednosti tih parametara koji daje globalni maksimum. Donja granica na $\hat{\mu}$ dolazi od činjenice da je negativan signal nefizikalan, a gornja granica je nametnuta od strane nas kako bi garantirali interval pouzdanosti. Osim toga, veća vrijednost $\hat{\mu}$ ne uzima se kao dokaz protiv signalne hipoteze.

U sljedećem koraku pronalazimo opaženu vrijednost testne statistike $\tilde{q}_\mu^{obs}$ za dani μ te vrijednosti parametara smetnje $\hat{\theta}_0^{obs}$ i $\hat{\theta}_\mu^{obs}$ koje najbolje opisuju podatke za hipoteze samo pozadine te pozadine i signala, respektivno. Dalje, generiramo N uzoraka iz predložaka signala i pozadine pomoću Monte Carlo simulacija za hipotezu samo pozadine i hipotezu signala i pozadine. U toj simulaciji fiksirane su vrijednosti za μ, $\hat{\theta}_0^{obs}$ i $\hat{\theta}_\mu^{obs}$. Potom, iz tih N uzoraka mjerimo testnu statistiku i konstruiramo funkciju gustoće vjerojatnosti $f(\tilde{q}_\mu|\mu,\hat{\theta}_\mu^{obs})$ i $f(\tilde{q}_\mu|0,\hat{\theta}_0^{obs})$.

Iz $f(\tilde{q}_\mu|\mu,\hat{\theta}_\mu^{obs})$ i $f(\tilde{q}_\mu|0,\hat{\theta}_0^{obs})$ možemo definirati dvije p-vrijednosti za hipoteze pozadine i signala te samo pozadine, p_μ i p_b:

$$p_\mu = P(\tilde{q}_\mu \geq \tilde{q}_\mu^{obs}|signal+pozadina) = \int_{\tilde{q}_\mu^{obs}}^{\infty} f(\tilde{q}_\mu|\mu,\hat{\theta}_\mu^{obs})\mathrm{d}\tilde{q}_\mu, \tag{3.4a}$$

Tablica 3.1: Očekivane gornje granice na udarne presjek za nivo pouzadnosti od 95%. Pretpostavljeni luminozitet je 138 fb^{-1} što odgovara cijelom Run2.

Očekivane vrijednosti	Gornja granica na udarni presjek bez ParticleNet uvjeta (fb)	Gornja granica na udarni presjek s ParticleNet uvjetom (fb)
-2 std. dev.	$\sigma < 0.84$	$\sigma < 0.42$
-1 std. dev.	$\sigma < 1.14$	$\sigma < 0.56$
Medijan	$\boldsymbol{\sigma < 1.61}$	$\boldsymbol{\sigma < 0.78}$
+1 std. dev.	$\sigma < 2.32$	$\sigma < 1.11$
+2 std. dev.	$\sigma < 3.16$	$\sigma < 1.51$

$$1 - p_b = P(\tilde{q}_\mu \geq \tilde{q}_\mu^{obs} | samo\ pozadina) = \int_{\tilde{q}_0^{obs}}^{\infty} f(\tilde{q}_\mu | 0, \hat{\theta}_0^{obs}) \mathrm{d}\tilde{q}_\mu, \tag{3.4b}$$

te izračunati nivo pouzdanosti (engl. confidence level) $\mathrm{CL}_S(\mu)$ kao omjer ovih dvaju intervala:

$$CL_S(\mu) = \frac{p_\mu}{1 - p_b}. \tag{3.5}$$

Primjerice, ako je za $\mu = 1$ nivo pouzdanosti $\mathrm{CL}_S \leq \alpha$, onda kažemo da smo isključili signal snage $\mu = 1$ s nivoom pouzdanosti od (1 - α). Također, možemo podešavati μ dok ne dođemo do nekog određenog nivoa pouzadnosti, a najčešće se navodi nivo pouzdanosti od 95%.

Konkretno za ovaj rad, koristili smo predloške histograma za pozadinu i signal koje smo dobili u dosadašnjem tijeku analize. Osim toga, za ovaj postupak smo od smetnji uključili nesigurnost na luminozitet od 10%. Rezultati procjene nalazi se u tablici 3.1, a oni nam govore koje su očekivane vrijednosti gornje granice udarnog presjeka koje možemo isključiti ukoliko signal ne vidimo. Vidimo da ParticleNet uvjet spušta gornju granicu otprilike za faktor 2, te da je očekivana gornja granica oko 0.8 fb ako koristimo taj uvjet. Usporedimo li tu gornju granicu s udarnim presjekom produkcije 3 Higgsovih bozona po standardnom modelu koja iznosi 0.1 fb, vidimo da je gornja granica i dalje za red veličine veća, no taj je proces nerezonantan pa ga ne bismo mogli vidjeti kao vrh u histogramu M_X i M_Y.

3.2 Pregled metoda podatkovne procjene pozadine

Zbog velikog napretka u tehnikama prepoznavanja okusa podmlazova u hadronskom debelom mlazu, sve više analiza uključuje i topologije u kojima su mlazovi kolimirani. U analizama u kojima se koriste mlazovi time se u pozadinu uključuju i QCD procesi koji rezultiraju nastankom mlazova. No, QCD je zbog svoje prirode teško modelirati, a modeli koji uspjevaju to učiniti i dalje imaju visoke sistematske greške. Kada uzmemo u obzir da se u

analizi često postavljaju zahtjevi na svojstva mlaza, poput njegove mase i okusa, dolazimo do zaključka da simulacije često nisu dovoljne. Zbog toga su razvijene metode koje nam omogućuju da procjenimo pozadinu izravno iz podataka [38].

3.2.1 ABCD metoda

Poznato je da QCD procesi koji rezultiraju s više mlazova u izlaznom kanalu ne rezoniraju na određenoj invarijantnoj masi dvaju ili više mlazova. Pri našoj selekciji podataka, možemo na neki način oblikovati tu pozadinu, no ona neće imati prave karakteristike rezonantnog procesa. Ako gledamo distribuciju invarijantne mase sustava mlazova, njena krivulja će biti glatkog oblika i padajuća u odnosu na invarijantnu mase sustava mlazova. Zbog toga nam najčešće nije važan točan oblik spektra pozadine kako bismo mogli procijeniti pozadinu. Jedna od najjednostavnijih metoda procjene pozadine na osnovu podatka je ABCD metoda [38].

ABCD metoda je tako nazvana jer dijelimo naš prostor promatranja pomoću varijablama v_1 i v_2 na četiri regije: A, B, C i D (slika 3.8). Varijable v_1 i v_2 koristimo za odabir signala tako da se signal očekuje samo u regiji C. Stoga, u regijama A, B i D gotovo isključivo doprinosi pozadina, dok je regija C signalna regija, te u njoj očekujemo doprinos signalnog procesa, ako on postoji. U svakoj od regija su kreirane distribucije po razredima varijable koju mjerimo. Ova metoda pretpostavlja da je omjer pozadine C/D jednak omjeru A/B, te time onda daje procjenu za pozadinu u signalnoj regiji koja iznosi $C = A/B \cdot D$. Primjerice, ako smo u regiji A izmjerili 100, u regiji B 10, a u regiji D 50 događaja, onda bismo očekivali da u regiji C imamo 5 događaja pozadine. Regije, pritom, ne moraju nužno bit svedene na jednu brojku, nego mogu biti i distribucije. Omjer A/B zove se transfer funkcija i on ne

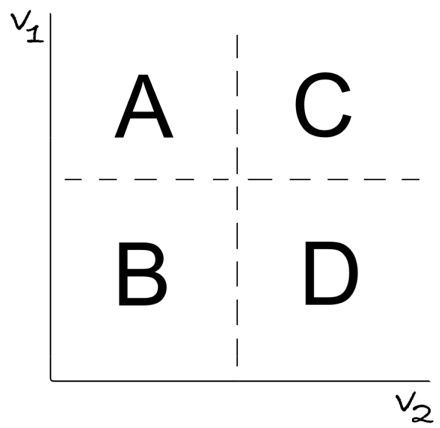

Slika 3.8: ABCD metoda. Inspirirano slikom 3.2 iz [38].

mora nužno bit konstantan u varijabli v_2. Dapače, često i nije, te se modelira polinomima niskog stupnja [38].

Ova se metoda pokazala uspješnom u prošlosti, no zbog pretpostavka da su omjeri A/B i C/D jednaki ima jednu manu. Ta je mana da se oblik pozadine u varijabli v_2 ekstrapolira iz ostalih regija. No, tome se može doskočiti tako da izaberemo prikladniju varijablu v_2 koja će razdijeliti prostor na još više dijelova tako da se signalna regija ne nalazi na rubu. Time zapravo više nećemo ekstrapolirati oblik pozadine. Naprotiv, tako ćemo ga interpolirati, što je i srž abecedne metode.

3.2.2 Abecedna metoda

Ako uzmemo u obzir sljedeći najjednostavniji slučaj, imat ćemo regije A, B, C, D, E i F, od kojih je C signalna regija (slika 3.9). Ovu metodu bismo mogli nazvati ABCDEF metodom, no svakim novim dodavanjem regija, naziv bi postajao sve nezgrapnijim pa se cijeli skup metoda naziva Abecednom metodom (engl. Alphabet method). U ovoj metodi više nemamo jednostavnu jednakost $C = A/B \cdot D$, nego pozadinu u C procjenjujemo na nešto složeniji način. Prvo, prinose pozadine između gornjih i donjih regija povezujemo transfer funkcijom $R_{Pass/Fail}$ koju modeliramo kao polinom niskog reda varijable v_2. Zatim, tu transfer funkciju prilagođavamo na podatke u svim područjima izuzevši C i D, te nakon prilagodbe tu transfer funkciju iskoristimo u regiji D što nam daje procjenu pozadine u regiji C [38].

Ova metoda ne mora biti ograničena samo na jednodimenzionalne histograme, nego se može i primijeniti na dvodimenzionalne histograme (ali i na histograme još viših dimen-

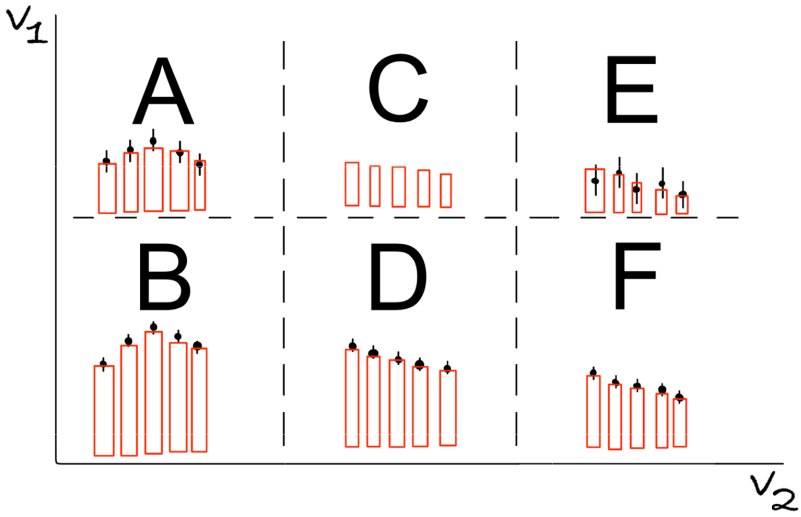

Slika 3.9: Abecedna metoda. Inspirirano slikom 3.3 iz [38]

zija). U tom slučaju govorimo o 2DAbecednoj metodi, a varijablu v_2 možemo shvatiti kao dvodimenzionalni vektor umjesto skalara.

3.2.3 Primjena abecedne metode na HHH analizu

U ovome ćemo radu raditi s metodom sličnoj 2DAbecednoj metodi. Kao pripadnu varijablu v_2 koristit ćemo 2D histogram invarijantne mase triju mlazova i para mlazova, a za v_1 koristit ćemo ParticleNet uvjet koji nam dijeli prostor na dvije kategorije - kategoriju prolaza i kategorija pada - koje su definirane u potpoglavlju 3.1. Naša metoda, iako vrlo slična 2DAbecednoj metodi, ima jednu vrlo bitnu razliku, a to je da mi zapravo nemamo klasično C i D područje. U našem slučaju mi imamo dvije katergorije (A i B ili P i F) - kategoriju prolaza i kategoriju pada opisane u potpoglavlju 3.1 - a svaki razred u histogramu možemo smatrati zasebnom regijom (slika 3.10). Naime, mi ne znamo a priori kolike će biti mase traženih čestica X i Y. Zbog toga, signal se može javiti gotovo u bilo kojem razredu naših histograma, pa zbog toga ne možemo rabiti klasičnu 2DAbecednu metodu u kojoj bi postojala jedna signalna regija.

