

# Kruskal-Wallis Analysis of CNN Architecture Performance on CT Image Lung Nodule Classification

Sekar Sari<sup>a1</sup>, Kevin Ilham Apriandy<sup>b2</sup>, Yerezqy Bagus<sup>b3</sup>

<sup>a</sup>Program Studi D3 Teknologi Listrik, Politeknik Internasional Tamansiswa Mojokerto  
Kota Mojokerto, Jawa Timur, Indonesia  
<sup>1</sup>sekarsari103@gmail.com

<sup>b</sup>Program Studi D3 Teknologi Komputer, Politeknik Internasional Tamansiswa Mojokerto  
Kota Mojokerto, Jawa Timur, Indonesia  
<sup>2</sup>kevinapriandy@gmail.com  
<sup>3</sup>yerezqybagus2@gmail.com

## Abstract

*CT lung image detection and classification with a Convolutional Neural Network (CNN) is an important step toward assisting radiologists faster and more precisely. CNN comprises various architectures with different characteristics and layer structures, which influence the test results. In addition, the number of epochs used during the training process has an impact on the performance of each CNN architecture. Testing variations throughout the same number of epochs on the CNN architecture yields various results depending on the analytic parameters of accuracy, precision, sensitivity, specificity, and F1-Score. The test results still do not provide statistical information on the performance of the CNN architecture in the classification of lung nodules on CT images. This study conducted a non-parametric statistical test, the Kruskal-Wallis test, to explore if there was a significant difference in the performance of the CNN architecture in classifying lung nodules from CT scan images. The results showed that the Asymp. Sig. Value for the five unpaired variables <0.05, including accuracy 0.002, precision 0.000, sensitivity 0.000, specificity 0.001, and F1-score 0.000, meaning that the hypothesis decision is accepted. In the classification of multiclass lung cancer CT images, the CNN architectures ResNet50, EfficientNetB1, MobileNetV2, VGG16, and AlexNet have considerably different average accuracy, precision, sensitivity, specificity, and F1-scores. Accordingly, after evaluating the CNN architecture with different numbers of epochs, it is known that each CNN design requires a distinct number of epochs to achieve the best test results.*

**Keywords:** Performance, Kruskal-Wallis Test, Non-Parametric Test, CNN Architecture, Epoch Variations

## 1. Pendahuluan

Kanker paru adalah masalah kesehatan yang menyerang organ paru-paru dimana sel-sel abnormal mulai berkembang secara tidak terkendali [1]. Kanker paru-paru sering didiagnosis pada tahap lanjut, karena gejalanya bisa berkembang perlahan dan tidak spesifik. Deteksi dini pemeriksaan radiologi sangat penting untuk meningkatkan kelangsungan hidup pasien, seperti (*computed tomography*) CT scan [2]. Setelah beberapa dekade, pemeriksaan dini kanker paru menggunakan CT scan banyak dilakukan, karena CT scan merupakan modalitas citra terbaik untuk deteksi dini kanker paru dan analisis nodul [3][4]. Hasil pemeriksaan dengan resolusi citra yang bagus dan detail menjadikan deteksi nodul paru menggunakan CT scan lebih efektif dilakukan [5], sehingga semakin banyak citra CT yang terakumulasi di rumah sakit untuk memerlukan diagnosis lebih lanjut oleh ahli radiologi. Namun proses deteksi dengan jumlah citra yang sangat besar akan menghabiskan waktu dan tenaga, Selain itu kesalahan dalam proses deteksi nodul menjadi lebih rawan meningkat [1].

Deteksi nodul paru berbasis sistem komputer atau *Computer-Aided Detection* (CAD) telah dikembangkan setiap tahunnya untuk membantu ahli radiologi dalam menangani kasus penyakit kanker paru [6]. Dengan adanya sistem CAD membantu ahli radiologi menginterpretasikan citra medis. Skema CAD sangat dibutuhkan untuk berbagai tugas deteksi seperti deteksi lesi, segmentasi lesi tubuh dan analisis patologis dengan teknik pengolahan citra dan algoritme *machine learning* [1]. Sistem CAD

