

## SIMULASI KARAKTERISASI INTERAKSI WIMP-QUARKS DI LHC DENGAN MENGGUNAKAN DEEP LEARNING

Reinard Primulando<sup>1\*</sup>

<sup>1</sup>Pusat Studi Fisika Teori, Program Studi Fisika, Fakultas Teknologi Informasi dan Sains, Universitas Katolik Parahyangan, Jl. Ciumbuleuit 94 Bandung

\*E-mail: [rprimulando@unpar.ac.id](mailto:rprimulando@unpar.ac.id)

### ABSTRAK

Materi gelap merupakan salah satu komponen terbesar dari isi alam semesta yang kita tidak ketahui interaksinya. Large Hadron Collider (LHC) merupakan laboratorium yang dapat digunakan untuk mencari materi gelap terutama dalam bentuk Weakly Interacting Massive Particles (WIMP). Untuk mencari sifat interaksi dari materi gelap, jika ditemukan pada LHC, maka channel sepasang lepton dan missing energy dapat digunakan. Penelitian ini dilakukan untuk mencari cara untuk membedakan interaksi dari WIMP dengan menggunakan deep feedforward networks. Dengan cara ini didapat akurasi 62,41% dalam membedakan jenis interaksi V+A dan V-A.

**Kata kunci:** Materi gelap, WIMP, LHC, deep learning

### 1. PENDAHULUAN

Materi gelap merupakan materi yang menyusun 23% dari komponen alam semesta. Bukti dari materi gelap selama ini hanya didapat dari interaksi gravitasi dari materi gelap dengan materi normal (Zyla, P.A. et al. 2020). Namun dari berbagai model fisis yang ada, terdapat motivasi yang kuat untuk materi gelap berinteraksi dengan gaya lain selain gaya gravitasi. Salah satu model fisis yang sangat populer dikenal dengan nama *Weakly Interacting Massive Particle* (WIMP). Partikel WIMP memiliki massa dalam orde sekitar 1 GeV hingga 1 TeV dan memiliki interaksi yang cukup signifikan dengan materi normal sehingga dapat dicari pada penumbuk partikel (Arcadi, G. et.al. 2018).

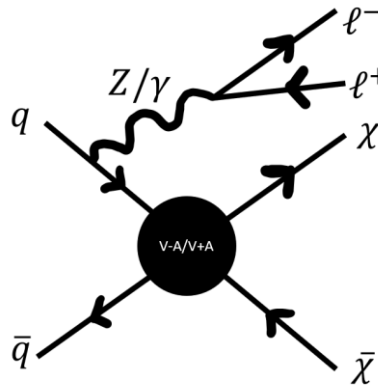
Untuk mengetahui sinyal dari WIMP di penumbuk partikel, diperlukan asumsi mengenai interaksi antara partikel dengan materi model standar yang ada di sekitar kita. Jika kita ingin melihat sinyal WIMP pada *Large Hadron Collider* (LHC), maka interaksi yang paling relevan adalah interaksi antara WIMP dengan quarks atau gluon. Sinyal yang dengan jumlah *event* yang diprediksi paling besar adalah sinyal yang terdiri dari jet berenergi sangat tinggi yang disertai oleh energi yang hilang (*missing energy / MET*). Sinyal ini dikenal dengan istilah monojet (Fox, P.J., et.al., 2012). Saat ini pencarian WIMP dengan sinyal monojet sedang dilakukan pada berbagai eksperimen di LHC seperti CMS (Sirunyan, A.M, et. al. 2018) dan ATLAS (Aaboud, M., et al. 2018).

Apabila di masa depan WIMP ditemukan di LHC, maka tugas selanjutnya adalah mengkarakterisasi interaksi antara WIMP dan materi model standar. Penelitian ini memfokuskan untuk membedakan antara dua tipe interaksi efektif WIMP yang akan disebut dengan V-A dan V+A:

$$\frac{\bar{q}\gamma^\mu(1-\gamma^5)q\bar{\chi}\gamma^\mu\chi}{\Lambda^4} \quad (V-A) \quad (1)$$

$$\frac{\bar{q}\gamma^\mu(1+\gamma^5)q\bar{\chi}\gamma^\mu\chi}{\Lambda^4} \quad (V+A) \quad (2)$$

