

Klasifikasi Penyakit Daun Kentang dengan Metode CNN dan RNN

JIHAN RIHADATUL AISYA, AGI PRASETIADI

Institut Teknologi Telkom Purwokerto, Indonesia
Email: 18102091@ittelkom-pwt.ac.id

ABSTRAK

Banyak jenis penyakit dan hama yang menyerang tanaman kentang masih dijumpai oleh para petani di Indonesia. Padahal kentang merupakan jenis sayuran yang tergolong familiar dan termasuk makanan pokok utama. Diperlukan metode klasifikasi untuk menggambarkan dan membandingkan hasil akurasi penyakit kentang. Dalam penelitian ini akan melakukan *image processing* dengan teknik *transfer learning* dan dilakukan augmentasi data, menggunakan metode klasifikasi *Convolutonal Neural Network (CNN)* dengan jenis VGG16 dan ResNet50 dan *Recurrent Neural Network (RNN)* jenis LSTM untuk mengklasifikasi dan membandingkan hasil akurasi penyakit daun kentang seperti, *Late blight* (Busuk Daun), *Early blight* (Bercak Daun), Daun Berlubang, Daun Menggulung dan Daun sehat. Pada penelitian ini mencari model terbaik dengan arsitektur VGG16 *dense layer* 75 memperoleh nilai tertinggi dengan nilai *precision* 0.87, *recall* 0.86, *accuracy* 0.86 dan *f1-score* 0.86, sedangkan untuk model dengan arsitektur VGG16 dan LSTM *dense layer* 100 memperoleh hasil terendah dengan nilai *precision* 0.21, *recall* 0.24, *accuracy* 0.24 dan *f1-score* 0.21.

Kata kunci: *Deep Learning*, LSTM, Resnet50, Tanaman Kentang, *Transfer learning*, VGG16

ABSTRACT

Many types of diseases that attack potato plants are still found by farmers in Indonesia. Whereas potato is a type of vegetable that is quite familiar and includes the main staple food. A classification method is needed to describe and compare the results of potato disease accuracy. In this study, image processing with transfer learning techniques and data augmentation will be carried out, using the CNN classification method with VGG16 and ResNet50 types and RNN LSTM types to classify and compare the results of potato leaf disease accuracy in five category In this study, looking for the best model with VGG16 dense layer architecture 75 obtained the highest value with a precision value of 0.87, recall 0.86, Accuracy 0.86, and f1-score 0.86, while the model with VGG16 architecture and LSTM dense layer 100 obtained the lowest result with a precision value of 0.21, recall 0.24, Accuracy 0.24 and f1-score 0.21.

Keywords: *Deep Learning*, LSTM, Resnet50, Potato Plants, *Transfer learning*, VGG16

1. PENDAHULUAN

Penyakit dan hama yang menyerang pada tanaman kentang merupakan salah satu bencana bagi para petani kentang. Bagi petani Indonesia sendiri menanggulangi penyakit dan hama masih sangat berupaya agar tidak terjadi gagal panen dalam industri pertanian. Padahal di negara Indonesia komoditi sayuran jenis umbi-umbian terbesar adalah kentang dengan nama latin *Solanum Tuberosum L.* Tercatat dalam Badan Pusat Statistik Indonesia pada tahun 2020 mengalami pertumbuhan salah satunya dipengaruhi oleh komoditas hortikultura yang mengalami pertumbuhan sekitar 7,85% karena adanya kenaikan peminatan buah dan sayur selama pandemi Covid-19 dan kentang menjadi salah satu komoditas hortikultura yang mengalami kenaikan permintaan (**Izudin, 2021**). Kabupaten Banjarnegara menjadi salah satu kabupaten yang ada di Jawa Tengah menyumbang komoditas pertanian kentang terbanyak di Jawa Tengah dengan luas panen selama 2020 mencapai 6.347 Ha dan total produksi sebanyak 1.149.576 Ton (**BPS, 2020**).