mampu meningkatkan efisiensi deteksi dan diagnosis serta memperbaiki beberapa kemungkinan kesalahan [3][7][8]. Kondisi tersebut memotivasi banyak peneliti mengembangkan sistem CAD untuk kinerja unggul dalam deteksi nodul paru. Sebagai terobosan modern, sistem CAD dengan *deep learning* telah dikembangkan pada beberapa tahun terakhir hingga sekarang ini, dengan harapan mampu meningkatkan proses pengenalan pola struktur paru dari segi kecepatan maupun keakuratan. Salah satu metode *deep learning* yang sudah digunakan oleh banyak peneliti dalam deteksi maupun klasifikasi citra paru yaitu *Convolutional Neural Network* (CNN) [1][9][10].

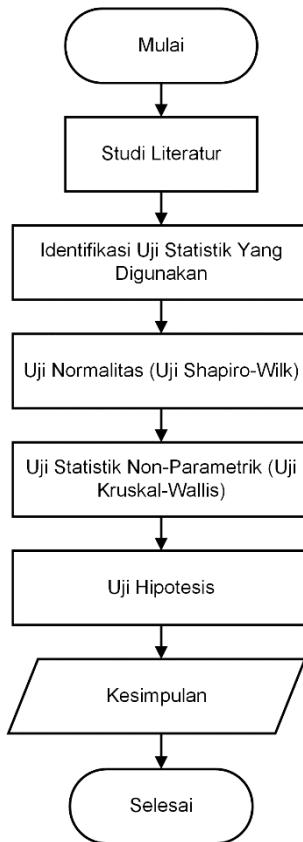
Pada tugas deteksi dan klasifikasi penyakit paru-paru, CNN terdiri dari berbagai arsitektur dengan karakteristik dan struktur layer yang berbeda, yang dapat mempengaruhi hasil pengujian. Selain itu penggunaan jumlah *epoch* dalam proses pelatihan juga berpengaruh terhadap performa kinerja dari setiap arsitektur CNN. *Epoch* adalah nilai yang digunakan dalam pelatihan untuk mengembalikan proses pelatihan kembali ke awal, proses ini dilakukan ketika *neural network* telah selesai melatih keseluruhan dataset dalam sekali pelatihan dari dataset awal hingga akhir. Penggunaan jumlah *epoch* dalam proses pelatihan akan mempengaruhi performa kinerja dari hasil pengujian model atau arsitektur [5]. Untuk mengetahui jumlah *epoch* yang dibutuhkan oleh sebuah model maka perlu dilakukan pengujian variasi jumlah *epoch*.

Pengujian variasi jumlah *epoch* yang sama terhadap arsitektur CNN memberikan hasil yang bervariatif, dan hasilnya menunjukkan adanya perbedaan performa yang ditinjau dari parameter analisis seperti akurasi, presisi, sensitivitas, spesifisitas dan *F1-score*. Diketahui terdapat tiga arsitektur dengan performa baik dan dua arsitektur dengan performa kurang baik. Meskipun hasil pengujian memberikan indikasi awal tentang perbedaan kinerja antar arsitektur CNN, namun belum sepenuhnya memberikan dasar statistik yang cukup kuat untuk mendukung validitas kesimpulan yang diambil. Oleh karena itu, penerapan uji statistik menjadi penting dilakukan untuk menguji hipotesis secara objektif, mengukur signifikansi perbedaan performa antar arsitektur dan memastikan kesimpulan yang diperoleh benar yang didasarkan pada data kuantitatif yang valid. Berdasarkan latar belakang tersebut, penelitian ini melakukan uji beda statistik non parametrik Kruskal-Wallis untuk mengevaluasi apakah terdapat perbedaan yang signifikan performa kinerja antar arsitektur CNN— ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet—dalam mengklasifikasikan nodul paru dari citra CT-scan.

