



Analisis Monitoring Gerakan Duduk dengan Menggunakan Metode Mobile Net Ssd pada Karyawan

<u>INFO PENULIS</u>	<u>INFO ARTIKEL</u>
Ailul Aiman Universitas Muhammadiyah Makassar ailulaiman46@gmail.com	ISSN: 3026-3603 Vol.3, No. 1 April 2025 http://jurnal.ardenjaya.com/index.php/ajst
Fahrim Irhamna Rahman Universitas Muhammadiyah Makassar fachrim141020@unismuh.ac.id	
Titin Wahyuni Universitas Muhammadiyah Makassar titinwahyuni@unismuh.ac.id	

© 2025 Arden Jaya Publisher All rights reserved

Saran Penulisan Referensi:

Aiman, A., Rahman, I. F., & Wahyuni, T. (2025). Analisis Monitoring Gerakan Duduk dengan Menggunakan Metode Mobile Net Ssd pada Karyawan *Arus Jurnal Sains dan Teknologi*, 3(1), 127-133.

Abstrak

Produktivitas merupakan faktor kunci dalam keberhasilan organisasi di dunia kerja modern. Karyawan yang sehat dan nyaman cenderung lebih produktif dan inovatif. Namun, postur tubuh yang buruk saat duduk dapat menyebabkan kelelahan, nyeri punggung bawah, serta penurunan produktivitas. Untuk mengatasi masalah ini, teknologi pemantauan postur duduk berbasis computer vision semakin berkembang. Salah satu metode yang efektif adalah MobileNet Single Shot Detector (SSD), yang digunakan untuk mendeteksi dan menganalisis postur duduk. MobileNet SSD dapat mengenali berbagai pose duduk secara cepat dan memberikan umpan balik instan kepada karyawan mengenai posisi duduk yang ergonomis. Penelitian ini bertujuan untuk mengukur akurasi MobileNet SSD dalam mendeteksi gerakan duduk yang baik dan buruk, serta untuk menganalisis potensi penerapan teknologi ini dalam lingkungan kerja. Hasil penelitian menunjukkan bahwa MobileNet SSD memiliki akurasi yang tinggi dalam mendeteksi postur duduk, yang dapat membantu perusahaan untuk meningkatkan kesejahteraan karyawan dan merancang strategi kerja yang lebih efisien di masa depan.

Kata kunci: produktivitas, postur duduk, MobileNet SSD, computer vision, akurasi, pemantauan

Abstract

Productivity is a key factor in organizational success in the modern world of work. Employees who are healthy and comfortable tend to be more productive and innovative. However, poor posture when sitting can cause fatigue, lower back pain, and decreased productivity. To overcome this problem, computer vision-based sitting posture monitoring technology is increasingly developing. One effective method is the MobileNet Single Shot Detector (SSD), which is used to detect and analyze sitting posture. MobileNet SSD can quickly recognize various sitting poses and provide instant feedback to employees regarding ergonomic sitting positions. This research aims to measure the accuracy of MobileNet SSD in detecting good and bad sitting movements, as well as to analyze the potential application of this technology in the work environment. The research results show that MobileNet SSD has high accuracy in detecting sitting posture, which can help companies improve employee well-being and design more efficient work strategies in the future.

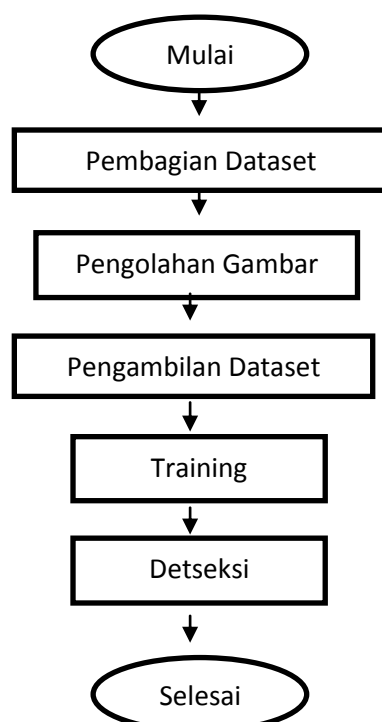
Keywords: productivity, sitting posture, MobileNet SSD, computer vision, accuracy, monitoring