Dari data produksi yang semakin meningkat namun faktanya banyak kendala dalam pengelolaannya. Beberapa penyakit yang sering menyerang dari pada tanaman kentang seperti penyakit becak coklat atau hawar dini (*early blight*), busuk daun (*late blight*) yang sering menyerang pada daun kentang (**Asif, dkk, 2020**). Dibutuhkan metode yang mampu menggambarkan dan membandingkan hasil akurasi. Penelitian ini akan membagi menjadi 5 kategori penyakit yang menyerang daun kentang ialah, Busuk Daun, Becak Daun, Daun Berlubang, Daun sehat dan Daun Sakit yang didapatkan dari pemotongan gambar. Dalam penelitian sebelumnya hanya membagi menjadi 3 kategori dan *dataset* yang diperoleh melalui situs Kaggle.

Oleh karena itu untuk memudahkan klasifikasi peneliti menggunakan metode CNN yang mampu mengenali objek gambar (Ilahiyah and Nilogiri 2018) dan metode RNN yang dapat menghemat memori (*feedback loop*) sehingga dapat mendeteksi secara akurat (**Cheng and Liu, 2017**). Penelitian ini menggunakan teknik *transfer learning* VGG16 dan ResNet serta ditambah dengan LSTM yang belum ada di penelitian sebelumnya dalam kasus ini dan pengambilan dataset secara langsung kemudian dilakukan pemotongan gambar, mengklasifikasi menjadi 5 kelas dan augmentasi data.

2. METODE PENELITIAN

Metode yang digunakan pada penelitian ini menggunakan CNN dan RNN dengan teknik . Jenis *transfer learning* yang digunakan VGG16, ResNet50, VGG16-LSTM dan Resnet50-LSTM, serta dilakukan pengujian menggunakan *confusion matrix* agar mengetahui hasil yang terbaik. Untuk lebih akan dijelaskan pada berikut ini:

2.1 Penelitian Terdahulu

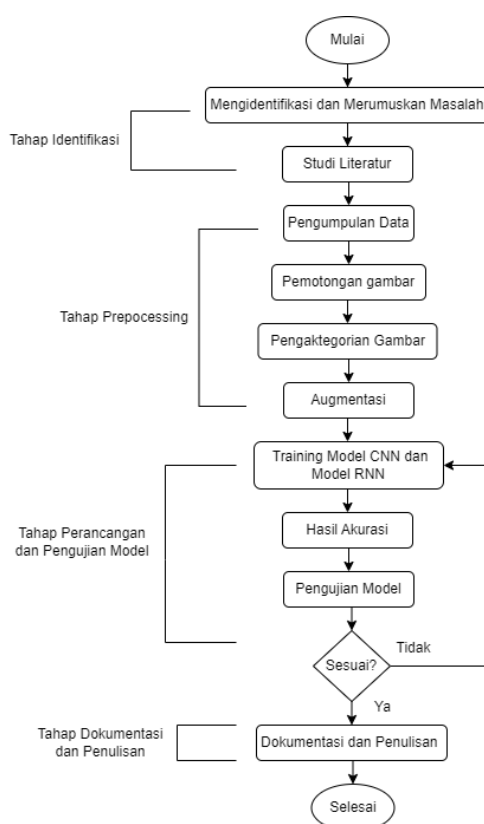
Penelitian ini bertujuan untuk membandingkan hasil klasifikasi pada penyakit daun tanaman kentang menggunakan kecerdasan buatan yang sudah banyak dilakukan dan diterapkan pada berbagai bidang teknologi dan menunjukkan manfaat dari kecerdasan buatan yaitu mampu berpikir layaknya otak manusia untuk menyelesaikan masalah, salah satunya untuk memprediksi penyakit pada daun kentang. Adapun beberapa jurnal rujukan yang menjadi referensi pada penelitian ini.

Pada yang dilakukan oleh Soojin Lee, Ramy Hussein, Martin J. McKeown pada tahun 2019 yang berjudul "*A Deep Convolutional-Recurrent Neural Network Architecture for Parkinson's Disease EEG Classification*" menjelaskan bahwa masalah pada penerapan EGG dalam merekam

secara non-invasif sebagai alat diagnosa penyakit Parkinson masih sulit digunakan secara efektif untuk diagnosis penyakit tersebut sehingga dilakukan perhitungan akurasi menggunakan metode CNN, RNN dan LSTM sehingga penelitian ini menghasilkan akurasi mencapai 96,9%, presisi 100%, dan recall 93,4% dibandingkan dengan rekaman EEG (Lee, Hussein, and McKeown 2019).