## 2. Metode Penelitian

Penelitian ini merupakan penelitian yang menggunakan teknik analisis non-parametrik Kruskal-Wallis untuk mengetahui perbedaan signifikan terhadap performa kinerja arsitektur CNN dalam mengklasifikasikan citra CT kanker paru. Data yang digunakan pada penelitian ini diambil dari hasil pengujian arsitektur CNN berdasarkan jumlah *epoch* yang berjumlah 25 data. Sebelum melakukan uji statistik non-parametrik, dilakukan uji normalitas untuk mengetahui data sampel berdistribusi normal atau tidak. Data yang digunakan dalam penelitian ini  $< 50$ , sehingga uji normalitas menggunakan Uji Shapiro-Wilk. Pengujian uji normalitas Shapiro-Wilk dan uji statistik non-parametrik Kruskal-Wallis dilakukan menggunakan perangkat lunak IBM SPSS Statistics 25.

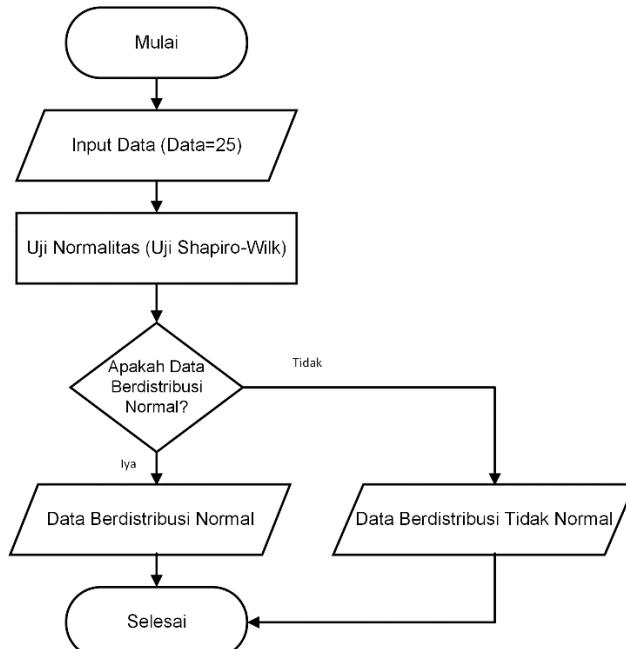
Metode penelitian ini ditunjukkan pada Gambar 1, yang terdiri dari studi literatur, identifikasi uji statistik yang digunakan, uji normalitas, uji beda statistik non-parametrik, uji hipotesis dan kesimpulan. Studi literatur adalah proses membaca, menganalisis dan menentukan metode yang relevan untuk digunakan pada penelitian ini. Identifikasi uji statistik yang digunakan adalah proses menentukan metode yang tepat untuk digunakan pada penelitian ini berdasarkan data sampel yang ada dan tujuan yang akan dicapai. Uji normalitas adalah proses pengujian untuk mengetahui data berdistribusi normal atau tidak, sehingga dapat ditentukan uji selanjutnya yang tepat berdasarkan distribusi data penelitian. Uji beda statistik non-parametrik adalah proses pengujian untuk mengetahui apakah terdapat perbedaan yang signifikan terhadap performa kinerja antar arsitektur CNN dalam mengklasifikasikan nodul paru dari citra CT-scan. Uji hipotesis adalah pengujian untuk menentukan apakah hipotesis ditolak atau diterima. Kesimpulan adalah hasil akhir yang didukung oleh hasil uji hipotesis dan pembahasan yang telah disampaikan.



**Gambar 1.** Flowchart Metode Penelitian

## 2.1. Uji Normalitas Shapiro-Wilk

Uji normalitas bertujuan untuk mengetahui apakah data berdistribusi normal atau tidak normal [11]. Uji normalitas yang digunakan adalah uji Shapiro-Wilk untuk jumlah sampel data yang berukuran kecil  $< 50$  [12][13]. Gambar 2 menunjukkan flowchart uji normalitas Shapiro-Wilk. Dalam proses pengujian ini, langkah pertama adalah *input* data yang berjumlah 25 data hasil pengujian arsitektur CNN. Langkah kedua dilakukan pengujian menggunakan uji Shapiro-Wilk. Data dapat dikatakan berdistribusi normal jika memiliki nilai signifikansi  $> 0,05$  [11].