A. Pendahuluan

Di dunia kerja modern, produktivitas merupakan faktor kunci bagi keberhasilan organisasi. Karyawan yang sehat dan merasa nyaman cenderung lebih produktif, inovatif, dan berkomitmen, postur tubuh yang kurang tepat dan posisi yang tidak ergonomis saat duduk dapat menyebabkan peningkatan jumlah energi, dan transfer tenaga yang tidak efisien dari otot ke jaringan rangka yang menyebabkan timbulnya kelelahan, hal ini dapat berujung pada nyeri punggung bawah, karyawan mengalami penurunan produktivitas kerja dan disabilitas. Oleh karena itu, perlu dilakukan edukasi kepada para karyawan awam mengenai postur yang baik dan sehat (Iskandar et al. 2021). Untuk mengatasi masalah ini, teknologi monitoring postur duduk menggunakan pendekatan *computer vision* semakin berkembang, Salah satu metode yang efektif untuk mendeteksi dan menganalisis postur duduk adalah *MobileNet Single Shot Detector* (SSD). *MobileNet* SSD merupakan jaringan *single-shot* multibox detection (SSD) yang mengidentifikasi objek dengan memindai piksel gambar yang berada di dalam koordinat kotak pembatas dan probabilitas kelas (Gustsa and Permadi 2023). Penerapan *MobileNet* SSD untuk memantau gerakan duduk karyawan dapat membantu dalam mendeteksi postur duduk yang tidak ergonomis. Algoritma ini mampu mengenali berbagai pose duduk secara cepat, sehingga kemungkinan pemberian umpan balik instan kepada karyawan jika mereka berada dalam posisi duduk yang baik dalam bekerja dan tidak baik dalam bekerja. Studi lain juga mendukung pentingnya deteksi postur otomatis dalam lingkungan kerja, posisi dalam bekerja terbagi atas dua yakni posisi statis dan posisi dinamis. Posisi statis adalah posisi bekerja tanpa melakukan gerakan pada sendi dan dalam kurun waktu yang lama (JANNA 2021). Gerakan duduk adalah aktivitas yang dilakukan oleh manusia dengan posisi tubuh yang terletak di atas permukaan, biasanya dengan bokong sebagai tumpuan. Aktivitas ini merupakan bagian penting dari kehidupan sehari-hari, terutama dalam konteks pekerjaan dan interaksi sosial. Posisi duduk yang benar yakni duduk dengan posisi tegap sudut 90 derajat yang mengharuskan seseorang untuk selalu menjaga bagian-bagian vital pada tubuh untuk selalu berada pada postur yang tepat (Supriyanto et al. 2023). Posisi duduk yang tidak ergonomis, seperti duduk membungkuk dalam waktu lama, dapat meningkatkan risiko nyeri punggung bawah. Duduk dalam posisi statis yang buruk menyebabkan otot bekerja terlalu keras tanpa cukup waktu untuk pemulihan, sehingga aliran darah ke otot terganggu, sedangkan posisi duduk yang ergonomis seperti duduk dengan lurus tidak membungkuk bisa mendapatkan kenyamanan dalam bekerja (Amin et al. 2023).

Dengan analisis gerakan duduk ini, perusahaan dapat lebih proaktif dalam melakukan pekerjaan dan kesejahteraan karyawan. Data yang dihasilkan dari monitoring ini juga dapat digunakan untuk menganalisis pola kerja karyawan dan merancang strategi bekerja dengan fokus di masa depan.

B. Metodologi



1. Pengambilan dataset

Data di ambil menggunakan kamera smartphone dari beberapa subjek dan objek.

2. Pengolahan gambar

Dalam pengolahan data di perlukan preprocessing data yang di mana Preprocessing merupakan tahap krusial sebelum memasukkan citra ke dalam model atau algoritma, yang bertujuan untuk menyiapkan dan meningkatkan kualitas atau kesesuaian citra sesuai dengan kebutuhan.

3. Pemberian label

Dalam langkah ini, dataset telah di proses dengan pengolahan gambar yang di beri label menggunakan platform *Roboflow*. *Roboflow* bertujuan untuk menambahkan kotak pembatas pada setiap objek yang terdapat dalam gambar.

4. Pembagian dataset

Dataset yang telah di beri label akan di bagi menjadi tiga bagian yaitu data training, data validasi, dan data testing. Data training di gunakan untuk melatih model deteksi, sementara data validasi di gunakan untuk mengevaluasi performa model selama proses pelatihan. Data testing kemudian di gunakan untuk menguji performa model dan mengukur akurasi dengan menggunakan data yang belum pernah di lihat sebelumnya.