Penelitian berikutnya yang dilakukan oleh Md. Al-Amin, Tasfia Anika Bushra dan Md Nazmul Hoq pada tahun 2019 yang berjudul "*Prediction of Potato Disease from Leaves using Deep Convolution Neural Network towards a Digital Agricultural System*" penelitian ini menganalisis diagnosa penyakit daun kentang menggunakan metode CNN bertujuan agar petani kentang dapat mendiagnosa penyakit kentang secara dini dan mengurangi gagal panen. Hasil dari penelitian ini menunjukkan akurasi sebesar 98,33% dalam mendeteksi penyakit daun kentang (Al-Amin, Bushra, and Hoq 2019).

2.2 Alur Penelitian




Gambar 1. Alur Penelitian

Penelitian ini terdiri dari tahap identifikasi, tahap *preprocessing*, tahap perancangan dan pengujian model, terakhir tahap dokumentasi.

2.3 CNN (*Convolutional Neural Network*)


Convolutional Neural Network (CNN) salah satu arsitektur yang dapat mengenali suatu indikasi prediktif suatu objek berupa gambar, teks, potongan suara, dan sebagainya. Metode ini bekerja untuk mengurangi kompleksitas perhitungan yang didasari dengan *weight sharing* dan *sliding window* (Bean n.d.)(Rozaqi, dkk, 2021).



Gambar 2. Arsitektur CNN

2.5 VGG16 (Visual Geometry Group 16)

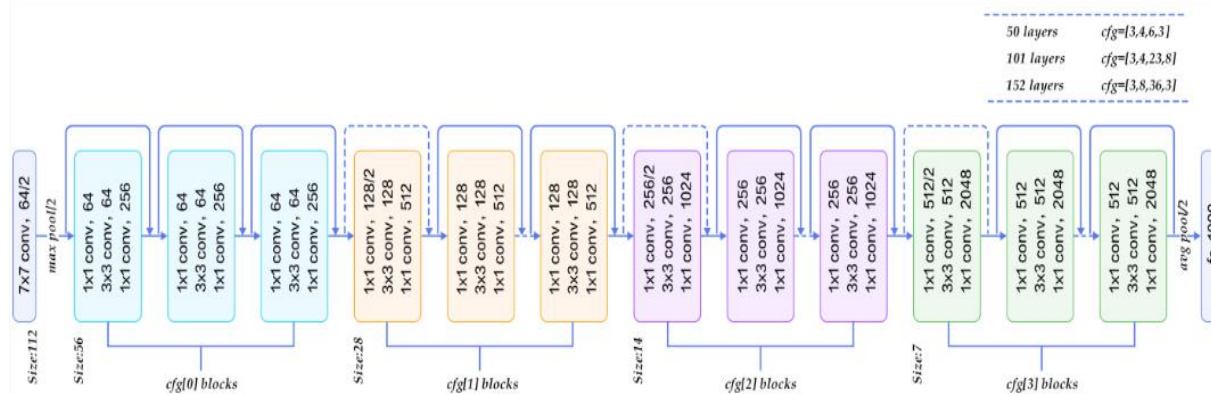
VGG dikembangkan oleh Simonyan dan Zisserman. VGG sendiri terdiri dari 16 lapisan konvolusi yang arsitekturnya seragam atau teratur. Memiliki konvolusi 3x3 dengan banyak filter. Kelebihan dari arsitektur VGG ini dalam mengekstraksi fitur dari gambar secara mendalam, topologi yang homogen dan sederhana. Namun terdapat kelemahan dari arsitektur ini adalah biaya komputasi yang terlalu tinggi karena penggunaan sekitar 140 juta parameter (Alzubaidi et al. 2021).



Gambar 3. Arsitektur VGG16

2.6 ResNet50

Residual Network atau ResNet diperkenalkan oleh Kaiming He yang memenangkan ILSVRC (ImageNet Large Scale Visual Recognition Challenge) pada tahun 2015. Tujuan dari arsitektur ini merancang *ultra-deep network* yang bebas dari masalah gradien yang hilang. ResNet50 merupakan jenis yang paling umum yang digunakan yang terdiri dari 49 lapisan konvolusi ditambah satu lapisan Fully-Connected Layer (Asif, dkk, 2020).