**Gambar 2.** Flowchart Uji Normalitas Shapiro-Wilk

## 2.2. Uji Statistik Non-Parametrik Kruskal-Wallis

Uji statistik non-parametrik merupakan suatu metode analisis data yang tidak memerlukan persyaratan bahwa data berdistribusi normal. Pengujian ini hanya menentukan persyaratan atau memberikan asumsi bahwa data yang diperoleh bersifat *independent* dan variabel yang diteleki memiliki kontinuitas [14]. Uji Kruskal-Wallis adalah uji statistik non-parametrik untuk menentukan perbedaan signifikan antar kelompok *variable independent* yang lebih dari dua. Uji Kruskal-Wallis merupakan alternatif dari uji One Way ANOVA (*Analysis of Variance*) yang digunakan untuk mengetahui apakah terdapat perbedaan rata-rata data yang lebih dari dua atau minimal tiga kelompok *independent*. Uji Kruskal-Wallis dilakukan pada data yang berdistribusi tidak normal dan *unpaired variable*. Uji Kruskal-Wallis dituliskan dalam persamaan (1) [15]:

$$K = (N - 1) \frac{\sum_{i=1}^g n_i (r_i - R)^2}{\sum_{i=1}^g \sum_{j=1}^{n_i} (r_{ij} - R)^2} \quad (1)$$

Dengan,

$n_i$  : jumlah pengamatan dalam kelompok

$r_{ij}$  : peringkat (diantara semua pengamatan) pengamatan j dari kelompok i

$N$  : jumlah pengamatan di semua kelompok

Sedangkan persamaan untuk menentukan peringkat (diantara semua pengamatan) dituliskan dalam persamaan (2) [14]:

$$r = \frac{\sum_{j=1}^{n_i} r_{ij}}{n_i} \quad (2)$$

Hipotesis

$H_0: \mu_1 = \mu_2 = \mu_3 = \mu_4 = \mu_5$

$H_1:$  tidak semua  $\mu_i$  sama, dimana  $i = 1,2,3,4,5$  (ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet).

Dengan tingkat signifikansi  $\alpha = 5\% = 0,05$  adalah bilangan yang mencerminkan besarnya peluang menolak  $H_0$  ketika  $H_1$  bernilai benar. Apabila nilai  $p\text{-value} \leq \alpha$  maka penolakan terhadap  $H_0$  dan sebaliknya apabila  $p\text{-value} > \alpha$  maka penerimaan  $H_0$  [16]. *Flowchart* Uji Kruskal-Wallis ditunjukkan pada Gambar 3.

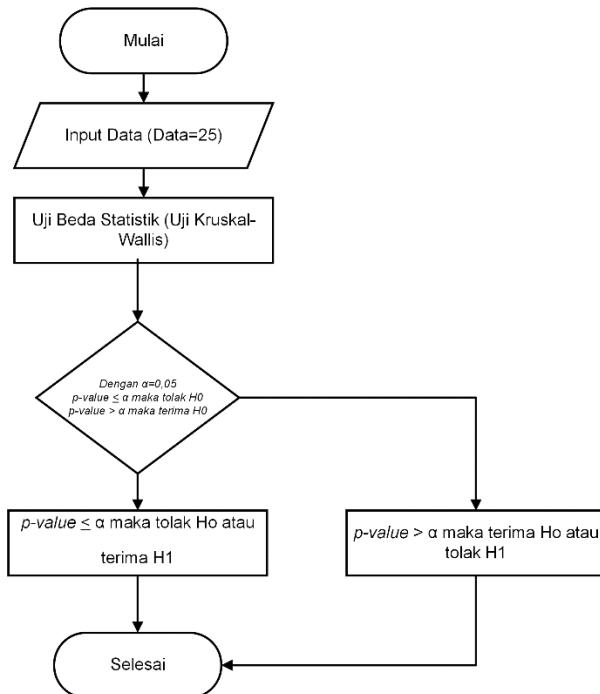
## 2.3. Uji Hipotesis Penelitian

Hipotesis dalam penelitian ini;

$H_0:$  Tidak ada perbedaan rata-rata akurasi, presisi, sensitivitas, spesifikasi dan F1-score antara arsitektur CNN ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet dalam klasifikasi nodul paru pada citra CT multiclass

$H_1:$  Ada perbedaan rata-rata akurasi, presisi, sensitivitas, spesifikasi dan F1-score antara arsitektur CNN ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet dalam klasifikasi nodul paru pada citra CT multiclass