5. Training

Pada langkah ini, data yang telah di bagi menjadi data latih dan data uji akan di akses. Data yang tersedia dalam bentuk API di *Roboflow* akan di ambil melalui lingkungan pengembangan seperti *VSCode*.

6. Deteksi

Proses pendeteksian di mulai dengan memasukkan gambar yang telah di kumpulkan. Gambar tersebut kemudian di analisis menggunakan *MobileNet SSD* untuk mengidentifikasi objek. Hasil dari proses ini mencakup akurasi, yang menunjukkan beberapa efektif dalam mengenali objek.

C. Hasil dan pembahasan

a) Pembuatan model

Pengambilan dataset

Dataset gambar di ambil menggunakan kamera HP dan terdiri dari 200 gambar gerakan duduk. Dataset ini mencakup berbagai. Duduk yang sehat dalam kesehatan dan duduk tidak sehat dalam kesehatan.

Duduk yang sehat dalam kesehatan dan duduk tidak sehat dalam kesehatan.

Tempat pengambilan data	Objek data yang di ambil	Jumlah Data Gambar
RSUD Sayang Rakyat	Duduk yang sehat dalam kesehatan	100
	Duduk tidak tidak sehat dalam kesehatan	100

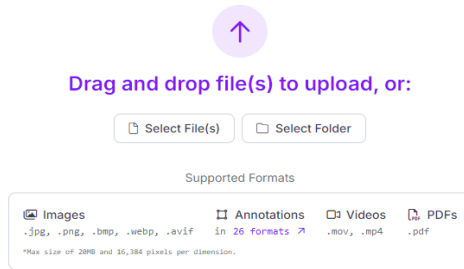


Gambar duduk yang tidak sehat dalam kesehatan.

b) Pelabelan

Upload dataset

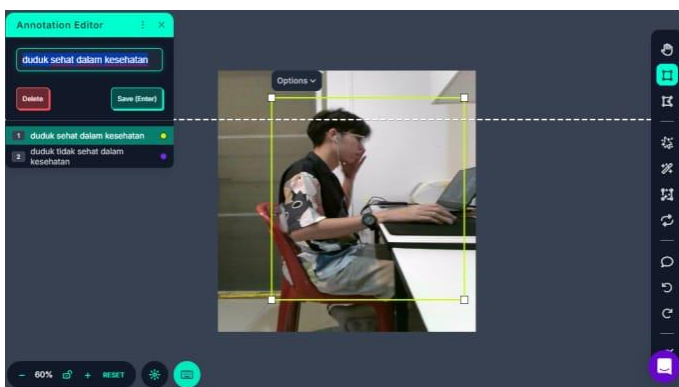
Gambar yang telah di kumpulkan sebelumnya akan di unggah ke Roboflow sebelum proses pelabelan di lakukan.



Pembuatan class dataset

Tujuan pembuatan kelas ini adalah untuk mempermudah penentuan dataset gambar yang telah di beri bounding box, sehingga secara otomatis akan muncul duakelas yang telah di buat. Dengan demikian, dataset akan masuk ke dalam kategori yang sesuai

Proses pelabelan dan pembagian kategori gambar. proses pelabelan gambar menggunakan alat Roboflow di lakukan dengan menambahkan bounding box atau frame pada objek dalam gambar. Setelah bounding box di tambahkan, kelas dengan kategori duduk bekerja dan duduk tidak bekerja.



c) Preprocessing Gambar

Proses pengolahan gambar melibatkan pengeditan gambar menggunakan Roboflow, termasuk penyesuaian warna, bentuk, dan ukuran, serta penggunaan teknik seperti Preprocessing dan Augmentation. Mengubah ukuran gambar (reize) menjadi 320 x 320 bertujuan untuk mengurangi beban kerja GPU saat melatih model.

Preprocessing Auto-Orient: Applied
 Resize: Stretch to 320x320

Augmentations No augmentations were applied.