Dengan  $q$  adalah quarks,  $\chi$  adalah WIMP,  $\gamma$  adalah matriks gamma dan  $\Lambda$  adalah skala efektif yang menentukan kuat dari interaksi. Interaksi tersebut menentukan jenis interaksi spin antara WIMP dan materi model standar. Kedua interaksi di atas sama-sama menghasilkan sinyal monojet, namun secara fundamental interaksi keduanya berbeda. Sinyal monojet tidak dapat membedakan antara kedua jenis interaksi tersebut. Karenanya untuk mengetahui interaksi sebenarnya, diperlukan sinyal lain yang walaupun jumlah *events* yang diamati akan lebih kecil, namun dapat membedakan jenis spin dari model ini. Interaksi antara quarks dan  $Z$  serta quarks dan foton memiliki jenis interaksi yang juga bergantung pada struktur spin. Baik  $Z$  maupun foton dapat berubah menjadi sepasang lepton dan antilepton di LHC. Lepton lebih mudah untuk dideteksi di LHC sehingga dapat diusulkan sinyal sepasang lepton dan *missing energy* untuk membedakan antara kedua interaksi di atas. Diagram Feynman yang mendeskripsikan fenomena di atas dapat dilihat pada Gambar 1.



**Gambar 1.** Diagram Feynman yang digunakan dalam makalah ini.

Pada umumnya, metoda yang dipakai untuk membedakan antara dua buah interaksi adalah metoda *cut and count*. Dalam metoda ini, diambil batasan tertentu pada beberapa parameter yang teramati. Dari batasan tersebut, didapat area atau volume yang memiliki jumlah *events* yang cukup banyak untuk suatu jenis interaksi tertentu. Metoda *cut and count* telah cukup umum dipakai dalam berbagai penelitian fisika partikel, seperti untuk membedakan sinyal dan *backgrounds* pada monojet di eksperimen CMS (Sirunyan, A.M, et. al. 2018) dan ATLAS (Aaboud, M., et al. 2018).

Kelemahan dari metoda *cut and count* adalah area atau volume yang ditentukan umumnya terbatas dalam bentuk persegi *n*-dimensi. Bentuk lain, misalnya bola, sebetulnya dapat juga diakomodasi oleh metoda *cut and count*. Namun pada umumnya *event* tidak tersebar dalam bentuk-bentuk yang teratur yang dapat dibuat persamaan matematikanya dengan mudah. Hal ini terjadi karena sifat non-linear dari amplitudo hamburan. Bahkan integrasi dari *phase space* tidak dapat dilakukan secara analitik dan harus bergantung kepada simulasi numerik. Karenanya, *deep learning* merupakan salah satu solusi yang dapat digunakan untuk membedakan kedua jenis interaksi tersebut.

Penggunaan *deep learning* dalam fisika partikel bukanlah hal yang baru. Fisikawan eksperimen telah menggunakannya misalkan dalam identifikasi partikel (Belayneh, D. et.al. 2020). Contoh penggunaan *deep learning* untuk membedakan antara sinyal supersimetri dengan *backgrounds* telah dibahas oleh Baldi, P. et. al. (2014). Review mengenai penggunaan *deep learning* pada fisika partikel dapat dilihat pada karya Guest, D. et.al. (2018).

Dalam penelitian ini, *deep learning* akan digunakan untuk membedakan dua jenis interaksi yang terdapat dalam persamaan (1) dan (2). Setelah ditunjukkan bahwa metoda *deep learning* dapat digunakan untuk membedakan kedua jenis interaksi tersebut, akan dibahas bagaimana menginterpretasikan lebih jauh hasil dari *deep learning* tersebut agar didapat gambaran awal dari intuisi fisis yang dapat membedakan kedua interaksi tersebut.

## 2. METODE

### 2.1 Event Generation

Simulasi dari *event* LHC dilakukan dengan menggunakan Madgraph 5 (Alwall J., et.al. 2014). Hanya sinyal yang digunakan sebagai input pada penelitian ini. Selain itu efek dari *final state radiations* dan detektor tidak akan disimulasikan pada penelitian ini. Kedua efek di atas tidak akan mengubah hasil penelitian ini secara kualitatif. Untuk membuat model MadGraph 5 digunakan FeynRules 2.0 (Alloul, A., et.al. 2014). Pada Tabel 1 ditunjukkan parameter beserta *cuts* yang digunakan dalam simulasi ini. Untuk masing-masing tipe interaksi, disimulasikan 100000 events. Kemudian data dibagi menjadi menjadi *train set* sebanyak 67% dan *validation set* sebanyak 33%.