Pengambilan keputusan dari uji hipotesis penelitian ini dilakukan berdasarkan hasil keputusan nilai *Asymp. Sig.* pada uji Kruskal-Wallis. Apabila nilai *Asymp. Sig.*  $\leq 0,05$  maka  $H_1$  diterima dan sebaliknya apabila *Asymp. Sig.*  $> 0,05$  maka  $H_0$  diterima. *Unpaired variable* yang digunakan adalah nilai parameter analisis dari pengujian arsitektur CNN yaitu akurasi, presisi, sensitivitas, spesifikasi dan F1-score. Akurasi digunakan untuk menentukan seberapa akurat model arsitektur dalam mengklasifikasikan citra. Sensitivitas menggambarkan keberhasilan model arsitektur dalam menemukan informasi. Presisi merepresentasikan tingkat kesepakatan antara data yang diminta dengan hasil prediksi model arsitektur. Spesifikasi merepresentasikan seberapa mungkin pengujian memberikan hasil negatif untuk citra yang tidak memiliki karakteristik. F1-score mengukur keakuratan pengujian dengan mempertimbangkan sensitivitas dan presisi.



**Gambar 3.** Flowchart Uji Kruskal-Wallis

### 3. Hasil dan Pembahasan

Pengumpulan data penelitian dilakukan dengan cara uji coba arsitektur CNN dengan beberapa jumlah *epoch* yang telah ditentukan. *Epoch* adalah nilai yang digunakan dalam pelatihan untuk mengembalikan proses pelatihan kembali ke awal, proses ini dilakukan ketika *neural network* telah selesai melalih keseluruhan dataset dalam sekali pelatihan dari dataset awal hingga akhir. Penggunaan jumlah *epoch* dalam proses pelatihan akan mempengaruhi performa kinerja dari hasil pengujian model atau arsitektur. Untuk mengetahui jumlah *epoch* yang dibutuhkan oleh sebuah model maka perlu dilakukan pengujian variasi jumlah *epoch*. Variasi jumlah *epoch* yang digunakan dalam pengambilan data adalah 50, 100, 150, 200 dan 250. Data yang digunakan dalam penelitian ini berjumlah 25 data. Tabel 1, menunjukkan skenario evaluasi dari parameter *input* yang berupa variasi jumlah *epoch* pada pelatihan arsitektur CNN.

**Tabel 1.** Skenario Evaluasi dari Parameter *Input*

| No | Skenario | Jumlah Epoch | Arsitektur CNN                                        | Parameter yang Diamati                                 |
|----|----------|--------------|-------------------------------------------------------|--------------------------------------------------------|
| 1. | I        | 50           | ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet | akurasi, presisi, sensitivitas, spesifisitas, F1-Score |
| 2. | II       | 100          | ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet | akurasi, presisi, sensitivitas, spesifisitas, F1-Score |
| 3. | III      | 150          | ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet | akurasi, presisi, sensitivitas, spesifisitas, F1-Score |
| 4. | IV       | 200          | ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet | akurasi, presisi, sensitivitas, spesifisitas, F1-Score |
| 5. | V        | 250          | ResNet50, EfficientNetB1, MobileNetV2, VGG16, AlexNet | akurasi, presisi, sensitivitas, spesifisitas, F1-Score |

### 3.1. Hasil Uji Normalitas Shapiro-Wilk

Sampel data yang digunakan dalam penelitian ini berjumlah 25 dari semua kelas data yang diuji dan *unpaired variable*. Sebelum uji hipotesis, dilakukan uji normalitas menggunakan uji Shapiro-Wilk karena data berjumlah < 50. Uji normalitas digunakan untuk mengetahui data berdistribusi normal atau tidak normal. Hasil uji normalitas Shapiro-Wilk ditunjukkan pada Tabel 2. Setelah mengamati data hasil uji normalitas Shapiro-Wilk pada kolom Sig. dan kesesuaian dengan dasar pengambilan keputusan uji Shapiro-Wilk, dapat diketahui bahwa data berdistribusi tidak normal karena terdapat beberapa data yang memiliki nilai Sig. < 0,05 salah satunya yaitu 0,006 (variabel akurasi dari arsitektur CNN EfficientNetB1). Sehingga diketahui bahwa data berdistribusi tidak normal.