Training Google colab
 Hasil pelatihan

Split data : 0.3
 Learning rate : 0.0001

Aktivasi : softmax
 Epoch : 30
 Batch size : 16


Model check point : call back Proses training

```

9/9 epoch 24: val_class_output_accuracy did not improve from 0.65000
9/9 -----> 1s 30ms/step - bbox_output_loss: 32136.5156 - bbox_output_mse: 32166.4609 - class_output_accuracy: 0.7604 - class_output_loss: 0.4882 - loss: 32166.4609
9/9 -----> 0s 8ms/step - bbox_output_loss: 31580.6973 - bbox_output_mse: 31576.1367 - class_output_accuracy: 0.7492 - class_output_loss: 0.5330 - loss: 31576.4105
9/9 epoch 25: val_class_output_accuracy did not improve from 0.65000
9/9 -----> 1s 30ms/step - bbox_output_loss: 31036.3984 - bbox_output_mse: 31071.895 - class_output_accuracy: 0.7507 - class_output_loss: 0.5322 - loss: 31036.3984
9/9 -----> 0s 8ms/step - bbox_output_loss: 31693.2949 - bbox_output_mse: 31694.6426 - class_output_accuracy: 0.8328 - class_output_loss: 0.4285 - loss: 31693.2949
9/9 epoch 26: val_class_output_accuracy did not improve from 0.65000
9/9 -----> 1s 30ms/step - bbox_output_loss: 31069.4395 - bbox_output_mse: 31071.8072 - class_output_accuracy: 0.8272 - class_output_loss: 0.4365 - loss: 31071.8072
9/9 -----> 0s 8ms/step - bbox_output_loss: 31151.1445 - bbox_output_mse: 31148.2168 - class_output_accuracy: 0.7843 - class_output_loss: 0.4928 - loss: 31148.2168
9/9 epoch 27: val_class_output_accuracy did not improve from 0.65000
9/9 -----> 1s 30ms/step - bbox_output_loss: 31156.5957 - bbox_output_mse: 31151.3242 - class_output_accuracy: 0.7023 - class_output_loss: 0.4953 - loss: 31151.3242
9/9 -----> 0s 8ms/step - bbox_output_loss: 30804.3125 - bbox_output_mse: 30803.6673 - class_output_accuracy: 0.7834 - class_output_loss: 0.5376 - loss: 30804.3125
9/9 epoch 28: val_class_output_accuracy did not improve from 0.65000
9/9 -----> 1s 30ms/step - bbox_output_loss: 30904.3652 - bbox_output_mse: 30903.2578 - class_output_accuracy: 0.7057 - class_output_loss: 0.5358 - loss: 30903.2578
9/9 -----> 0s 8ms/step - bbox_output_loss: 30273.8340 - bbox_output_mse: 30275.6250 - class_output_accuracy: 0.7304 - class_output_loss: 0.5521 - loss: 30276.1191
9/9 epoch 29: val_class_output_accuracy did not improve from 0.65000
9/9 -----> 1s 30ms/step - bbox_output_loss: 30305.0918 - bbox_output_mse: 30308.3164 - class_output_accuracy: 0.7368 - class_output_loss: 0.5472 - loss: 30308.3164
9/9 -----> 0s 8ms/step - bbox_output_loss: 30418.6113 - bbox_output_mse: 30421.0234 - class_output_accuracy: 0.7551 - class_output_loss: 0.4785 - loss: 30421.5405
9/9 epoch 30: val_class_output_accuracy did not improve from 0.65000
9/9 -----> 1s 30ms/step - bbox_output_loss: 30895.8398 - bbox_output_mse: 30410.1838 - class_output_accuracy: 0.7561 - class_output_loss: 0.4796 - loss: 30410.1838

```

Grafikhasil training



Pada bagian ini, hasil dari pelatihan model pada 30 epoch akan dijelaskan dan dianalisis untuk memberikan pemahaman terkait dengan performa model yang telah dilatih. Model ini menggunakan data yang telah dibagi dengan rasio 70:30 (70% untuk pelatihan dan 30% untuk validasi) dan dioptimalkan menggunakan learning rate sebesar 0.0001. Aktivasi yang digunakan adalah *softmax*, dengan ukuran batch sebesar 16, dan checkpoint model digunakan sebagai callback untuk menyimpan model terbaik.

Pada pelatihan model selama 30 epoch, terdapat beberapa metrik yang dapat diamati, yaitu nilai *loss*, akurasi kelas, serta nilai *loss* pada data validasi. Secara umum, nilai-nilai tersebut memberikan gambaran mengenai seberapa baik model belajar selama pelatihan dan bagaimana kemampuan model dalam menggeneralisasi ke data yang belum pernah dilihat sebelumnya.