Korištenje ovakve metode možemo opravdati uz nekoliko jednostavnih argumenata. Prvo, oblik pozadine, u varijablama invarijantne mase dvaju i triju mlazova, u našoj analizi bi trebao biti gladak i ne bi trebao imati odlike pravih rezonanci. Drugo, transfer funkciju između dvije kategorije modeliramo kao polinom niskog reda u varijablama invarijantne mase dvaju i triju mlazova. Treće, za signal očekujemo da će biti relativno uska rezonanca. U tom slu-

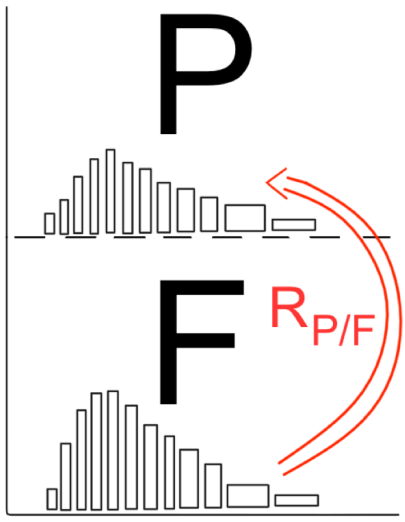

Slika 3.10: Metoda procjene pozadine korištena u ovom slučaju.

čaju, ako signal postoji i javi se u podacima, ne trebamo se brinuti da će ga naša metoda uspjeti pokriti kao pozadinu prilagodbom na podatke. Razlog je taj da kombinacija relativno glatkog oblika raspodjele i transfer funkcije kao polinoma niskog reda neće uspjeti prilagoditi pozadinu u signalnoj regiji kao pozadinu s uskom rezonancom.

Da bismo primjenili metodu, prvo definiramo prinos pozadine u kategoriji pada, $n_F^{bkg,data-driven}(i)$, za i-ti razred:

$$n_F^{bkg,data-driven}(i) = n_F^{podaci}(i) - n_F^{bkg,\,MC}(i), \tag{3.6}$$

gdje su $n_F^{podaci}(i)$ mjereni broj događaja u i-tom razredu, a $n_F^{bkg,\,MC}(i)$ broj događaja u i-tom razredu iz Monte-Carlo simulacija različitih uzoraka koji doprinose pozadini, a nisu pozadina koju pokušavamo procijeniti. Pod $n_F^{bkg,\,MC}(i)$ možemo uvrstiti dijelove pozadine koji su dobro modelirani, primjerice produkciju para top kvarkova u našem slučaju, ili pak ne uvrstiti ništa i cijelu procjenu raditi samo s podacima, ukoliko nam oblici pozadina to dozvoljavaju. Dalje, definiramo prinos pozadine u kategoriji prolaza, $n_P^{bkg}(i)$, za i-ti razred:

$$n_P^{bkg}(i) = n_F^{bkg,data-driven}(i) \cdot R_{P/F}(i) + n_P^{bkg,\,MC}(i) \tag{3.7}$$

gdje je $R_{P/F}(i)$ transfer funkcija koju modeliramo polinomom niskog stupnja. Na kraju, prilagođavamo jednadžbe (3.6) i (3.7) podacima tako da variramo i $n_F^{bkg}(i)$ i $R_{P/F}(i)$ koristeći metodu najveće izglednosti kako bismo dobili model koji najbolje opisuje pozadinu u obje kategorije. Funkcija izglednosti ima sljedeći oblik:

$$\begin{aligned}\mathscr{L} = &\prod_i \text{Poisson}(d_F(i)|n_F^{bkg,data-driven}(i) + n_F^{bkg,\,MC}(i)) \times \\ &\prod_i \text{Poisson}(d_P(i)|n_F^{bkg,data-driven}(i) \cdot R_{P/F} + n_P^{bkg,\,MC}(i) + \mu n^{signal}(i)),\end{aligned} \tag{3.8}$$

gdje su $d_F(i)$ i $d_P(i)$ eksperimentalno izmjereni podaci u kategoriji pada i prolaza. Prilagođavanjem $n_F^{bkg}(i)$, parametara u transfer funkciji $R_{P/F}$ i snage signala μ tražimo maksimum funkcije izglednosti. Također, prilagođavamo i parametre smetnje.

3.3 Rezultati podatkovne procjene pozadine

U ovome ćemo potpoglavlju predstaviti rezultate dobivene metodom procjene pozadine predstavljene u prošlom potpoglavlju. Prvo ćemo krenuti od usporedbe oblika pozadine u kate-

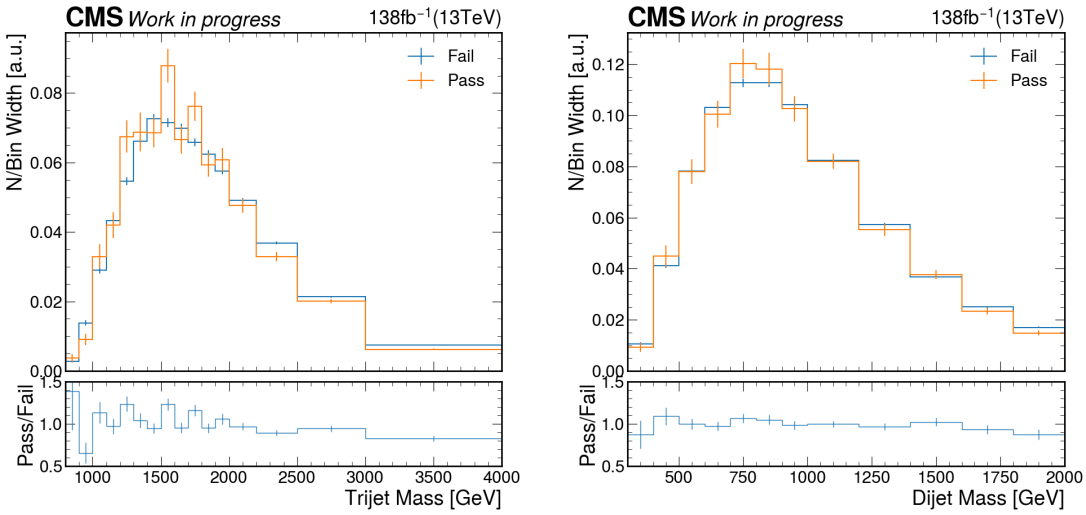

Slika 3.11: Normalizirane distribucije invarijantne mase (lijevo) triju mlazova i (desno) parova mlazova u kategorijama prolaza i pada za QCD procese u validacijskoj regiji i pripadni omjeri.

gorijama prolaza i pada kako bismo se uvjerili da su oni dovoljno slični jer je to važan preduvjet za korištenje ove metode. Zatim ćemo metodu primijeniti na validacijsku regiju da provjerimo radi li metoda kako bismo mi očekivali. Zato ćemo izvesti statističke testove - F-test i GoF test - da bismo taj odgovor dobili i numerički. Nakon te potvrde, iskoristit ćemo oblik transfer funkcije na signalnu regiju kako bismo iz toga izračunali gornje limese udarnih presjeka, što je konačni rezultat koji u ovome radu i tražimo.

3.3.1 Usporedba oblika pozadine

Kao što smo i spomenuli u uvodu ovog potpoglavlja, jedan od preduvjeta da metoda podatkovne procjene pozadine radi je da je oblik pozadine sličan između kategorija prolaza i pada. Kako bismo provjerili je li taj preduvjet zadovoljen, distribucije invarijantne mase dvaju i triju mlazova, dobivene iz simulacija, normalizirat ćemo tako što ćemo podijeliti sve razrede s integralom histograma i širinom razreda te pomnožiti sa sto[8], pa onda usporediti njihove oblike između kategorija prolaza i pada. Također, dati ćemo i omjere normaliziranih distribucija kako bismo lakše uočili neke razlike i njihove pravilnosti u distribucijama između kategorija prolaza i pada. Prvo ćemo usporediti oblike posebno za pozadinu porijeklom QCD procesa te iz produkcije $t\bar{t}$ u validacijskoj regiji, a potom i u signalnoj regiji.

Rezultati usporedbe oblika u validacijskoj regiji možemo vidjeti na slikama 3.11 i 3.12. Za QCD procese možemo primijeti da su distribucije mase parova mlazova za kategoriju pro-

[8]Zadnji korak radimo samo zbog ograničenja programa za crtanje, no on ni na koji način ne utječe na oblik.

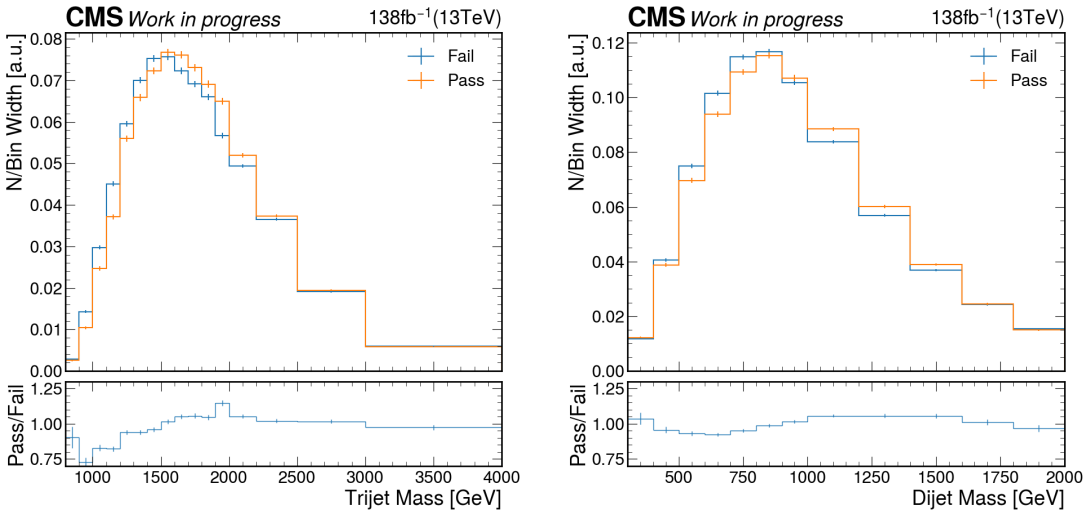

Slika 3.12: Normalizirane distribucije invarijantne mase (lijevo) triju mlazova i (desno) parova mlazova u kategorijama prolaza i pada za $t\bar{t}$ proces u validacijskoj regiji i pripadni omjeri.

laza i pada naoko vrlo slične s nekim odstupanjima, dok distribucije mase triju mlazova, iako relativno slične - unutar statističkih grešaka - imaju značajnija odstupanja u vidu nekoliko modulacija u omjerima. No, za ta bismo odstupanja dalje trebali istražiti jesu li ona samo do statistike ili predstavljaju sistematski efekt u simulaciji. To bismo učinili tako da bismo "olabavili" našu selekciju, zahtijevajući manje stroge uvjete, što bi dovelo do većeg broja selektiranih događaja pa time i do manjih statističkih nesigurnosti. U omjeru distribucija, pak, možemo vidjeti i da on u pravilu blago pada s porastom mase triju, ali i para, mlazova.

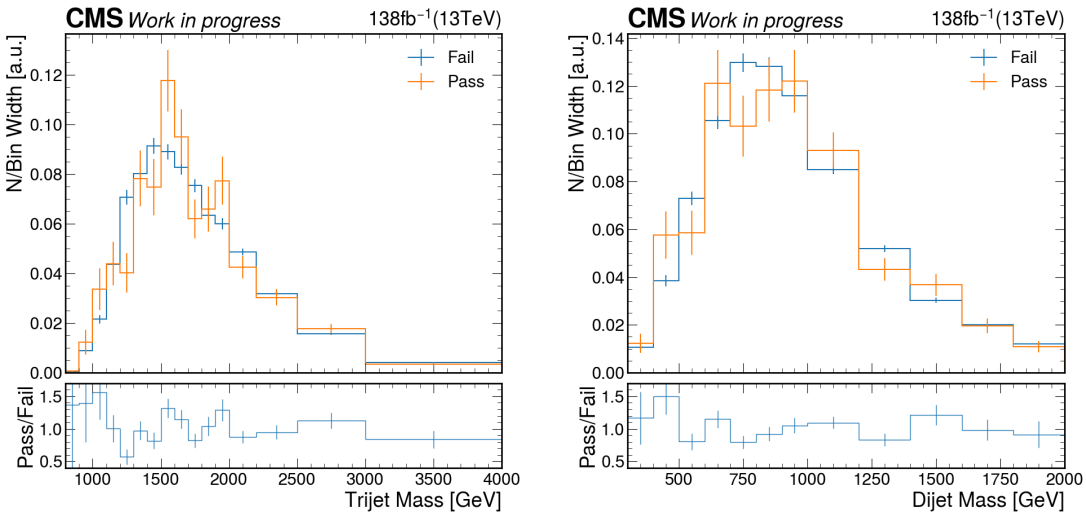

Slika 3.13: Normalizirane distribucije invarijantne mase (lijevo) triju mlazova i (desno) parova mlazova u kategorijama prolaza i pada za QCD procese u signalnoj regiji i pripadni omjeri.