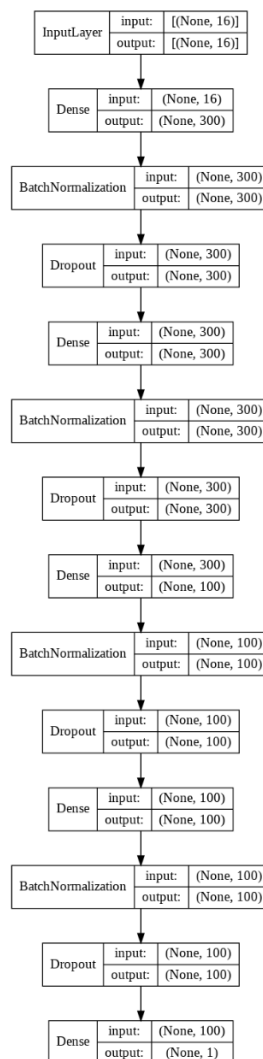
### 2.2 Model Deep Learning

Model *deep learning* yang dipakai dalam penelitian ini adalah *deep feedforward networks* (DFN) yang dirangkum pada Gambar 2. Model ini terinspirasi dari model pada karya Baldi, P. et. al. (2014). Model yang dipakai diimplementasikan di Keras dengan TensorFlow sebagai *backend*. Parameter yang menjadi input bagi model tersebut adalah  $p_T, \eta, \phi$  dan  $m$  dari masing-masing lepton dan antilepton,  $p_T, \eta, \phi$  dan  $m$  dari jumlah

momentum lepton dan anti lepton,  $\Delta\phi$  dari lepton dan anti lepton, lepton dan *missing energy* serta anti lepton dan *missing energy*,  $\Delta R$  dari lepton dan anti lepton sehingga total input adalah 16 parameter.

**Tabel 1.** Parameter yang digunakan dalam penelitian ini


Parameter	Nilai
$\sqrt{s}$	14 TeV
$m_\chi$	10 GeV
$\Lambda$	20 TeV
$p_T^l$	> 10 GeV
$ \eta^l $	< 2,5
(MET)	> 500 GeV



**Gambar 2.** Model *Deep Learning* yang digunakan dalam penelitian ini

Parameter input tersebut akan melewati DFN dengan *hidden layers* terdiri atas 4 *layers* yang terdiri atas 300, 300, 100 dan 100 neurons. Fungsi aktivasi dari masing-masing *layer* tersebut adalah ReLu. *Batch normalization* dilakukan pada masing-masing output *hidden layer*. Regularisasi *Dropout* dengan *rate* 50% juga dilakukan pada setiap koneksi penghubung *hidden layer*. Karena dalam kasus ini ada dua kelas (*V-A* dan *V+A*) yang diklasifikasikan, maka hanya terdapat sebuah *layer* output dengan fungsi aktivasi sigmoid dan fungsi *loss* yang digunakan adalah *binary crossentropy*.

Training dari DFN dilakukan dengan menggunakan *optimizer* Adam. Training akan berhenti jika telah didapatkan akurasi yang maksimum dengan *patience* sebanyak 10 epoch. Didapatkan bahwa jumlah *epoch* yang harus dijalankan sebanyak 34 *epoch*. Hasil dari *loss* dan akurasi sebagai fungsi dari *epoch* dapat dilihat pada Gambar 3.



**Gambar 3.** Nilai dari *loss* dan akurasi yang didapat sebagai fungsi dari *epoch*.


### 2.3 SHAP

Untuk lebih mengerti parameter apakah yang memiliki peran paling besar dalam membedakan kedua skenario interaksi, dapat digunakan metoda SHAP (SHapley Additive exPlanations) yang diusulkan oleh Lundberg S. dan Lee S.I. (2017). Metoda SHAP diusulkan untuk membantu menginterpretasikan hasil dari pembelajaran mesin. Nilai SHAP dari sebuah *feature* dihitung berdasarkan perbedaan antara nilai rata-rata jika *feature* tersebut ada atau tidak. Nilai rata-rata dari kasus ketika nilai *feature* tersebut tidak ada dipilih dari distribusi latar yang diatur di awal. Semakin besar absolut dari nilai SHAP, maka semakin besar pengaruh dari *feature* tersebut.