Gambar 4. Arsitektur ResNet50

2.7 RNN (Recurrent Neural Network)

Recurrent Neural Network (RNN) sebuah metode yang mampu merepresentasikan atau memfokuskan data sekuensial. RNN memiliki kemampuan untuk menyimpan memori (*feedback loop*) sehingga memungkinkan dapat mengenali pola data dengan baik dan membuat prediksi yang akurat (Aditya, 2018). Tugas dari RNN sendiri adalah menemukan hubungan antara *input* saat ini dan *input* yang diterapkan sebelumnya. Pada penerapan RNN


biasanya pada konvolusi 2 dimensi diubah menjadi 3 dimensi agar mempermudah proses dibagian base model.



Gambar 5. Arsitektur RNN

2.8 LSTM (Long Short-Term Memory)

Long Short-Term Memory salah satu modifikasi RNN dengan menambahkan *memory-cell* yang menyimpan memori dalam jangka panjang. LSTM diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997, dan sekarang sudah banyak orang menyempurnakan dan mempopulerkan metode ini (Lee, dkk, 2019). LSTM dibuat untuk handle permasalahan pada RNN yaitu *vanishing gradient* saat data diproses secara sekuensial yang panjang yang menyebabkan RNN sulit menangkap *long term dependencies* (Hanifa, dkk, 2021).




Gambar 6. Arsitektur LSTM

2.9 Transfer Learning

Transfer learning adalah teknik yang memanfaatkan *training* yang sudah ada sebelumnya (*pretrained model*) yang dapat digunakan untuk mengklasifikasi *dataset* baru tanpa melakukan *training* baru (Alzubaidi, dkk, 2021). Jenis pembelajaran pretrained model ini paling sering digunakan pada *deep learning*. *Transfer learning* juga perlu dilakukan adaptasi pada bagian akhir model (Junaedi, 2020). Keuntungan menggunakan *transfer learning* adalah dapat menghemat waktu pelatihan, kinerja jaringan saraf lebih baik, dan tidak memerlukan data yang banyak.

2.10 Confusion Matrix

Confusion matrix adalah salah satu teknik mengukur kinerja suatu model klasifikasi. Asal metode ini terdapat ulasan yang digunakan untuk membandingkan hasil kinerja yang dilakukan oleh suatu model dengan hasil kinerja klasifikasi yang seharusnya (Fakhri, dkk, 2019). Terdapat empat istilah pengukuran kinerja *confusion matrix* yang dapat merepresentasi hasil proses klasifikasi yaitu, *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)* dan *False Negative (FN)*. Nilai *True Negative (TN)* adalah jumlah data negatif yang terdeteksi dengan benar, sedangkan *False Positive (FP)* adalah data negatif namun terdeteksi sebagai data positif (Mahmud, dkk, 2019).



Gambar 7. Confusion Matrix

3. HASIL DAN PEMBAHASAN

3.1 Penerapan Model dan Training Model

Penelitian dilakukan dengan menggunakan arsitektur VGG16, ResNet50, VGG16-LSTM dan Resnet50-LSTM. Semua arsitektur menggunakan aktivasi ReLU pada Dense layer, kemudian menggunakan aktivasi Softmax pada Prediction Layer. Untuk model compile semua arsitektur menggunakan optimisasi jenis ADAM.

Selama pengujian model berlangsung, hasil proses training atau pelatihan data agar terbentuk sebuah model yang dapat digunakan pada tahap selanjutnya yaitu proses validation atau testing. Dalam proses training ini terdapat dua parameter penilaian yakni nilai accuracy dan loss. Accuracy merupakan nilai model prediksi yang benar, sedangkan nilai loss merupakan nilai model yang memprediksi keliru. Apabila nilai prediksi dari model bisa dikatakan sempurna maka nilai loss yang diperoleh harus mendekati 0 atau bernilai sama dengan 0 dan nilai accuracy yang diperoleh harus mendekati 1 atau bernilai sama dengan 1. Tujuan dari training model dalam penelitian ini untuk mencari nilai accuracy yang tinggi dan tidak terjadi underfitting ataupun overfitting. Dalam penelitian ini semua pelatihan model dilakukan dengan memakai data training sebanyak 4800 gambar dan data validation sebanyak 600 gambar dengan base model yang telah ditentukan sebelumnya, dense layer 25, 50, 75 dan 100, menggunakan 30 epoch, batch size 5 dan gambar berukuran 128x128 pixel. Dalam pencarian skema model hasil grafik performa akurasi train dan validasi dapat dilihat pada Tabel 1 dibawah ini.