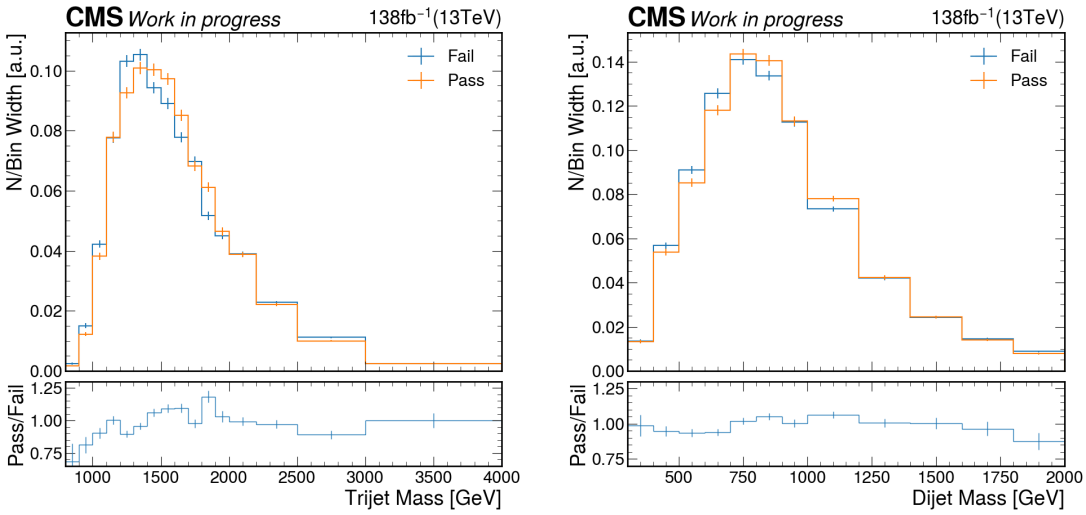

Slika 3.14: Normalizirane distribucije invarijantne mase (lijevo) triju mlazova i (desno) parova mlazova u kategorijama prolaza i pada za $t\bar{t}$ procesu signalnoj regiji i pripadni omjeri.

Za produkciju $t\bar{t}$, pak, vidimo da su distribucije mase i parova mlazova i triju mlazova vrlo slične u obliku. Tu se da i lijepo primijetiti i da je vrh distribucije lagano pomaknut udesno za kategoriju prolaza u odnosu na kategoriju pada za obje distribucije, što se potvrđuje i u omjerima distribucija. To se može izravno vidjeti činjenicom da na nižim vrijednostima doprinosi u kategoriji pada su gotovo uvijek viši, dok su doprinosi u kategoriji prolaza gotovo uvijek viši na većim vrijednostima masa. Naravno, taj pomak možemo modelirati u transfer funkciji metode podatkovne procjene pozadine.

Rezultati usporedbe oblika u signalnoj regiji prikazani su na slikama 3.13 i 3.14. Iako histogrami na prvu izgledaju različito od histograma za validacijsku regiju, zaključci su potpuno isti. Za QCD procese, distribucije masa su relativno slične, a odstupanja su većinom unutar statističkih grešaka, no opet imamo nekoliko modulacija u omjerima distribucija za koje nismo sigurni jesu li statistički ili sistematski efekt u simulacijama. Omjeri distribucija nam, kao i u validacijskoj regiji, ukazuju da oni padaju s masom para i triju mlazova, no ovdje je zaključak teže donijeti zbog većih oscilacija. Za pozadinu porijeklom iz produkcije $t\bar{t}$, distribucije su slične u obliku, te opet se može primijetiti da je vrh distribucije u kategoriji prolaza pomaknut blago udesno u odnosu na kategoriju pada za obje distribucije masa.

3.3.2 Primjena na validacijsku regiju

Nakon što smo se uvjerili da su oblici pozadine relativno slični između kategorije pada i kategorije prolaza, možemo primijeniti metode podatkovne procjene pozadine. Kao što smo

i već naveli, metodom možemo modelirati cijelu pozadinu ili samo dio nje, u slučaju da drugi dio pozadine modeliramo iz simulacije. Mi smo isprobali obje mogućnosti, što nam je dalo određenu fleksibilnost jer možemo izravno usporediti koja nam metoda daje bolju procjenu. U prvom smo slučaju modelirali dio pozadine pomoću simulacija produkcije top kvarkova, a dio koji je trebao predstavljati QCD procese smo modelirali podatkovnom procjenom. U drugom smo slučaju, pak, modelirali cijelu pozadinu podatkovnom procjenom.

Rezultati metode podatkovne procjene podataka u slučaju u kojem smo dio modelirali sa simulacijama produkcije top kvarkova mogu se vidjeti na slikama 3.15 i 3.16. Na lijevoj strani nalaze se histogrami koji odgovaraju kategoriji pada, dok su na desnoj strani histogrami koji odgovaraju kategoriji prolaza. Histogrami su po redu raspoređeni s obzirom na rez po masi dvaju ili triju mlazova kako bi izravna usporedba bila jasnija s obzirom na područje. Korištena transfer funkcija je linearnog oblika

$$R_{P/F}(x,y) = a + b \cdot x + c \cdot y, \tag{3.9}$$

gdje je x masa triju mlazova, dok y odgovara masi para mlazova. Vidimo da se procjena pozadina dana metodom relativno dobro slaže s podacima, pogotovo u distribuciji mase para mlazova, što vidimo na histogramima kad promatramo odstupanja procjene od podataka. Naravno, postoji i test koji nam daje numeričku ocjenu slaganja našeg modela s podacima, kao i test koji nam uspoređuje slaganje s obzirom na stupanj polinoma transfer funkcije. Oba ta testa će biti predstavljanje u sljedećem potpoglavlju, gdje će i bit opravdano korištenje transfer funkcije ovog oblika.

Rezultati metode podatkovne procjene podataka u slučaju u kojem smo cijelu pozadinu procijenili iz podataka mogu se vidjeti na slikama 3.17 i 3.18. Za razliku od slučaja gdje smo uključili simulacije produkcije top kvarka, ovdje smo koristili kvadratni oblik transfer funkcije:

$$R_{P/F} = a + b \cdot x + c \cdot y + d \cdot x^2 + f \cdot xy + g \cdot y^2. \tag{3.10}$$

Transfer funkciju u ovom obliku smo koristili jer nam je statistički test dao ocjenu da nam ona znatno bolje procjenjuje pozadinu od linearne transfer funkcije, a taj će statistički test biti objašnjen u sljedećem potpoglavlju. Možemo primijetiti da se i u ovom slučaju procjena posjeduje određeni stupanj slaganja s podacima, te bismo ju trebali usporediti s prethodnim slučajem, ali to ćemo tek moći dati nakon statističkih testova predstavljenih u sljedećem potpoglavlju.

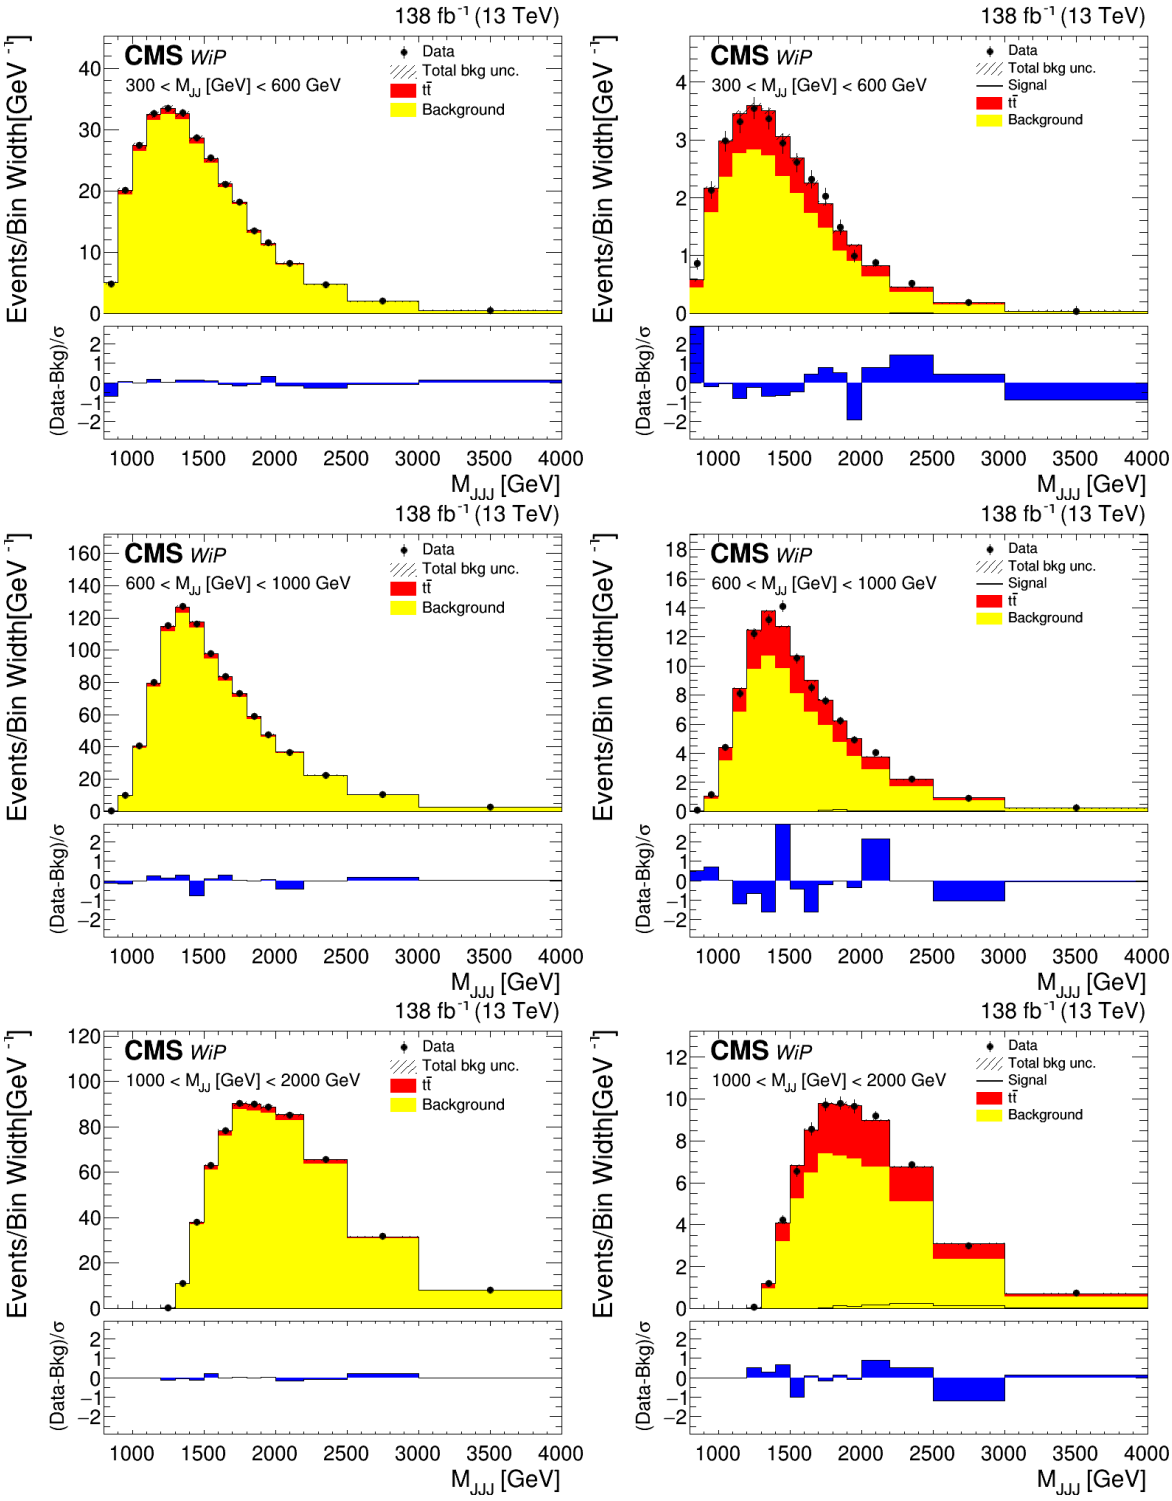

Slika 3.15: Rezultati procjene pozadine modelirane iz podataka i simulacija produkcije para top kvarkova u histogramu mase triju mlazova za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u validacijskoj regiji s istim rezovima na masu para mlazova u redu.