Implementasi dari metoda SHAP dapat dilakukan dengan menggunakan *package* yang telah disediakan pada laman <https://github.com/slundberg/shap>. Dalam implementasi tersebut, kita dapat memilih nilai distribusi latar yang kita inginkan. Dalam hal ini dipilih 200 nilai pertama dari data training sebagai nilai distribusi latar. Sedangkan untuk perhitungan nilai SHAP, dipakai 200 nilai pertama dari data validasi.

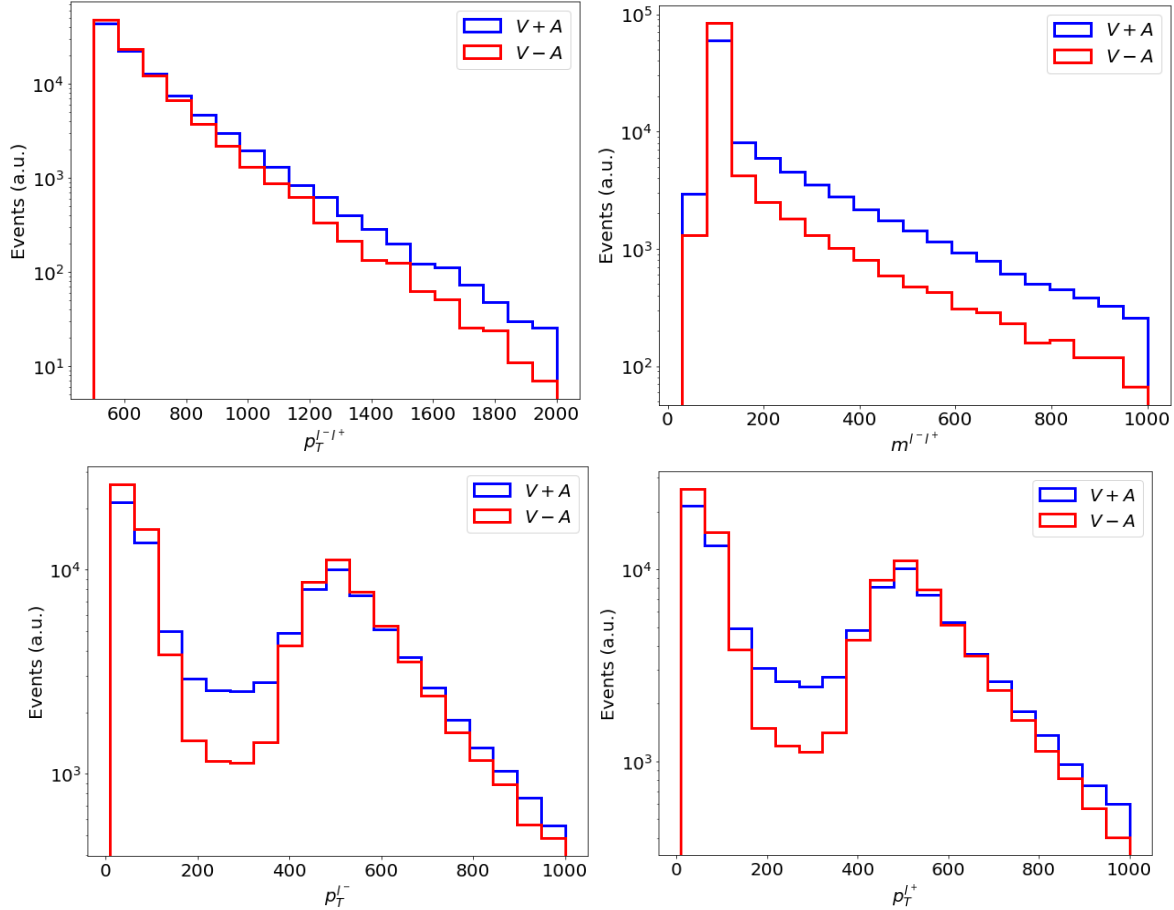
### 3. HASIL DAN PEMBAHASAN

Dari perhitungan DFN didapatkan bahwa akurasi maksimum yang didapatkan adalah 62,41%. Hasil ini lebih baik dibandingkan dengan tebakan acak yang menghasilkan akurasi 50% saja. Hal ini menunjukkan bahwa ada fenomena fisis yang bertanggung jawab dalam membedakan interaksi V-A dan V+A. Untuk mendapatkan petunjuk mengenai fenomena fisis apa yang berpengaruh, digunakan metoda SHAP untuk menghitung kontribusi dari parameter input. Hasil dari perhitungan dengan menggunakan metoda SHAP ditampilkan pada Gambar 4.



**Gambar 4.** *Output* dari metoda SHAP.

Dari Gambar 4, didapat bahwa ada empat buah parameter yang sangat berpengaruh untuk membedakan interaksi  $V+A$  dan  $V-A$ . Empat buah parameter tersebut adalah  $p_T$  dari lepton dan antilepton, kemudian massa invariant dari pasangan lepton dan antilepton serta  $p_T$  dari pasangan lepton dan antilepton. Grafik distribusi dari keempat parameter tersebut diberikan pada Gambar 5.



**Gambar 5.** Distribusi kinematik dari parameter yang paling penting menurut metoda SHAP.

Dari distribusi tersebut terlihat perbedaan antara kasus  $V+A$  dan  $V-A$ . Tampak dari distribusi massa invariant ( $m^{l+l+}$ ), event dari  $V-A$  lebih terkonsentrasi pada sekitar massa dari  $Z$  boson. Dapat disimpulkan bahwa struktur interaksi  $V-A$  membuat  $Z$  boson menjadi lebih mudah diproduksi daripada  $V+A$ . Untuk  $V+A$  produksi melalui foton memiliki jumlah *events* yang lebih besar. Hal ini juga didukung oleh  $p_T$  dari pasangan lepton dan