Tabel 1. Skema Pencarian Arsitektur dan Hasil Training

Model	Arsitektur	Akurasi	Val Akurasi
Model 1	VGG16 dense layer 25	0,9812	0,95
Model 2	VGG16 dense layer 50	0,9819	0,9167
Model 3	VGG16 dense layer 75	0,997	0,9583
Model 4	VGG16 dense layer 100	1	0,9667
Model 5	ResNet50 dense layer 25	0,931	0,8792
Model 6	ResNet50 dense layer 50	0,9903	0,9646
Model 7	ResNet50 dense layer 75	0,9986	0,9708
Model 8	ResNet50 dense layer 100	0,994	0,9708
Model 9	VGG16 + LSTM dense layer 25	0,3727	0,3792
Model 10	VGG16 + LSTM dense layer 50	0,4833	0,4146
Model 11	VGG16 + LSTM dense layer 75	0,3903	0,3812
Model 12	VGG16 + LSTM dense layer 100	0,4262	0,3875
Model 13	ResNet50 + LSTM dense layer 25	0,3072	0,3396
Model 14	ResNet50 + LSTM dense layer 50	0,4178	0,3812
Model 15	ResNet50 + LSTM dense layer 75	0,415	0,4375
Model 16	ResNet50 + LSTM dense layer 100	0,3088	0,3042

Dari Tabel 1 dapat dilihat untuk hasil pengujian grafik performa skema akurasi tertinggi diperoleh model 4 dengan arsitektur VGG *dense layer* 100 dan akurasi terendah diperoleh model 16 dengan arsitektur ResNet50 + LSTM *dense layer* 100.

Hasil dari pelatihan atau *training* setiap model disimpan menjadi *file* dengan format .h5 yang kemudian dapat dilanjutkan untuk pengujian model. Berikut adalah tabel rincian penggunaan memori pada setiap model. Diperoleh penggunaan memori yang paling sedikit adalah model 2 dengan arsitektur VGG16 *dense layer* 50 dan yang paling besar dalam penggunaan memori adalah model 8 dengan arsitektur ResNet50 *dense layer* 100.

Tabel 2. Penggunaan Memori Model

Model	Arsitektur	Penggunaan Memori
Model 1	VGG16 <i>dense layer</i> 25	61.4 MB
Model 2	VGG16 <i>dense layer</i> 50	60.9 MB
Model 3	VGG16 <i>dense layer</i> 75	66.3 MB
Model 4	VGG16 <i>dense layer</i> 100	68.8 MB
Model 5	ResNet50 <i>dense layer</i> 25	105 MB
Model 6	ResNet50 <i>dense layer</i> 50	114 MB
Model 7	ResNet50 <i>dense layer</i> 75	124 MB
Model 8	ResNet50 <i>dense layer</i> 100	134 MB
Model 9	VGG16 + LSTM <i>dense layer</i> 25	59 MB
Model 10	VGG16 + LSTM <i>dense layer</i> 50	59.1 MB
Model 11	VGG16 + LSTM <i>dense layer</i> 75	59.2 MB
Model 12	VGG16 + LSTM <i>dense layer</i> 100	59.4 MB
Model 13	ResNet50 + LSTM <i>dense layer</i> 25	94.7 MB
Model 14	ResNet50 + LSTM <i>dense layer</i> 50	94.8 MB
Model 15	ResNet50 + LSTM <i>dense layer</i> 75	95 MB
Model 16	ResNet50 + LSTM <i>dense layer</i> 100	95.2 MB

3.2 Hasil Pengujian Model

Setelah proses pelatihan atau *training* dilakukan kemudian dilakukan pengujian model atau testing dengan menggunakan *Confusion matrix* pada masing-masing model. Pengujian dilakukan dengan menggunakan *dataset* baru yang tidak di *training*. Data testing sendiri terdiri dari 5 kategori yaitu Bukan Daun, Daun Bercak, Daun Berlubang, Daun Busuk dan Daun Sehat yang masing-masing kategori terdiri 120 gambar dengan ukuran 128x128 *pixel* sehingga jumlah total data test sebanyak 600 gambar.

Perolehan nilai *confusion matrix* dari masing-masing model yang terdiri dari nilai *precision*, *recall*, *accuracy* dan *f1-score*. dapat dilihat pada tabel 3 berikut.