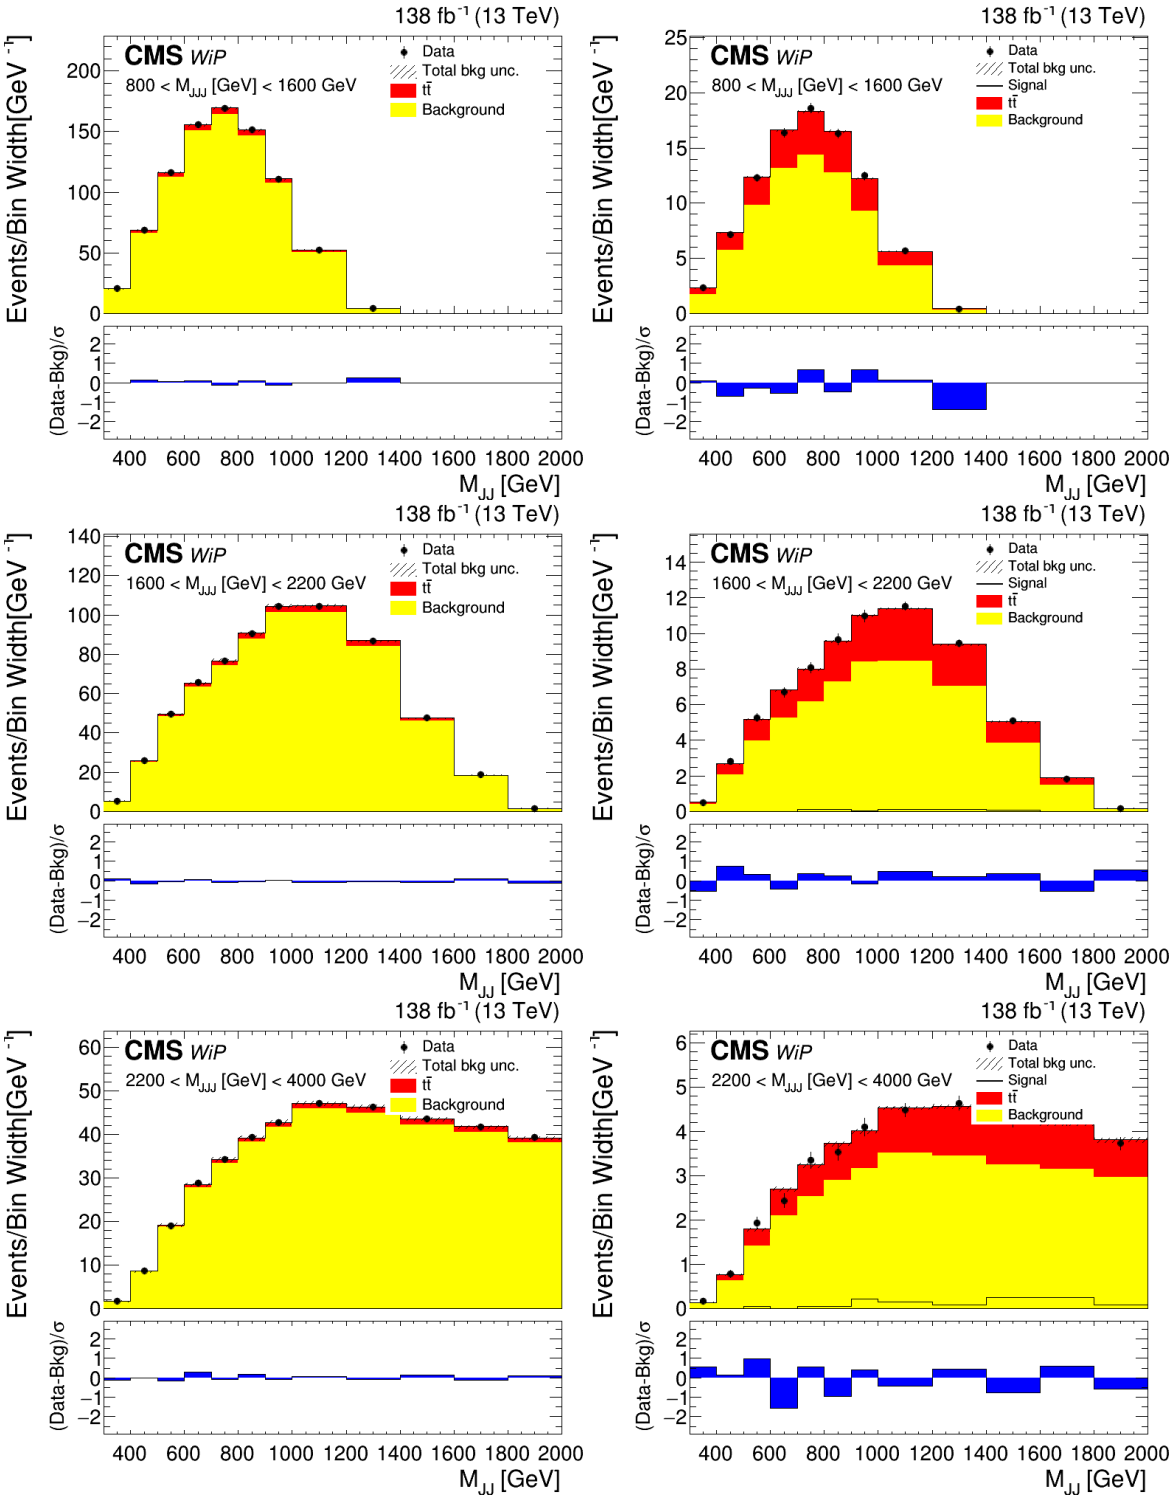

Slika 3.16: Rezultati procjene pozadine modelirane iz podataka i simulacija produkcije para top kvarkova u histogramu mase para mlazova za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u validacijskoj regiji s istim rezovima na masu triju mlazova u redu.

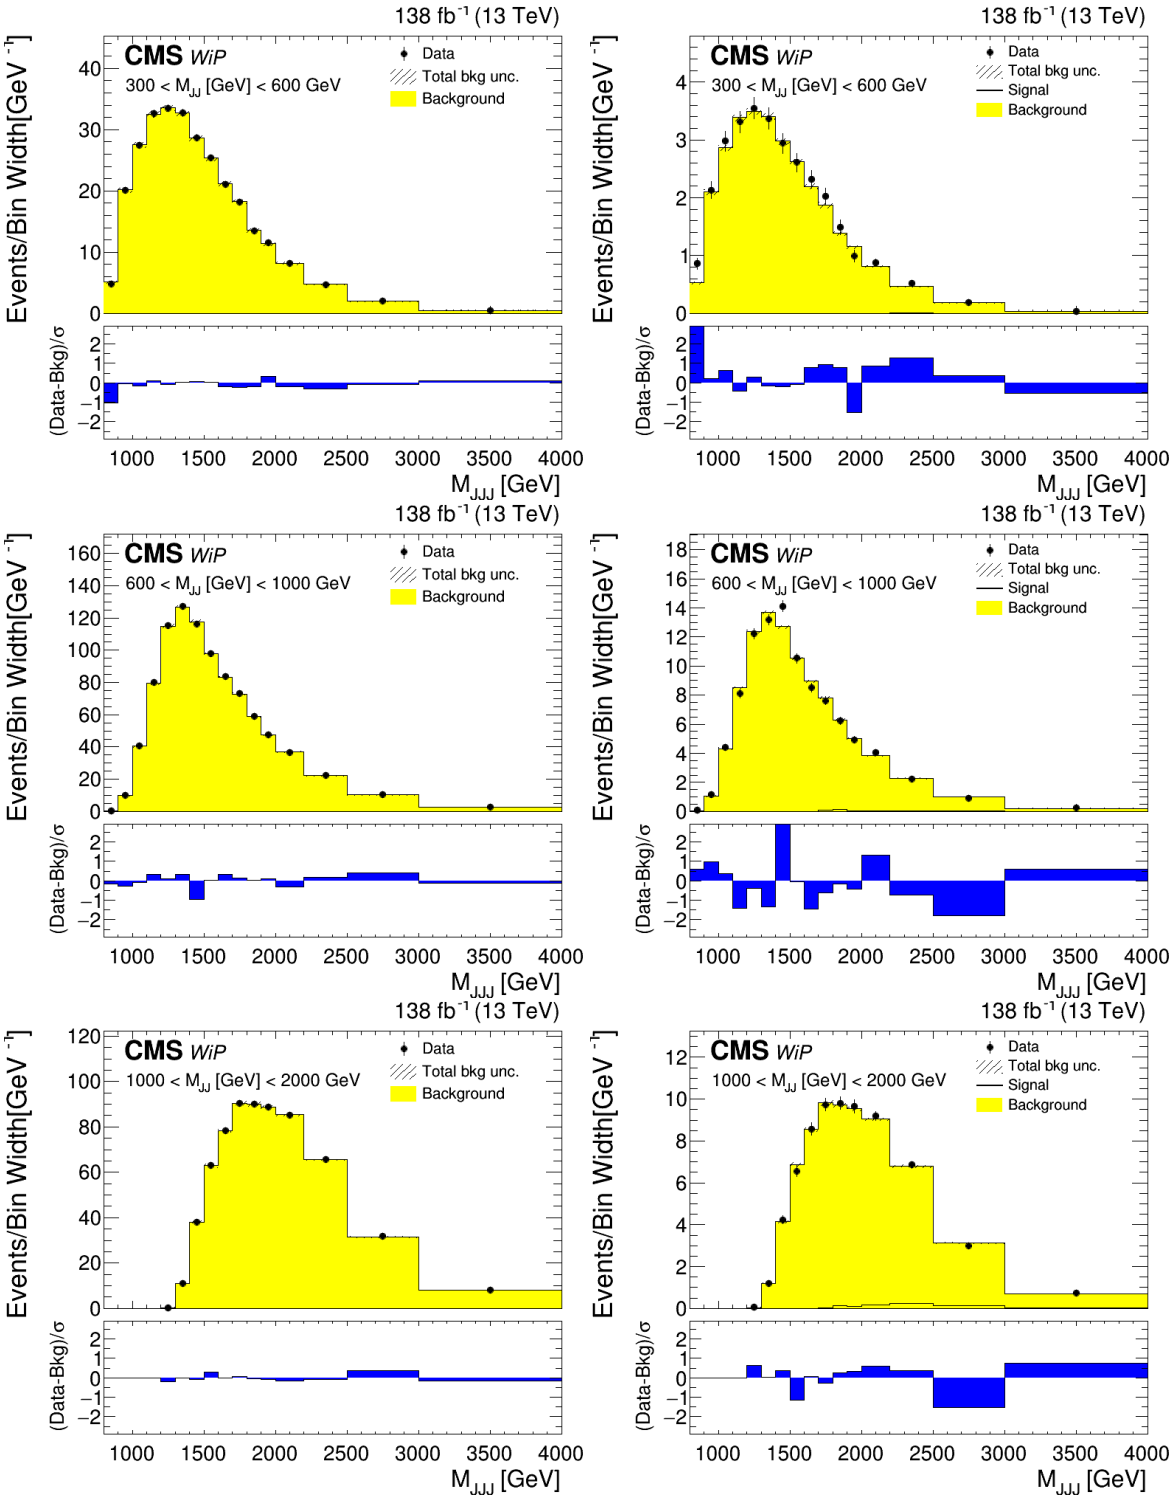

Slika 3.17: Rezultati procjene pozadine modelirane isključivo iz podataka u histogramu mase triju mlazova za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u validacijskoj regiji s istim rezovima na masu para mlazova u redu.