antilepton yang lebih besar pada kasus  $V+A$ . Foton lebih ringan dibandingkan dengan  $Z$  sehingga dapat memiliki momentum yang lebih besar dibandingkan dengan  $Z$ . Karenanya dapat dimengerti bahwa pasangan lepton dan antilepton memiliki momentum yang lebih besar pada kasus  $V+A$ . Pengambilan kesimpulan ini harus diinvestigasi lebih lanjut dengan cara lain misalnya dengan menghitung rasio antara channel monofoton dan mono- $Z$  dari kedua interaksi ini.

Distribusi  $p_T$  dari lepton ataupun antilepton terlihat mirip. Hal ini terjadi karena interaksi yang kita perhitungkan dalam penelitian ini masih menjaga simetri CP agar kekal. Hal yang menarik adalah penampakan dua puncak pada distribusi tersebut. Puncak yang berada di nilai  $p_T$  yang rendah terjadi karena momentum yang rendah memiliki *phase space* yang lebih besar sehingga cukup banyak lepton ataupun antilepton yang menempati momentum tersebut. Puncak tersebut terjadi persis pada *cut* dari  $p_T$  lepton dan antilepton yang tercantum pada Tabel 1. Puncak kedua terjadi di sekitar  $p_T \sim 500$  GeV karena cukup banyak *events* yang terjadi akibat peluruhan  $Z$  boson yang dapat dilihat pada distribusi massa invariant dari lepton dan antilepton.  $Z$  boson yang tercipta pada umumnya memiliki  $p_T \sim 500$  GeV untuk mengimbangi WIMP yang tercipta dan terdeteksi dalam bentuk *missing energy*. *Cut* yang diberikan atas *missing energy* adalah 500 GeV, sehingga menurut

hukum kekekalan momentum,  $p_T$  dari  $Z$  boson haruslah setidaknya 500 GeV. Dari plot terlihat bahwa dalam puncak distribusi  $V-A$  pada  $p_T \sim 500$  GeV terlihat lebih tinggi dibandingkan  $V+A$ . Hal ini dapat ditafsirkan bahwa  $Z$  boson lebih banyak tercipta jika interaksi antara WIMP dan quarks berbentuk  $V-A$ . Seperti dalam hal sebelumnya, konfirmasi dari tafsir ini dapat diinvestigasi dengan menghitung rasio antara channel monofoton dan mono- $Z$  atau dengan menghitung amplitudo hamburan secara analitik.