**Tabel 2.** Hasil Uji Normalitas Shapiro-Wilk

| <i>Unpaired Variable</i> | Arsitektur CNN | Kolmogorov-Smirnov <sup>a</sup> |    |        | Shapiro-Wilk |    |       |
|--------------------------|----------------|---------------------------------|----|--------|--------------|----|-------|
|                          |                | Statistic                       | df | Sig.   | Statistic    | df | Sig,  |
| Akurasi                  | ResNet50       | 0,182                           | 5  | 0,200* | 0,937        | 5  | 0,643 |
|                          | EfficientNetB1 | 0,367                           | 5  | 0,026  | 0,684        | 5  | 0,006 |
|                          | MobileNetV2    | 0,349                           | 5  | 0,047  | 0,778        | 5  | 0,053 |
|                          | VGG16          | 0,258                           | 5  | 0,200* | 0,831        | 5  | 0,141 |
|                          | AlexNet        | 0,315                           | 5  | 0,118  | 0,859        | 5  | 0,226 |
|                          | ResNet50       | 0,217                           | 5  | 0,200* | 0,948        | 5  | 0,723 |
| Sensitivitas             | EfficientNetB1 | 0,339                           | 5  | 0,062  | 0,716        | 5  | 0,014 |
|                          | MobileNetV2    | 0,345                           | 5  | 0,052  | 0,783        | 5  | 0,058 |
|                          | VGG16          | 0,286                           | 5  | 0,200* | 0,768        | 5  | 0,043 |
|                          | AlexNet        | 0,176                           | 5  | 0,200* | 0,965        | 5  | 0,841 |
|                          | ResNet50       | 0,436                           | 5  | 0,002  | 0,655        | 5  | 0,003 |
| Presisi                  | EfficientNetB1 | 0,285                           | 5  | 0,200* | 0,867        | 5  | 0,256 |
|                          | MobileNetV2    | 0,318                           | 5  | 0,109  | 0,869        | 5  | 0,261 |
|                          | VGG16          | 0,218                           | 5  | 0,200* | 0,932        | 5  | 0,609 |
|                          | AlexNet        | 0,189                           | 5  | 0,200* | 0,953        | 5  | 0,757 |
|                          | ResNet50       | 0,204                           | 5  | 0,200* | 0,930        | 5  | 0,596 |
| Spesifisitas             | EfficientNetB1 | 0,339                           | 5  | 0,061  | 0,735        | 5  | 0,021 |
|                          | MobileNetV2    | 0,360                           | 5  | 0,033  | 0,775        | 5  | 0,050 |
|                          | VGG16          | 0,198                           | 5  | 0,200* | 0,884        | 5  | 0,329 |
|                          | AlexNet        | 0,259                           | 5  | 0,200* | 0,938        | 5  | 0,649 |
|                          | ResNet50       | 0,202                           | 5  | 0,200* | 0,944        | 5  | 0,694 |
| F1_score                 | EfficientNetB1 | 0,367                           | 5  | 0,026  | 0,706        | 5  | 0,011 |
|                          | MobileNetV2    | 0,365                           | 5  | 0,028  | 0,767        | 5  | 0,043 |
|                          | VGG16          | 0,266                           | 5  | 0,200* | 0,877        | 5  | 0,295 |
|                          | AlexNet        | 0,207                           | 5  | 0,200* | 0,937        | 5  | 0,646 |

\*. This is a lower bound of the true significance

a. Lilliefors Significance Correction

### 3.2. Hasil Uji Statistik Non-Parametrik Kruskal-Wallis

Setelah mengetahui bahwa data berdistribusi tidak normal, maka untuk melakukan uji beda statistik dilakukan menggunakan uji non-parametrik. Variabel data hasil uji coba arsitektur CNN tidak berpasangan (*unpaired*) dan terdiri lebih dari dua kelompok (akurasi, presisi, sensitivitas, spesifisitas dan *F1-score*). Sehingga untuk melakukan uji beda statistik non-parametrik menggunakan uji Kruskal-Wallis. Tabel 3 menunjukkan hasil uji beda statistik Kruskal-Wallis. Pada penelitian ini dasar pengambilan keputusan uji Kruskal-Wallis yaitu Jika nilai Asymp. Sig. (2-tailed)  $\leq 0,05$  hipotesis 0 ditolak. Sebaliknya jika nilai Asymp. Sig. (2-tailed)  $> 0,05$  maka hipotesis 0 diterima.