Loss total dan Loss per output

Nilai *loss* total pada epoch pertama adalah sekitar 31.5 ribu, yang kemudian mengalami sedikit penurunan menjadi sekitar 30.4 ribu pada epoch terakhir (epoch 30). Penurunan ini menunjukkan adanya perbaikan kecil dalam kemampuan model untuk memprediksi output keseluruhan selama pelatihan. Namun, penurunan yang terbatas ini mengindikasikan bahwa model tidak mengalami peningkatan yang signifikan meskipun sudah melalui 30 epoch pelatihan.

Akurasi kelas

Akurasi model pada output kelas (*class_output_accuracy*) menunjukkan hasil yang bervariasi sepanjang pelatihan. Dimulai pada nilai sekitar 75% pada epoch 25, akurasi ini sempat menurun sedikit menjadi 73% pada epoch 29 dan 30. Fluktuasi ini menunjukkan bahwa model dapat belajar untuk mengenali pola-pola dalam data pelatihan, tetapi belum mampu mencapai performa yang lebih tinggi di atas 80%. Performa akurasi yang tidak mengalami peningkatan signifikan ini mengindikasikan bahwa model menghadapi kesulitan dalam mengenali kelas-kelas dengan lebih akurat dalam kondisi tertentu.

Hasil pada data validasi.

Akurasi kelas pada data validasi

Pada data validasi, akurasi untuk *class output* (*val_class_output_accuracy*) menunjukkan hasil yang cenderung stagnan. Nilai akurasi ini tidak pernah lebih tinggi dari 0.65 sepanjang 30 epoch pelatihan. Bahkan pada beberapa epoch, seperti pada epoch 28 dan 29, nilai akurasi

menurun sedikit menjadi 0.6333. hal ini menunjukkan bahwa meskipun model dapat belajar dengan baik pada data pelatihan, kemampuan model untuk mengeneralisasi pada data yang tidak terlihat sebelumnya masih terbatas.

Bounding box loss pada data validasi

Nilai *bbox output loss* pada data validasi juga menunjukkan hasil yang tidak membaik secara signifikan selama pelatihan. nilai *loss* ini tetap tinggi di atas 32 ribu pada sebagian besar epoch, yang menunjukkan bahwa model masih kesulitan dalam memprediksi lokasi bounding box dengan tepat pada data validasi. Bahkan, meskipun ada sedikit penurunan dalam nilai *loss* selama epoch-epoch tertentu, model tidak menunjukkan perbaikan yang substansial.

Pengamatan tambahan

Pengaruh learning rate

Learning rate yang di gunakan dalam pelatihan adalah 0.0001, yang terbilang cukup kecil. hal ini mungkin menjadi faktor yang memperlambat laju konvergensi model, yang terlihat dari penurunan *loss* yang relatif lambat selama pelatihan. model mungkin membutuhkan lebih banyak epoch atau perubahan pada learning rate untuk mencapai konvergensi yang lebih baik dan meningkatkan kerja.

Penggunaan model check point

Model check point di gunakan selama pelatihan untuk menyimpan model terbaik setiap kali performanya meningkat. Meskipun demikian, tidak ada peningkatan signifikan dalam akurasi pada data validasi yang menunjukkan bahwa meskipun model di simpan pada setiap iterasi terbaik, ia tetap tidak dapat mengeneralisasi dengan baik ke data validasi.

Hasil validasi gambar pelatihan



Hasil akurasi training

4/4 13ms/step

Confusion Matrix:

```
[[ 13 22]
 [  0 25]]
```

Classification Report:

	precision	recall	f1-score	support
duduk sehat dalam kesehatan	1.00	0.37	0.54	35
duduk tidak sehat dalam kesehatan	0.53	1.00	0.69	25
accuracy			0.63	60
macro avg	0.77	0.69	0.62	60
weighted avg	0.80	0.63	0.61	60

Kesimpulan dari hasil pelatihan

Secara keseluruhan, meskipun model menunjukkan kemampuan yang relatif baik dalam memprediksi kelas pada data pelatihan, kemampuan model untuk mengeneralisasi ke data validasi masih terbatas. hal ini tercermin dari fluktuasi dan stagnasi dalam akurasi kelas serta tingginya nilai *bbox output loss* pada data validasi. kinerja model yang tidak mengalami peningkatan signifikan ini menandakan perlunya penyesuaian lebih lanjut pada parameter model, seperti learning rate, atau penggunaan teknik lain untuk meningkatkan kemampuan generalisasi model.