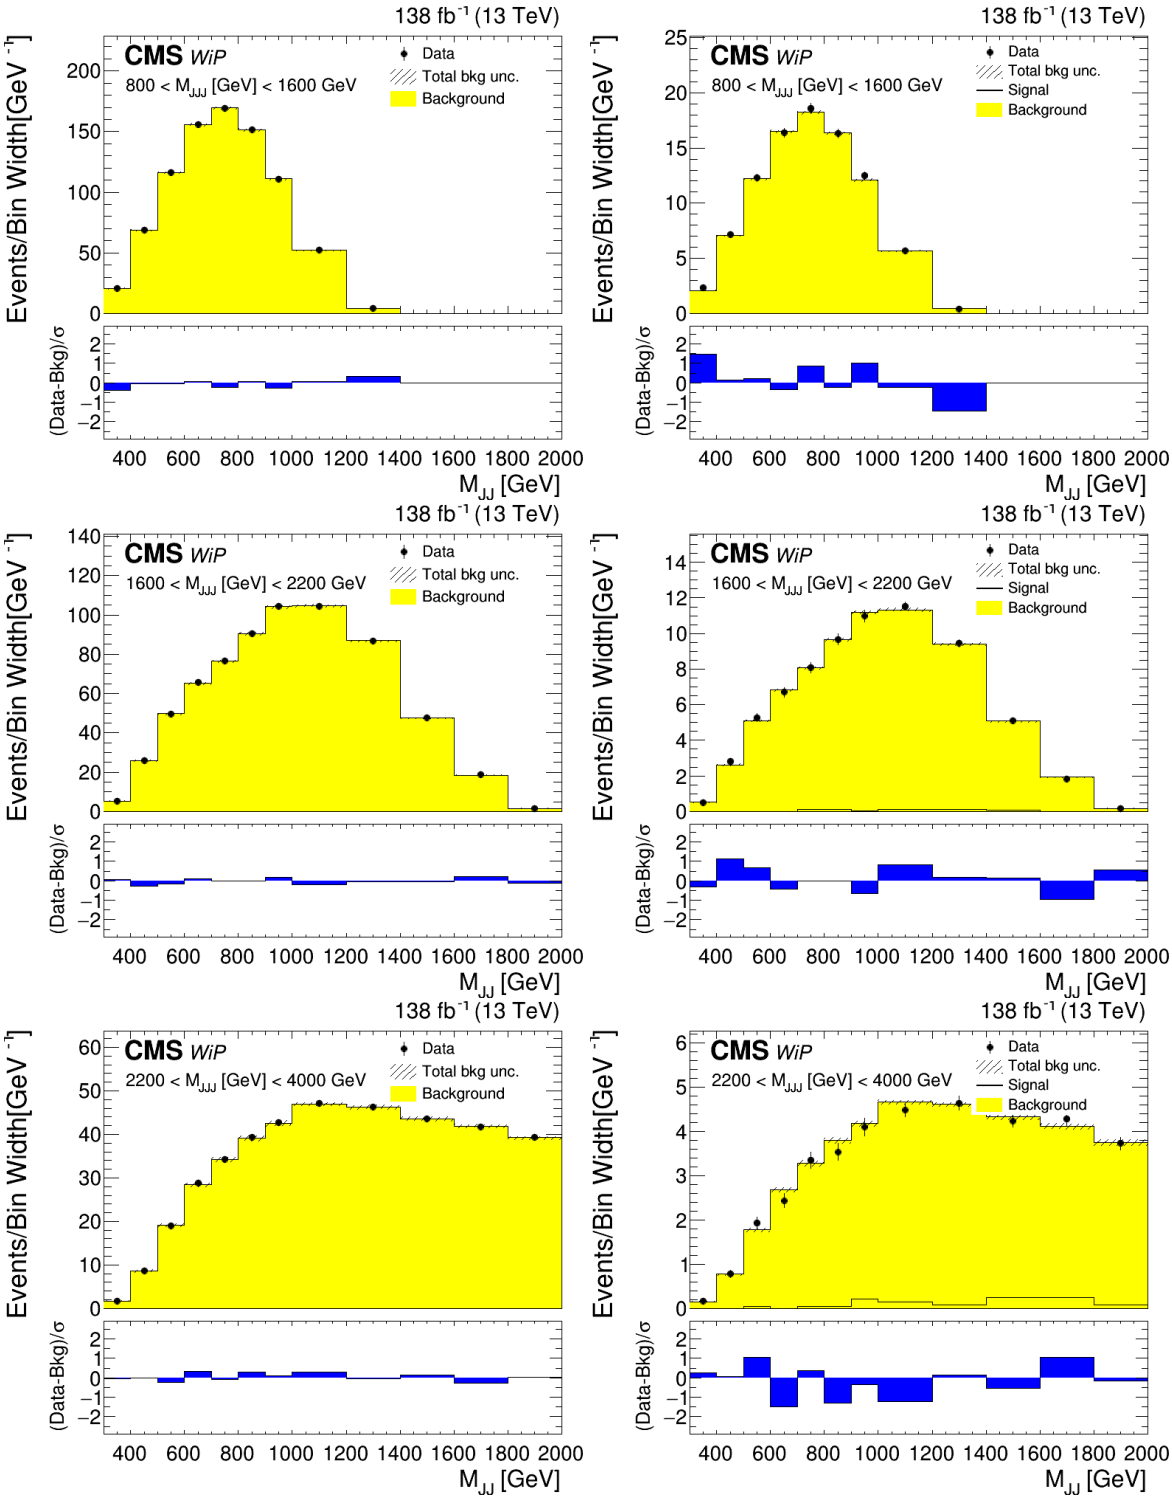

Slika 3.18: Rezultati procjene pozadine modelirane isključivo iz podataka u histogramu mase para mlazova za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u validacijskoj regiji s istim rezovima na masu triju mlazova u redu.

3.3.3 F-test i GoF

Da bismo potvrdili slaganje podataka i metode opisivanja pozadine, radimo statističke testove. U ovome ćemo slučaju koristiti tzv. GoF test (test valjanosti prilagodbe, engl. Goodness of Fit). GoF test je povoljan kada trebamo testirati nul-hipotezu bez da specificiramo alternativnu hipotezu. Dakle, on nam ne govori (nužno) koja se hipoteza bolje slaže od dvije ponuđene, nego koliko se dana hipoteza dobro slaže s podacima. GoF, χ^2, definiran je relacijom

$$\chi^2 = \sum_i \frac{(d_i - f_i)^2}{\sigma_i^2}, \tag{3.11}$$

gdje su d_i i-ti mjereni podaci s devijacijom σ_i, a f_i predviđanje modela. Za normalnu razdiobu, on poprima oblik χ^2 distribucije s n stupnjeva slobode, gdje je n dan razlikom broja razreda u histogramu i broja parametara u prilagodbi.

Postupak testiranja valjanosti procjena GoF testom je dan u nekoliko koraka. Prvo, definiramo model pozadine te ga prilagođavamo na podatke. Zatim, taj model koristimo kao predložak za generiranje N distribucija tzv. pseudopodataka (engl. toy data), pritom uzimajući srednju vrijednost iz procjene modela i pretpostavljajući da je statistička nesigurnost dana Poissonovom distribucijom. U našem slučaju, taj je predložak 2D histogram invarijantne mase triju i para mlazova. Zatim na tih N distribucija pseudopodataka prilagođavamo naš model pozadine te izračunamo GoF za dani set pseudopodataka. Na kraju, iz tih N setova pseudopodataka dobivamo distribuciju rezultata GoF testa te ju uspoređujemo s opaženom vrijednošću u podacima. Tu mjeru obično izražavamo u obliku p-vrijednosti, koja mjeri u koliko slučajeva bi odstupanje bilo veće. Kao graničnu vrijednost za prihvaćenje modela uzimamo p-vrijednost $p = 0.05$; drugim riječima, ako opisanim postupkom dobijemo p-vrijednost veću od 0.05, model ćemo prihvatiti kao valjan. U suprotnom, zaključit ćemo da model nedovoljno dobro opisuje podatke.

Kako bismo odredili koji je stupanj polinoma transfer funkcije najpovoljniji za odabir, koristimo tzv. F-test. F-test je u biti bilo koji statistički test gdje je testna statistika raspodjeljenja po F-distribuciji [10]. F-distribucija s parametrima (d_1, d_2) je dana kao omjer dvaju χ^2 varijabli: $X = \frac{\chi_1/d_1}{\chi_2/d_2}$, gdje su χ_1 i χ_2 nezavisne varijable koje slijede χ^2 distribuciju s d_1 i d_2 stupnjeva slobode. U F-testu koji mi provodimo, dva modela koja mi uspoređujemo imaju razliku u redu polinoma kojeg koristimo u transfer funkciji $R_{P/F}$ čime imaju različiti broj stupnjeva slobode. Osnovni model (model 1) s p_1 parametara je podskup alternativnog

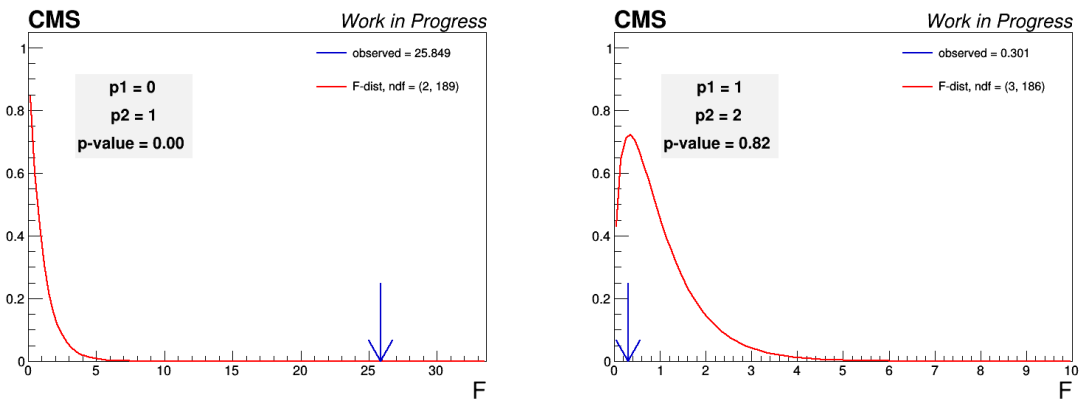

Slika 3.19: Rezultati F-testa za model u kojem su uključene simulacije produkcije top kvarkova za polinome (Lijevo) nultog i prvog stupnja te (Desno) prvog i drugog stupnja.

modela (model 2) s p_2 parametara ($p_1 < p_2$) te zbog toga konstruiramo F-statistiku kao:

$$F = \frac{-2\ln(\lambda_1/\lambda_2)/(p_2 - p_1)}{-2\ln\lambda_2/(n_{razreda} - p_2)}, \tag{3.12}$$

gdje je $n_{razreda}$ broj razreda u histogramu za prilagodbu najvećoj izglednosti, dok su λ_i pripadne vrijednosti izglednosti za model i. I logaritam omjera izglednosti u brojniku i logaritam izglednosti u nazivniku slijede χ^2 raspodjelu. Izraz u brojniku to slijedi po Wilksovom teoremu [39], dok izraz u nazivniku to čini asimptotski. Dakle, ako model 2 ne daje znatno bolji rezultat od modela 1, F će slijediti F-distribuciju s $(p_2 - p_1, n_{razreda} - p_2)$ parametara. Ako se rezultat testa F nalazi u repu te distribucije, gdje je p-vrijednost $p < 0.05$, odbacujemo model 1 i uzimamo model 2 kao novi osnovni model.

Kako bismo potvrdili valjanost modela, koristimo kombinaciju GoF-testa i F-testa. F-testom određujemo koji je najpovoljniji red polinoma za transfer funkcijom. Krećemo od polinoma nultog stupnja, te testiramo daje li nam polinom prvog stupnja bolji rezultat. Ako daje ($p < 0.05$), onda uzimamo polinom prvog stupnja kao osnovni model te testiramo daje li nam polinom drugog stupnja bolji rezultat, i tako dalje. Nakon što pronađemo najpovoljniji red polinoma za transfer funkciju, cjelokupni model testiramo GoF-testom, te ako je model valjan, on će na GoF testu imati p-vrijednost $p > 0.05$. Ako je $p < 0.05$, onda možemo pokušati s polinomom sljedećeg stupnja dok $p > 0.05$ ili moramo nešto drugo izmijeniti u našem modelu.

Za model u kojem smo jedan dio modelirali sa simulacijama produkcije top kvarkova, ispostavlja se da je optimalno korištenje polinoma prvog stupnja. Rezultati F-testa prikazani su na slici 3.19. P-vrijednost testa između nultog i prvog stupnja daje < 0.01, što znači da

polinom prvog stupnja nudi veliko poboljšanje u odnosu na polinom nultog stupnja. Test između prvog i drugog stupnja polinoma, pak, daje $p \approx 0.82$, što znači da daljnje povećanje stupnja polinoma ne nudi znatno poboljšanje modela. GoF test za ovaj model i transfer funkciju oblika polinoma prvog stupnja, prikazan na slici 3.20 daje rezultat p-vrijednosti od 0.11, što je dovoljno da ovaj model smatramo valjanim.

Situacija je bitno različita kada testiramo model koji koristi isključivo podatke. F-test nam sugerira da nam je polinom drugog stupnja optimalan (slika 3.21). No, GoF test za polinom drugog stupnja (slika 3.22) nam daje p-vrijednost od tek 0.01, što nam nije dovoljno da smatramo model valjanim. Čak ni daljnjim povećanjem stupnja polinoma, ne dobiva se dovoljna p-vrijednost od 0.05. Problem bi mogao biti u tome da pozadine za QCD i $t\bar{t}$ procese imaju različite omjere između kategorije prolaza i kategorije pada. Stoga, ukupna transfer funkcija $R_{P/F}$ bi trebala biti nekakva kombinacija transfer funkcija $R^{QCD}_{P/F}$ i $R^{t\bar{t}}_{P/F}$ za pojedine procese. No, čini se da takvu funkciju nije posve lako dobiti prilagodbom. Stoga, u daljnjoj primjeni koristit ćemo model koji u sebi sadrži dio modeliran simulacijama produkcije top kvarkova.