**Tabel 3.** Hasil Uji Kruskal-Wallis

|                  | Test Statistics <sup>a,b</sup> |              |         |              |          |
|------------------|--------------------------------|--------------|---------|--------------|----------|
|                  | Akurasi                        | Sensitivitas | Presisi | Spesifisitas | F1_Score |
| Kruskal-Wallis H | 16,573                         | 20,058       | 21,693  | 20,639       | 19,414   |
| df               | 4                              | 4            | 4       | 4            | 4        |
| Asymp. Sig.      | 0,002                          | 0,000        | 0,000   | 0,000        | 0,001    |

Hasil uji beda statistik Kruskal-Wallis pada Tabel 3 menunjukkan bahwa nilai Asymp. Sig. untuk kelima *unpaired variable* < 0,05 yaitu akurasi 0,002; presisi 0,000; sensitivitas 0,000; spesifisitas 0,001 dan *F1-score* 0,000. Sehingga dapat diketahui bahwa hipotesis 0 ditolak dan hipotesis 1 diterima.

### 3.3. Hasil Uji Hipotesis Penelitian

Hasil uji hipotesis penelitian ini berdasarkan hasil dari uji Kruskal-Wallis, yaitu menolak hipotesis 0 dan menerima hipotesis 1. Sehingga hasil uji hipotesis dalam penelitian ini adalah ada perbedaan rata-rata akurasi, presisi, sensitivitas, spesifisitas dan F1-Score antara arsitektur CNN ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet pada klasifikasi citra CT kanker paru *multiclass* secara signifikan dengan taraf signifikansi  $\alpha=5\%$  atau 0,05. Hal tersebut menandakan bahwa pengujian arsitektur CNN—ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet—dalam mengklasifikasikan nodul paru dari citra CT-scan membutuhkan jumlah *epoch* yang beragam (berbeda) untuk mencapai hasil pengujian yang terbaik.

### 4. Kesimpulan

Berdasarkan hasil uji beda statistik Kruskal Wallis, maka kesimpulan dari penelitian ini adalah terdapat perbedaan yang signifikan terhadap performa kinerja dari arsitektur CNN—ResNet50, EfficientNetB1, MobileNetV2, VGG16 dan AlexNet—dalam mengklasifikasikan citra CT nodul paru *multiclass* dengan taraf signifikasi 0,05. Penelitian ini didukung oleh data hasil pengujian arsitektur CNN berdasarkan variasi jumlah *epoch* dengan *unpaired variable* yaitu akurasi, presisi, sensitivitas, spesifisitas dan *F1-score*. Dengan demikian diketahui bahwa performa kinerja antar arsitektur CNN membutuhkan jumlah *epoch* yang berbeda untuk mencapai hasil pengujian yang terbaik.