D. Kesimpulan

- Teknologi MobileNet Single Shot Detector (SSD) memiliki potensi besar dalam mendeteksi dan mengklasifikasikan gerakan duduk pada karyawan di tempat kerja. Model ini terbukti efektif dalam mengenali berbagai postur duduk yang ergonomis maupun tidak ergonomis secara cepat dan akurat, dengan memanfaatkan teknologi computer vision yang ringan dan cocok

- b) Confusion matrix dengan epoch 100 menggambarkan distribusi prediksi model untuk setiap kelas, dengan diagonal utama menunjukkan jumlah prediksi yang benar untuk masing-masing kelas. Precision, recall, dan f1-score untuk setiap kelas. Untuk kelas duduk sehat dalam kesehatan, Precision adalah 0.97, recall 0.91, dan f1-score 0.94. Pada kelas duduk tidak sehat dalam kesehatan precision mencapai 0.89, recall 0.96, dan f1-score 0.92. Rata-rata akurasi keseluruhan model adalah 0.93 dengan precision rata-rata (macro avg) 0.93, recall rata-rata 0.94 dan f1-score rata-rata 0.93

E. Saran

Berdasarkan hasil penelitian ini, penulis merekomendasikan agar penelitian berikutnya lebih lanjut dapat menguji penggunaan MobileNet SSD di berbagai jenis pekerjaan dengan beragam kegiatan fisik. Hal ini bisa mencakup pekerjaan di kantor, di pabrik, atau pekerjaan dengan mobilitas tinggi, untuk melihat bagaimana teknologi ini dapat diterapkan secara lebih luas. Dan untuk meningkatkan pemantauan postur duduk, penelitian lebih lanjut bisa menggabungkan teknologi wearable seperti pelacak postur atau perangkat sensor di tubuh karyawan, yang memungkinkan pemantauan postur lebih akurat dan berbasis data yang lebih kaya.

F. Referensi

- AGustsa, A. H., & Permadi, G. S. (2023). Sistem Deteksi Bahasa Isyarat Secara Realtime Dengan Tensorflow Object Detection dan Python Menggunakan Metode Convolutional Neural Network. *Inovate: Jurnal Ilmiah Inovasi Teknologi Informasi*, 7(2), 37-46.
- Amin, N. A., Muchsin, A. H., Khalid, N. F., & Sam, A. D. P. (2023). Hubungan Lama dan Posisi Duduk dengan Kejadian Low Back Pain (LBP) pada Mahasiswa di Fakultas Kedokteran Universitas Muslim Indonesia Angkatan 2019. *Fakumi Medical Journal: Jurnal Mahasiswa Kedokteran*, 3(4), 269-277.
- Iskandar, M. M., Quzwain, F., Gading, P. W., & Tarawifa, S. (2020). Penyuluhan Posisi Duduk Yang Benar untuk Kesehatan Punggung Bagi Masyarakat Awam. *Medical Dedication (medic): Jurnal Pengabdian kepada Masyarakat FKIK UNJA*, 3(2).
- Janna, S. N. R. (2021). *Hubungan lama duduk dan posisi duduk terhadap keluhan nyeri punggung bawah pada karyawan rektorat universitas hasanuddin makassar* (Doctoral dissertation, Universitas Hasanuddin).
- Supriyanto, Arif, Noor, N., Prastyaningsih, Y., (2023) Komputer dan Bisnis, Teknologi Rekayasa Komputer Jaringan, and Politeknik Negeri Tanah Laut. 2023. "Penerapan Sistem Tertanam Untuk Deteksi Posisi Duduk." *Konvergensi* 19 (1): 21-29. [https://jurnal.untagsby.ac.id/index.php/KONVERGENSI/article/view/8123%0Ahttps://jurnal.un tag-sby.ac.id/index.php/KONVERGENSI/article/view/8123/5683](https://jurnal.untagsby.ac.id/index.php/KONVERGENSI/article/view/8123%0Ahttps://jurnal.un%20tag-sby.ac.id/index.php/KONVERGENSI/article/view/8123/5683).