3.3.4 Primjena na signalnu regiju

Nakon što smo se uvjerili da metoda radi u validacijskoj regiji, mogli bismo je primijeniti i u signalnoj regiji. No, za to je potrebno odsljepljivanje (engl. unblinding), što je proces koji zahtjeva rigoroznu provjeru analize kojoj su svi elementi analize gotovi te odobrenje radne grupe CMS kolaboracije koja se bavi sličnim analizama. Taj proces traje relativno

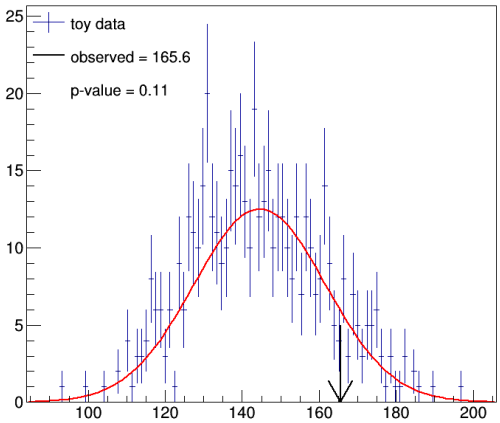

Slika 3.20: GoF test za model u kojem su uključene simulacije produkcije top kvarkova, a transfer funkcija je polinom prvog stupnja.

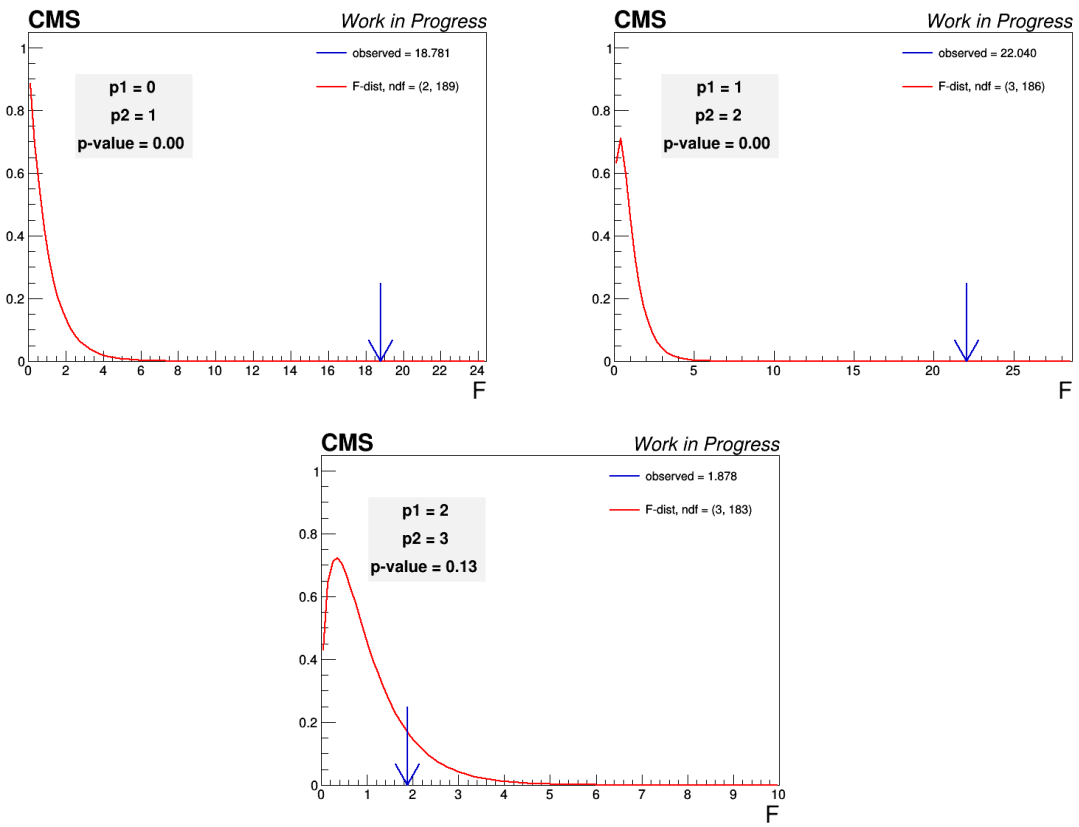

Slika 3.21: Rezultati F-testa za modeliranje samo s podacima za polinome (Gore lijevo) nultog i prvog stupnja, (Gore desno) prvog i drugog stupnja te (Dolje) drugo i trećeg stupnja.

dugo, dulje nego što bismo mogli čekati za pisanje ovog rada i obuhvaća elemente koji nisu predviđeni u sklopu njega. Stoga, ovdje ne možemo dati konkretne rezultate jer ne smijemo koristiti eksperimentalne podatke u ovom području, ali ono što možemo napraviti je dati rezultate koje bismo mogli očekivati na temelju ove analize.

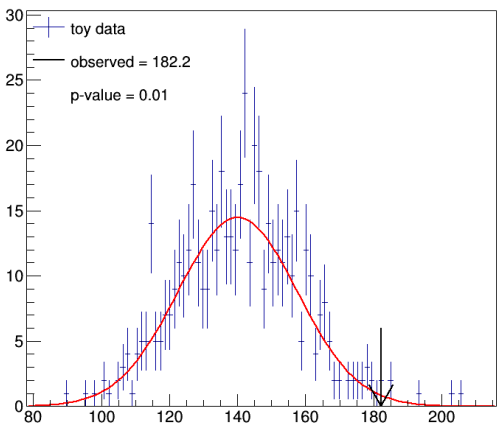

Slika 3.22: GoF test za model koji isključivo koristi podatke, a transfer funkcija je polinom drugog stupnja.

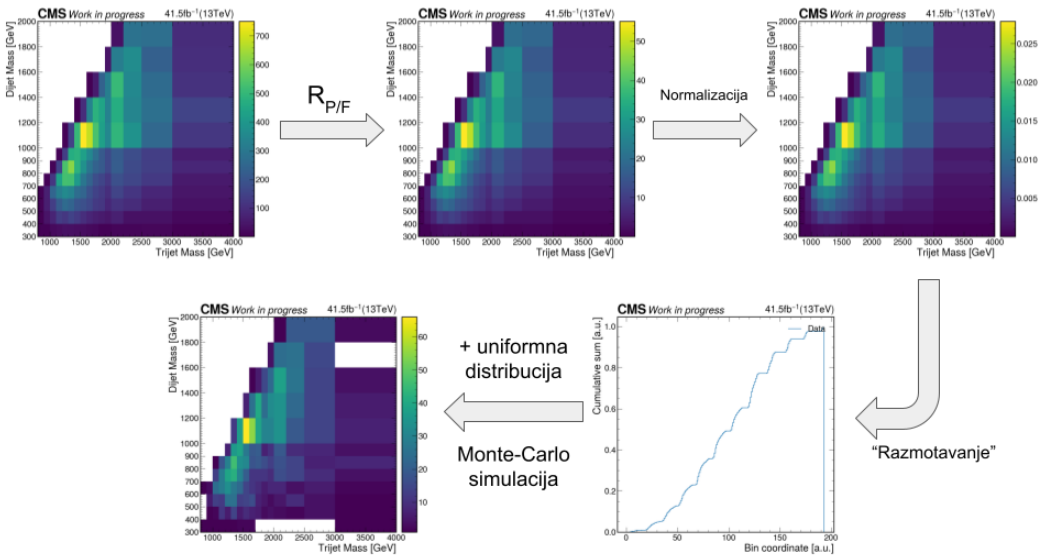

Slika 3.23: Algoritam za simuliranje podataka u kategoriji prolaza signalne regije. Gornji red s lijeva nadesno: 2D histogram distribucije masa triju i para mlazova u kategoriji pada signalne regije, procijenjeni 2D histogram distribucije masa triju i para mlazova u kategoriji prolaza signalne regije te distribucija gustoće vjerojatnosti. Donji red: (lijevo) simulirani 2D histogram distribucije masa triju i para mlazova i (desno) "razmotani" 1D histogram kumulativne sume distribucije gustoće vjerojatnosti.

Iako ne možemo koristiti stvarne eksperimentalne podatke u signalnoj regiji, bar ne iz kategorije prolaza, to ne znači nužno da ne smijemo predvidjeti kako bi oni izgledali u toj kategoriji. Kao što smo vidjeli kod usporedbe oblika pozadine, slične zaključke možemo donijeti o odnosu oblika pozadine između kategorije pada i prolaza i u signalnoj i u validacijskoj regiji. Zbog toga ćemo moći koristiti transfer funkciju koju smo dobili prilagodbom u validacijskoj regiji kako bismo predvidjeli kako bi izgledali podaci u kategoriji prolaza u signalnoj regiji.

Algoritam simuliranja podataka u kategoriji prolaza signalne regije prikazan je na slici 3.23. Krećemo iz 2D histograma invarijante mase triju mlazova i para mlazova dobivenog iz eksperimentalnih podataka u kategoriji pada. Na taj 2D histogram primjenjujemo transfer funkciju $R_{P/F}$ koju smo dobili prilagodbom u validacijskoj regiji. Time smo dobili očekivane vrijednosti histograma u kategoriji prolaza pod pretpostavkom da je transfer funkcija u signalnoj regiji identična onoj u validacijskoj regiji. No, taj histogram ima necjelobrojne vrijednosti pa ga ne možemo izravno koristiti izravno. Umjesto toga, prvo ga normaliziramo i time dobivamo 2D histogram funkcije gustoće vjerojatnosti. Taj histogram "razmotavamo" u 1D histogram na način da idemo red po red u 2D histogramu i svaki razred pridodajemo kumulativnoj sumi koju spremamo u odgovarajući razred u 1D histogramu. Nakon toga, ge-

neriramo N slučajnih realnih brojeva između 0 i 1 koristeći uniformnu distribuciju, gdje je N vrijednost integrala 2D histograma očekivanih vrijednosti u kategoriji prolaza zaokružen na cijeli broj. Iz uniformne distribucije dobivamo rezultat koji povezujemo s koordinatom u 2D histogramu preko "razmotanog" 1D histograma tražeći prvi razred u 1D histogramu koji ima veću vrijednost kumulativne vjerojatnosti od rezultata koji smo dobili iz uniformne distribucije. Radeći to N puta, dobivamo N događaja u simuliranom 2D histogramu koji sada sadrži samo cjelobrojne podatke. Taj histogram možemo koristiti za statističke testove u signalnoj regiji.

Nakon što smo dobili simulirane podatke u signalnoj regiji, možemo na njima ponoviti proces podatkovne procjene pozadine kao što smo i napravili u validacijskoj regiji. Rezultati podatkovne procjene mogu se vidjeti na slikama 3.24 i 3.25. Vidi se da se procjene dobro slaže s podacima, što je potvrđeno F testom i GoF testom (slike 3.26 i 3.27), no to smo i očekivali jer smo naprosto tako definirali podatke u kategoriji prolaza. F-test nam jasno sugerira da je polinom prvog stupnja optimalan izbor za transfer funkciju s rezultatima $p < 0.01$ između polinoma nultog i prvog stupnja te $p = 0.65$ između polinoma prvog i drugog stupnja. GoF test za naš model s transfer funkcijom polinoma prvog stupnja nam, pak, daje p-vrijednost od 0.56 što znači da naš model jako dobro opisuje podatke.