### Referensi

- [1] H. Jiang, H. Ma, W. Qian, M. Gao, and Y. Li, "An Automatic Detection System of Lung Nodule Based on Multigroup Patch-Based Deep Learning Network," *IEEE J. Biomed. Heal. Informatics*, vol. 22, no. 4, pp. 1227–1237, 2018, doi: 10.1109/JBHI.2017.2725903.
- [2] Q. Dou, H. Chen, L. Yu, J. Qin, and P. A. Heng, "Multilevel Contextual 3-D CNNs for False Positive Reduction in Pulmonary Nodule Detection," *IEEE Trans. Biomed. Eng.*, vol. 64, no. 7, pp. 1558–1567, 2017, doi: 10.1109/TBME.2016.2613502.
- [3] M. Anthimopoulos, S. Christodoulidis, L. Ebner, A. Christe, and S. Mougiakakou, "Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1207–1216, 2016, doi: 10.1109/TMI.2016.2535865.
- [4] X. Huang, W. Sun, T. L. (Bill) Tseng, C. Li, and W. Qian, "Fast and fully-automated detection and segmentation of pulmonary nodules in thoracic CT scans using deep convolutional neural networks," *Comput. Med. Imaging Graph.*, vol. 74, pp. 25–36, 2019, doi: 10.1016/j.compmedimag.2019.02.003.
- [5] T. Messay, R. C. Hardie, and T. R. Tuinstra, "Segmentation of pulmonary nodules in computed tomography using a regression neural network approach and its application to the Lung Image Database Consortium and Image Database Resource Initiative dataset," *Med. Image Anal.*, vol. 22, no. 1, pp. 48–62, 2015, doi: 10.1016/j.media.2015.02.002.
- [6] R. Zhang, C. Cheng, X. Zhao, and X. Li, "Multiscale Mask R-CNN-Based Lung Tumor Detection Using PET Imaging," *Mol. Imaging*, vol. 18, pp. 1–8, 2019, doi: 10.1177/1536012119863531.
- [7] R. Golan, C. Jacob, and J. Denzinger, "Lung nodule detection in CT images using deep convolutional neural networks," *Proc. Int. Jt. Conf. Neural Networks*, vol. 2016-Octob, no. 1, pp. 243–250, 2016, doi: 10.1109/IJCNN.2016.7727205.
- [8] R. Tekade and K. Rajeswari, "Lung Cancer Detection and Classification using Deep Learning," *IEEE Xplore*, 2018.
- [9] A. Y. Saleh, C. K. Chin, V. Penshie, and H. R. H. Al-Absi, "Lung cancer medical images

- classification using hybrid cnn-svm," *Int. J. Adv. Intell. Informatics*, vol. 7, no. 2, pp. 151–162, 2021, doi: 10.26555/ijain.v7i2.317.
- [10]Y. Chen, X. Duan, S. Chatani, W. Du, J. Wang, and Q. Hu, "An Improved Region-based Fully Convolutional Network for Automatic Pulmonary Nodules Detection," pp. 256–261, 2019.
- [11]S. Hadija Difinubun, O. Dominggus Nara, M. Abdin, J. Teknik, S. Politeknik, and N. Ambon, "Analisis Pengaruh Sumber Daya Manusia Terhadap Aspek Kinerja Pekerja Pada Proyek Pembangunan Gedung Laboratorium Terpadu Pendukung Blok Masela Universitas Pattimura," *J. Agreg.*, vol. 2, no. 1, pp. 76–86, 2023.
- [12]P. Mishra, C. M. Pandey, U. Singh, A. Gupta, C. Sahu, and A. Keshri, "Descriptive statistics and normality tests for statistical data," *Ann. Card. Anaesth.*, vol. 22, no. 1, pp. 67–72, 2019, doi: 10.4103/aca.ACA\_157\_18.
- [13]A. Indrasetianingsih, I. A. Haryanto, and P. A. Divaio, "Analisis Kruskal-Wallis untuk Mengetahui Kemampuan Literasi Siswa SMP Miftahurrohman Gresik Berdasarkan Asesmen Kompetensi Minimum," *Indones. J. Multidiscip. Soc. Technol.*, vol. 2, no. 1, pp. 32–36, 2024, doi: 10.31004/ijmst.v2i1.286.
- [14]F. Rozi, Irma, and D. Maulidiya, "Analisis Perubahan Inflasi Beberapa Kota Besar di Indonesia dengan Menggunakan Uji Kruskal-Wallis," *Multi Prox. J. Stat. Univ. Jambi*, vol. 1, no. 2, pp. 103–115, 2022, [Online]. Available: <https://online-journal.unja.ac.id/multiproximityhttps://doi.org/10.22437/multiproximity.v1i2.21418>
- [15]H. Takagi, "Statistical Tests for Computational Intelligence Research and Human Subjective Tests," pp. 1–52, 2015.
- [16]A. Quraisy and N. Hasni, "Analisis Kruskal-Wallis Terhadap Kemampuan Numerik Siswa," *VARIANSI J. Stat. Its Appl. Teach. Res.*, vol. 3, no. 3, pp. 156–161, 2021, doi: 10.35580/variansium29957.