#### 4. KESIMPULAN

Dalam penelitian ini telah dibuat sebuah model DFN yang dapat membedakan jenis interaksi antara WIMP dan *quarks*. Jenis interaksi yang dibedakan dalam penelitian ini adalah jenis  $V+A$  dan  $V-A$ . DFN dapat membedakan hingga akurasi 62,41%. Hasil ini kemudian dicoba lebih didalami dengan menggunakan metoda SHAP. Didapat bahwa parameter yang berpengaruh untuk membedakan kedua jenis interaksi tersebut adalah  $p_T$  dari lepton dan antilepton, kemudian massa invariant dari pasangan lepton dan antilepton serta  $p_T$  dari pasangan lepton dan antilepton. Pembahasan awal mengenai alasan fisis pentingnya keempat parameter tersebut telah dibahas. Diduga perbedaan tersebut terjadi karena  $Z$ -boson tercipta lebih banyak dalam kasus  $V-A$  dibandingkan dengan kasus  $V+A$ . Dugaan ini memerlukan konfirmasi lebih jauh dalam penelitian lainnya. Jika ingin diperdalam maka amplitudo penuh dari hamburan ini sebaiknya dihitung dengan lebih tepat. Dalam penelitian selanjutnya dapat juga dibandingkan jenis-jenis interaksi lainnya, terutama dalam bentuk  $\frac{\bar{q}\gamma^\mu(\cos\theta + \gamma^5 \sin\theta)q\bar{\chi}\gamma^\mu\chi}{\Lambda^4}$  dan melakukan regresi dari input terhadap nilai  $\theta$ . Akurasi yang lebih tinggi kemungkinan dapat dicapai jika mempertimbangkan interaksi yang memiliki lebih banyak  $Z$ -boson atau foton di keadaan akhir. Dengan banyaknya partikel di keadaan akhir, jumlah *events* yang terjadi pun menjadi lebih kecil. Perhitungan yang lebih mendalam mengenai akurasi dan jumlah *events* dapat dilakukan pada penelitian selanjutnya.

#### UCAPAN TERIMA KASIH

Penelitian ini didukung oleh LPPM UNPAR dengan No Perjanjian III/LPPM/2021-02/9-P.

#### PUSTAKA

- Aaboud, M., et al. 2018. Search for dark matter and other new phenomena in events with an energetic jet and large missing transverse momentum using the ATLAS detector, JHEP 01, 126 (2018)
- Alloul, A., et.al. 2014. FeynRules 2.0 - A complete toolbox for tree-level phenomenology. Comput. Phys. Commun. 185, 2250-2300
- Alwall J., et.al. 2014. The automated computation of tree-level and next-to-leading order differential cross sections, and their matching to parton shower simulations. JHEP 07, 079 (2014)
- Arcadi, G. et.al. 2018. The waning of the WIMP? A review of models, searches, and constraints. Eur. Phys. J. C 78, no.3, 203 (2018)
- Baldi, P. et.al. 2014. Searching for Exotic Particles in High-Energy Physics with Deep Learning, Nature Commun. 5, 4308
- Belayneh, D. et.al. 2020. Calorimetry with deep learning: particle simulation and reconstruction for collider physics. Eur. Phys. J. C 80, no.7, 688 (2020)
- Fox, P.J., et.al., 2012. Missing Energy Signatures of Dark Matter at the LHC. Phys. Rev. D 85, 056011 (2012)
- Guest, D. et.al. 2018. Deep Learning and its Application to LHC Physics. Ann. Rev. Nucl. Part. Sci. 68, 161-181 (2018)
- Lundberg S. and Lee S.I. 2017. A unified approach to interpreting model predictions. Presented at 2017 Conference on Neural Information Processing Systems, Long Beach, California, United States, December 4-9 2017
- Sirunyan, A.M, et. al. 2018. Search for new physics in final states with an energetic jet or a hadronically decaying  $W$  or  $Z$  boson and transverse momentum imbalance at  $\sqrt{s} = 13$  TeV. Phys. Rev. D 97, no.9, 092005 (2018)
- Zyla, P.A. et al. 2020. Review of Particle Physics. Prog. Theor. Exp. Phys. 2020, 083C01.