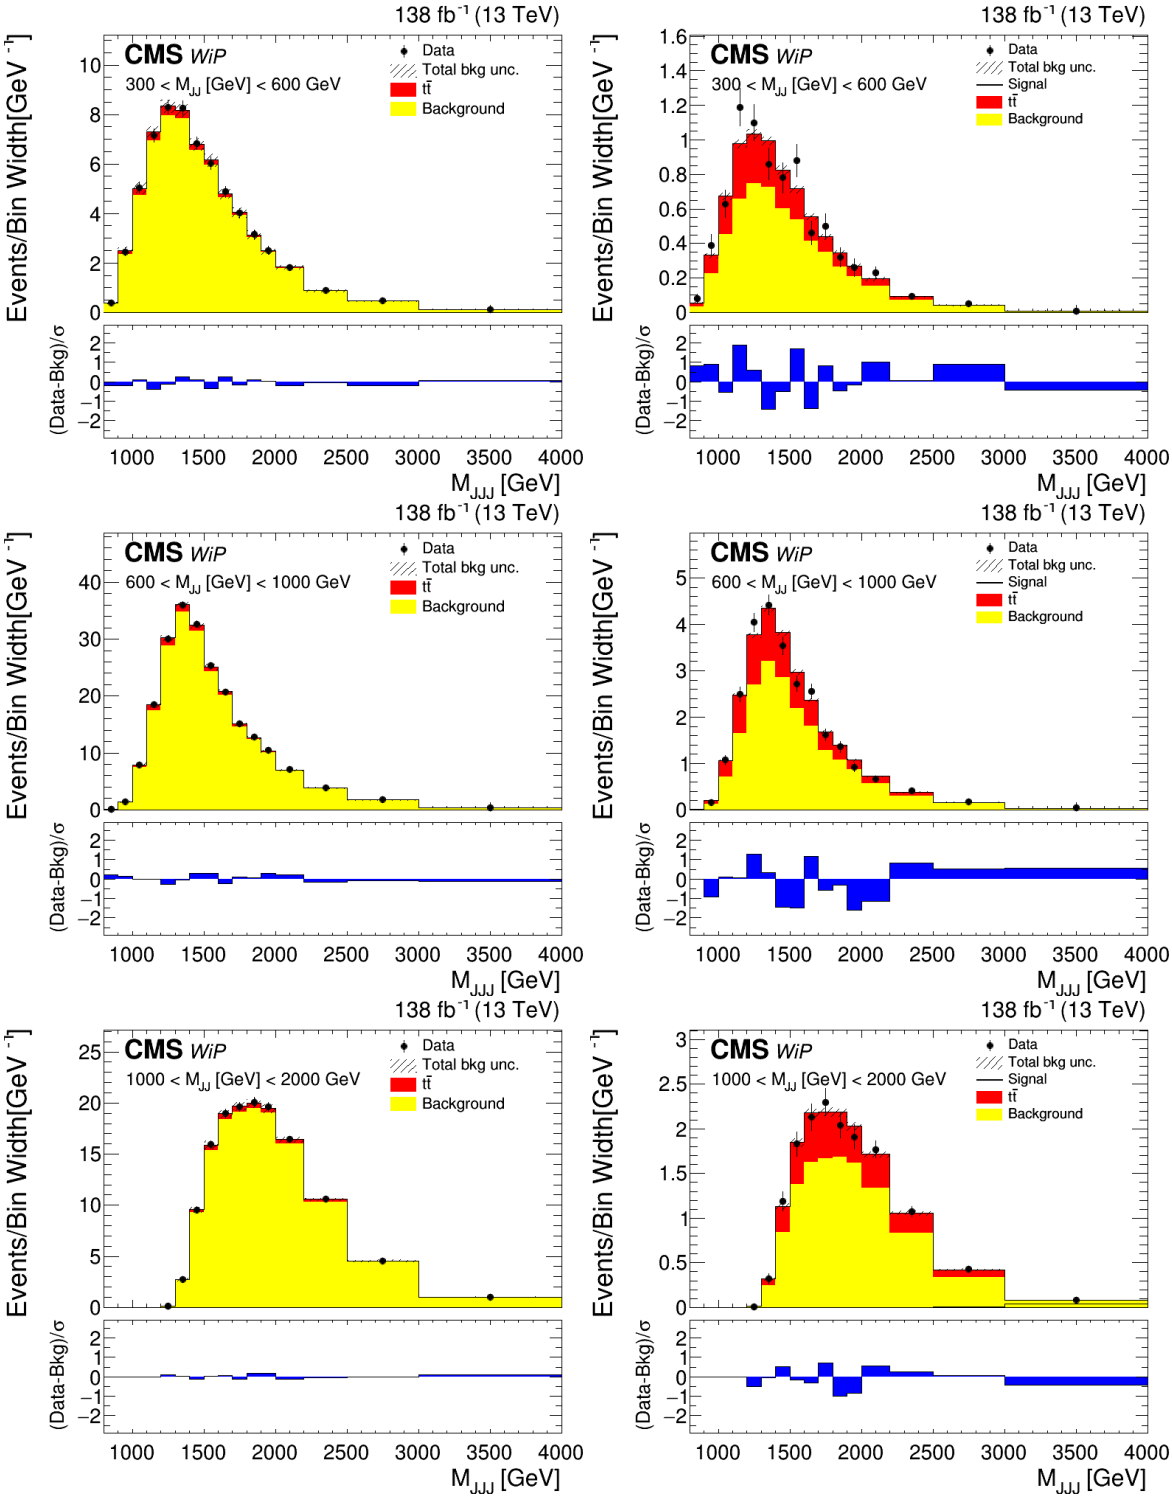

Slika 3.24: Rezultati procjene pozadine modelirane iz podataka i simulacija produkcije $t\bar{t}$ te procijenjenog oblika pozadine u kategoriji prolaza u histogramu mase triju mlazova za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u signalnoj regiji s istim rezovima na masu para mlazova u redu.

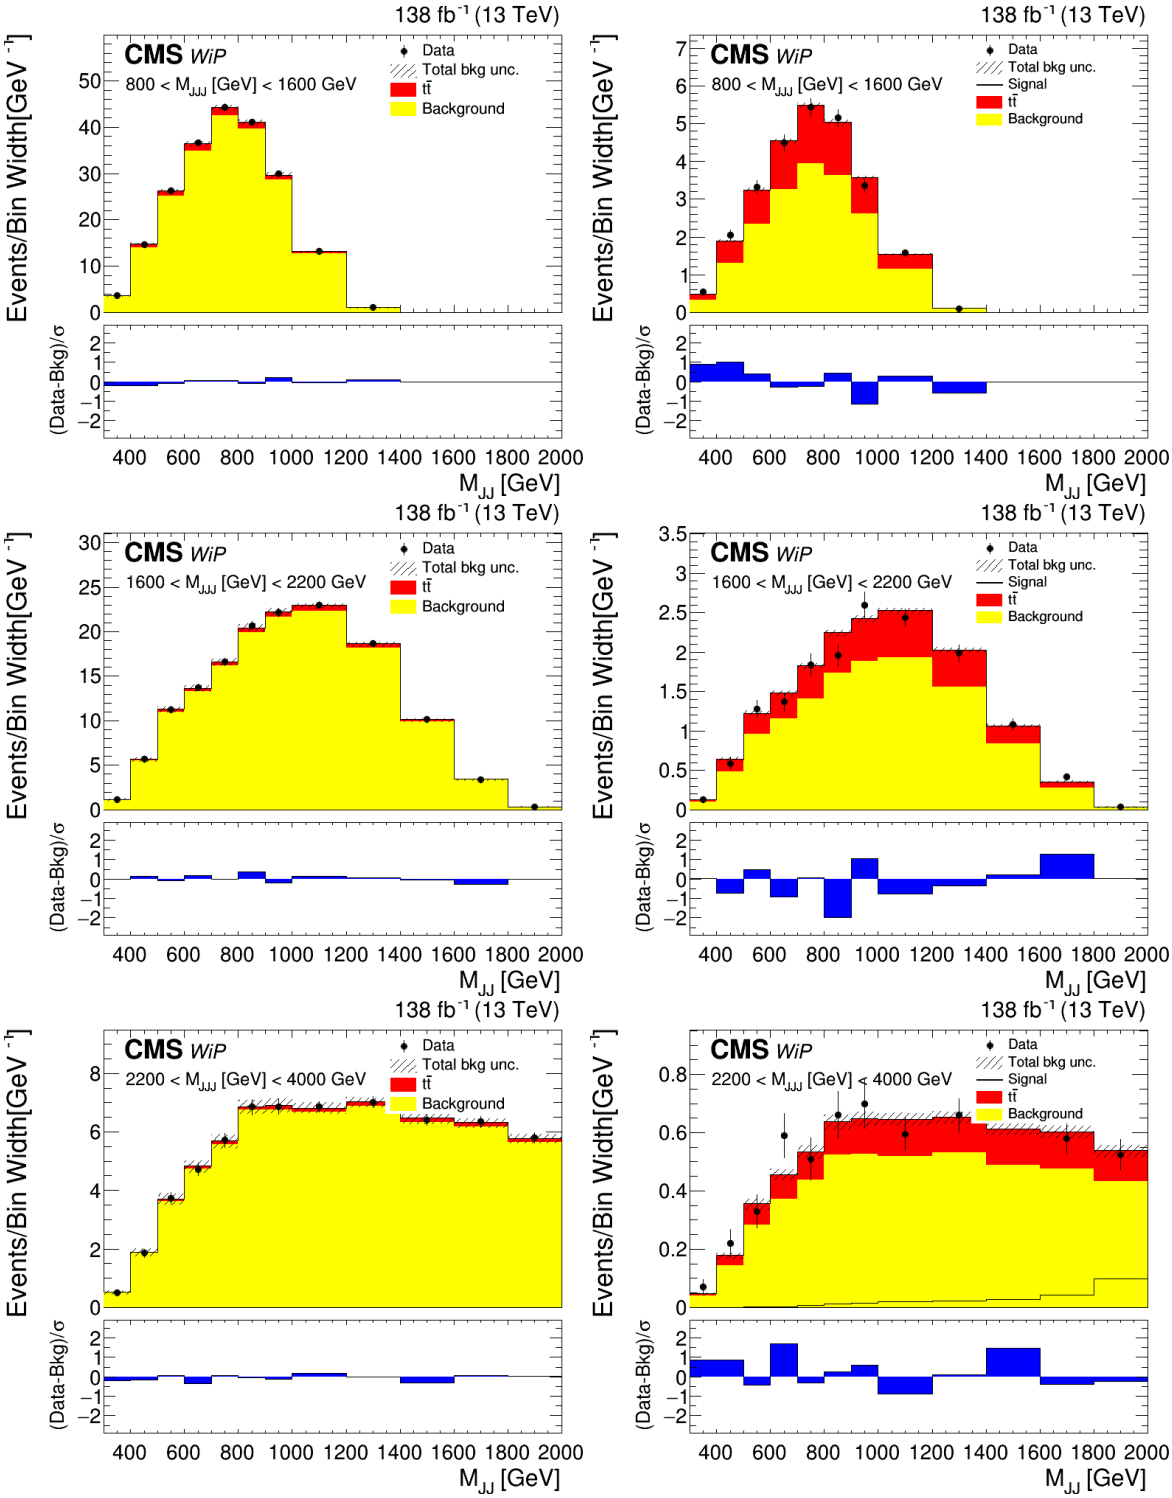

Slika 3.25: Rezultati procjene pozadine modelirane iz podataka i simulacija produkcije $t\bar{t}$ te procijenjenog oblika pozadine u kategoriji prolaza u histogramu mase para mlazova za: (lijevo) kategoriju pada i (desno) kategoriju prolaza u signalnoj regiji s istim rezovima na masu triju mlazova u redu.

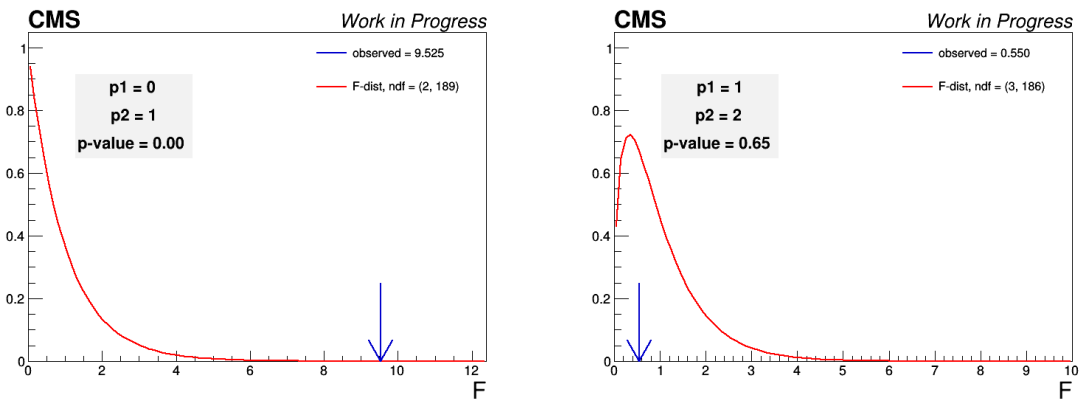

Slika 3.26: Rezultati F-testa za modeliranje pozadine iz pseudopodataka s uključenim $t\bar{t}$ simulacijama za polinome (lijevo) nultog i prvog stupnja i (desno) prvog i drugog stupnja.

3.3.5 Gornji limesi na udarni presjek novih procesa

Koristeći isti postupak kao i u potpotpoglavlju 3.1.2, možemo dobiti gornje granice na udarni presjek signalnog procesa koristeći procjenjenu pozadinu umjesto simulirane. Rezultati tog postupka su dani u tablici 3.2. To možemo pripisati činjenici da je prinos pozadine veći iz podatkovne procjene nego iz simulacija, ali i činjenici da su ovdje sistematske greške nešto više nego što smo procijenili ih u 3.1.2.

Na kraju bi i valjalo pogledati kako očekivane gornje granice ovise o masama čestica X i Y za različite M_X i M_Y. Zbog toga smo odabrali još dodatne tri točke: (M_X, M_Y) = (1100 GeV, 800 GeV), (3500 GeV, 700 GeV) i (3500 GeV, 2000 GeV) te smo ponovili analizu za signalni proces s tim vrijednostima i dali gornje granice na njihove udarne presjeke. Rezultati očekivanih gornjih granica udarnih presjeka tih uzoraka prikazani su u tablici 3.3. U istoj

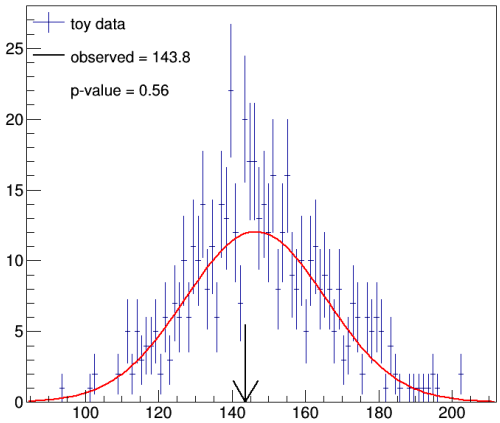

Slika 3.27: GoF test za modeliranje pozadine iz pseudopodataka s uključenim $t\bar{t}$ simulacijama, a transfer funkcija je polinom prvog stupnja.

Tablica 3.2: Očekivane gornje granice na udarni presjek signalnog procesa dobivene pomoću metode procjene pozadine. Gornja je granica dana za područje u kojem je uključen Particle-Net uvjet.

Očekivana vrijednost	Gornja granica na udarni presjek (fb)
-2 std. dev.	$\sigma < 0.81$
-1 std. dev.	$\sigma < 1.08$
Medijan	$\boldsymbol{\sigma < 1.51}$
+1 std. dev.	$\sigma < 2.12$
+2 std. dev.	$\sigma < 2.84$

je tablici prikazana i efikasnost selekcije signala ε_{sig}, koja je definirana kao omjer broja događaja iz uzorka koji prođe našu selekciju i ukupnog broja događaja. Iz tih rezultata možemo izvući jedan važan zaključak, a to je da gornja granica na udarni presjek uvelike ovisi o masama čestica X i Y. Za (M_X, M_Y) = (1100 GeV, 800 GeV), očekivana gornja granica je veća za 2 reda veličine od granica ostalih uzoraka. Postoje dva razloga zašto je to tako - prvi je da je pozadina veća oko mase tog uzorka, a drugi, i bitniji, je da taj uzorak rijetko proizvede tri debela mlaza. Naime, moguće je da jedan od produciranih Higgsovih bozona nema dovoljan impuls za raspad koji bi rezultirao kolimiranim mlazovima. Stoga naša selekcija događaja ima nisku efikasnost za ovaj signal. Ostali uzorci rezultiraju sličnim rezultatom od oko 1 fb - kod njih se gotovo uvijek produciraju 3 debela mlaza. Razlika između njih je što imaju različite prinose pozadine oko područja u kojima se nalazi vrh njihovog raspada u histogramu mase tri i dva mlaza, kao i različite efikasnosti selekcije signala koja uvelike ovisi o masama. Koliko ćemo moći ograničiti gornju granicu udarnog presjeka signalnog procesa ovisi o kombinaciji količini prinosa pozadine i efikasnost naše selekcije za signalni proces. Što je niži prinos pozadine, a efikasnost selekcije veća, to je niža očekivana gornja granica.

Tablica 3.3: Efikasnosti signala ε_{sig} za našu selekciju i medijalne očekivane gornje granice na udarni presjek signalnog procesa dobivene pomoću metode procjene pozadine za različite mase X i Y.

(M_X, M_Y)	ε_{sig}	Gornja granica na udarni presjek s nivoom pouzdanosti od 95% (fb)
(1100 GeV, 800 GeV)	0.3%	$\sigma < 161$
(2000 GeV, 1100 GeV)	11.8%	$\sigma < 1.51$
(3500 GeV, 700 GeV)	6.3%	$\sigma < 1.19$
(3500 GeV, 2000 GeV)	20.1%	$\sigma < 0.42$

4 Zaključak

U ovome smo radu predstavili potragu za rezonantnim raspadom dvije nove skalarne čestice X i Y u Higgsovom sektoru standardnog modela. Raspade smo tražili u kinematičkom režimu u kojem su čestice X i Y dovoljno masivne da 3 producirana Higgsova bozona posjeduju relativno velik impuls koji je dovoljan da parovi mlazova, nastalih iz raspada svakog od Higgsovih bozona, budu kolimirani. U potrazi smo prvo koristili uzorke dobivene iz Monte Carlo simulacija te eksperimentalno mjerene podatke. Kod usporedbe uzoraka iz simulacija s eksperimentalno mjerenim podacima, postojalo je relativno veliko neslaganje bez obzira na našu selekciju što smo pripisali lošem modeliranju jednom od ključnih procesa koji doprinose pozadini - QCD procesa. Zbog toga smo se odlučili na alternativnu analizu koja je koristila podatkovnu procjenu pozadine. Pri podatkovnoj smo procjeni pozadine objasnili nekoliko metoda te koristili metodu koja je vrlo slična 2DAbecednoj metodi. Proveli smo metodu za dva različita modela: model u kojem smo koristili samo podatke te model u kojem smo koristili simulacije produkcije para top kvarkova. Pomoću statističkih testova - F-testa i GoF testa - zaključili smo da je potonji model bolji te da je optimalan oblik transfer funkcije polinom prvog stupnja u 2D prostoru. Nakon što smo proveli i potvrdili valjanost našeg modela u validacijskoj regiji, generirali smo pseudopodatke u signalnoj regiji te proveli metodu podatkovne procjene pozadine i tamo. Na kraju smo dali očekivane gornje granice na dopuštene udarne presjeke koji bi signalni proces mogao imati u slučaju da ne opazimo signal. Taj rezultat smo dali i na temelju podatkovne procjene pozadina i na temelju Monte Carlo simulacija. Za (M_X, M_Y) = (2000 GeV, 1100 GeV) dobili smo da nam obje metode daju slične rezultate reda veličine 1 fb, s tim da na temelju podatkovne procjene pozadine dobivamo malo veću gornju granicu za udarni presjek. Također, pogledali smo i kako se taj rezultat mijenja za različite vrijednosti masa čestica X i Y i zaključili da naša analiza nije osjeljiva na relativno niske mase tih čestica koje ne produciraju 3 debela mlaza što je i očekivano. Da bismo povećali osjetljivost trebali bismo definirati nove kategorije događaja u kojima ne moraju svi mlazovi biti debeli, nego može postojati kombinacija običnih i debelih mlazova. U područjima u kojima se većinom produciraju 3 debela mlaza, gornje granice udarnog presjeka su reda veličine 1 fb, te ovise o kombinaciji prinosa pozadine u području rezonantnog vrha na signal i efikasnosti naše selekcije na signal.

Literatura

[1] Standard Model of Elementary Particles, (17.9.2019), Wikimedia Commons, https://commons.wikimedia.org/wiki/File:Standard_Model_of_Elementary_Particles.svg, 22.5.2023.

[2] Gross, D. J.; Wilczek, F. Ultraviolet Behavior of Non-Abelian Gauge Theories. // Phys. Rev. Lett. Vol. 30(1973), str. 1343–1346.

[3] Politzer, H. D. Reliable Perturbative Results for Strong Interactions? // Phys. Rev. Lett. Vol. 30(1973), str. 1346–1349.

[4] Thomson, M. Modern particle physics. New York : Cambridge University Press, 2013

[5] Workman, R. L. i dr. Review of Particle Physics. // Progress of Theoretical and Experimental Physics. Vol. 2022(2022), str. 083C01.

[6] Glashow, S. L. Partial Symmetries of Weak Interactions. // Nucl. Phys. Vol. 22(1961), str. 579–588.

[7] Weinberg, S. A Model of Leptons. // Phys. Rev. Lett. Vol. 19(1967), str. 1264–1266.

[8] Englert, F.; Brout, R. Broken Symmetry and the Mass of Gauge Vector Mesons. // Phys. Rev. Lett. Vol. 13(1964), str. 321–323.

[9] Higgs, P. W. Broken Symmetries and the Masses of Gauge Bosons. // Phys. Rev. Lett. Vol. 13(1964), str. 508–509.

[10] Roguljić, M. Search for new scalar resonances using proton-proton collisions recorded by the CMS experiment at the Large Hadron Collider. Doktorski rad. Prirodoslovno-matematički fakultet, Sveučilište u Zagrebu, 2022.

[11] Measurement of matter-antimatter differences in beauty baryon decays. // Nature Physics. Vol. 13, 4(2017), str. 391–396.

[12] Robens, T.; Stefaniak, T.; Wittbrodt, J. Two-real-scalar-singlet extension of the SM: LHC phenomenology and benchmark scenarios. // The European Physical Journal C. Vol. 80, 2(2020).

[13] Papaefstathiou, A.; Robens, T.; Tetlalmatzi-Xolocotzi, G. Triple Higgs boson production at the Large Hadron Collider with Two Real Singlet scalars. // Journal of High Energy Physics. Vol. 2021, 5(2021).

[14] Maltoni, F.; Vryonidou, E.; Zaro, M. Top-quark mass effects in double and triple Higgs production in gluon-gluon fusion at NLO. // Journal of High Energy Physics. Vol. 2014, 11(2014).

[15] Florian, D. de; Mazzitelli, J. Two-loop corrections to the triple Higgs boson production cross section. // Journal of High Energy Physics. Vol. 2017, 2(2017).

[16] Evans, L.; Bryant, P. LHC Machine. // Journal of Instrumentation. Vol. 3, 08(2008), str. S08001.

[17] Boyd, J. T. LHC Run-2 and Future Prospects. 13.1.2020. arXiv: 2001.04370 [hep-ex].

[18] Benedikt, M. i dr. LHC Design Report. Geneva : CERN, 2004

[19] Radiofrequency Cavities, (17.9.2012), CERN Document Server, https://cds.cern.ch/record/1997424, 10.6.2023.

[20] The CERN Accelerator Complex, (16.10.2019), Vanden Broeck, R., https://cds.cern.ch/record/2693837, 7.6.2023.

[21] Chatrchyan, S. i dr. The CMS experiment at the CERN LHC. // Journal of Instrumentation. Vol. 3, 08(2008), str. S08004.

[22] Adam, W. i dr. The CMS Phase-1 pixel detector upgrade. // Journal of Instrumentation. Vol. 16, 02(2021), str. P02027.

[23] Leo, W. R. Techniques for nuclear and particle physics experiments: a how-to approach; 2nd ed. Berlin : Springer, 1994

[24] CMS Detector Slice, (12.1.2016), CERN Document Server, http://cds.cern.ch/record/2120661, 16.5.2023.

[25] Tumasyan, A. i dr. Strategies and performance of the CMS silicon tracker alignment during LHC Run 2. // Nucl. Instrum. Meth. A. Vol. 1037(2022), str. 166795.

[26] Sirunyan, A. M. i dr. Performance of the CMS muon detector and muon reconstruction with proton-proton collisions at $\sqrt{s} = 13$ TeV. // Journal of Instrumentation. Vol. 13, 10(2018), str. P06015.

[27] Sirunyan, A. M. i dr. Electron and photon reconstruction and identification with the CMS experiment at the CERN LHC. // Journal of Instrumentation. Vol. 16(2021), str. P05014.

[28] Khachatryan, V. i dr. Jet energy scale and resolution in the CMS experiment in pp collisions at 8 TeV. // Journal of Instrumentation. Vol. 12, 02(2017), str. P02014.

[29] Sirunyan, A. M. i dr. Particle-flow reconstruction and global event description with the CMS detector. // Journal of Instrumentation. Vol. 12(2017), str. P10003.

[30] CMS coordinate system, (2.12.2022), TikZ.net, `https://tikz.net/axis3d_cms/`, 5.6.2023.

[31] Cacciari, M.; Salam, G. P.; Soyez, G. The anti-ik/isubit/i/subjet clustering algorithm. // Journal of High Energy Physics. Vol. 2008, 04(2008), str. 063.

[32] Soyez, G. The SISCone and anti-kt jet algorithms. 30.6.2008. arXiv: `0807.0021 [hep-ph]`.

[33] Larkoski, A. J. i dr. Soft drop. // Journal of High Energy Physics. Vol. 2014, 5(2014).

[34] Roguljić, M. Razvoj algoritma za identifikaciju hadronskih mlazova nastalih raspadom ultrarelativističkih Higgsovih bozona u dva b kvarka. Diplomski rad. Prirodoslovno-matematički fakultet, Sveučilište u Zagrebu, 2017.

[35] Qu, H.; Gouskos, L. Jet tagging via particle clouds. // Physical Review D. Vol. 101, 5(2020).

[36] The CMS collaboration. Identification of b-quark jets with the CMS experiment. // Journal of Instrumentation. Vol. 8, 04(2013), str. P04013.

[37] The ATLAS collaboration; The CMS collaboration. Procedure for the LHC Higgs boson search combination in Summer 2011. 16.8.2011.

[38] Corcodilos, L. The 2D Alphabet background modeling method and its use in the search for an excited bottom quark. Doktorski rad. Johns Hopkins University, 2021.

[39] Wilks, S. S. The Large-Sample Distribution of the Likelihood Ratio for Testing Composite Hypotheses. // Annals Math. Statist. Vol. 9, 1(1938), str. 60–62.