Tabel 3. Hasil Model Confusion Matrix

Model	Arsitektur	Precision	Recall	Accuracy	F1- Score
Model 1	VGG16 <i>dense layer</i> 25	0.82	0.82	0.82	0.81
Model 2	VGG16 <i>dense layer</i> 50	0.82	0.80	0.80	0.80
Model 3	VGG16 <i>dense layer</i> 75	0.87	0.86	0.86	0.86
Model 4	VGG16 <i>dense layer</i> 100	0.86	0.85	0.85	0.85
Model 5	ResNet50 <i>dense layer</i> 25	0.77	0.70	0.70	0.68

Model 6	ResNet50 <i>dense layer</i> 50	0.83	0.81	0.81	0.81
Model 7	ResNet50 <i>dense layer</i> 75	0.80	0.74	0.74	0.73
Model 8	ResNet50 <i>dense layer</i> 100	0.84	0.81	0.81	0.81
Model 9	VGG16 + LSTM <i>dense layer</i> 25	0.33	0.32	0.32	0.31
Model 10	VGG16 + LSTM <i>dense layer</i> 50	0.34	0.34	0.34	0.34
Model 11	VGG16 + LSTM <i>dense layer</i> 75	0.34	0.34	0.34	0.33
Model 12	VGG16 + LSTM <i>dense layer</i> 100	0.21	0.24	0.24	0.21
Model 13	ResNet50 + LSTM <i>dense layer</i> 25	0.34	0.32	0.32	0.30
Model 14	ResNet50 + LSTM <i>dense layer</i> 50	0.32	0.32	0.32	0.32
Model 15	ResNet50 + LSTM <i>dense layer</i> 75	0.31	0.31	0.31	0.30
Model 16	ResNet50 + LSTM <i>dense layer</i> 100	0.32	0.29	0.28	0.23

Dari tabel 3 menunjukkan hasil dari *confusion matrix* dari 16 model yang telah dicoba. Diantara 16 model tersebut memiliki nilai *precision*, *recall*, *accuracy* dan f1-score yang berbeda-beda berdasarkan arsitekturnya. Model 3 dengan arsitektur VGG16 *dense layer* 75 memperoleh nilai tertinggi dengan nilai *precision* 0.87, *recall* 0.86, *accuracy* 0.86 dan f1-score 0.86, kemudian model 4 dengan arsitektur VGG16 *dense layer* 100 berada di urutan kedua setelah model 3 dengan nilai *precision* 0.86, *recall* 0.85, *accuracy* 0.85 dan f1-score 0.85. Untuk hasil *confusion matrix* terendah adalah model 12 dengan arsitektur VGG16 + LSTM *dense layer* 100 dengan nilai *precision* 0.21, *recall* 0.24, *accuracy* 0.24 dan f1-score 0.21.

4. KESIMPULAN

Kesimpulan dari penelitian ini berhasil mengklasifikasikan penyakit daun kentang yang terdiri dari 5 kategori yaitu Bukan Daun, Daun Bercak, Daun Berlubang, Daun Busuk dan Daun Sehat menggunakan metode *Convolutional Neural Network* (CNN) dan metode *Recurrent Neural Network* (RNN). Penerapan model yang digunakan arsitektur VGG16, ResNet50, VGG16-LSTM dan Resnet50-LSTM. Semua arsitektur menggunakan aktivasi RelU pada *Dense layer* 25, 50, 75 dan 100, kemudian menggunakan aktivasi Softmax pada *Prediction Layer*. Untuk model compile semua arsitektur menggunakan optimalisasi jenis ADAM. Hasil kinerja model terbaik diperoleh model 3 dengan arsitektur VGG16 *dense layer* 75 memperoleh nilai tertinggi dengan nilai *precision* 0.87, *recall* 0.86, *accuracy* 0.86 dan f1-score 0.86 dengan penggunaan memori sebesar 66.3 MB. Sedangkan untuk kinerja model terendah diperoleh model 12 dengan arsitektur VGG16 + LSTM *dense layer* 100 dengan nilai *precision* 0.21, *recall* 0.24, *accuracy* 0.24 dan f1-score 0.21 dengan penggunaan memori sebanyak 59.4 MB. Nilai *confusion matrix* rendah disebabkan karena model yang menggunakan LSTM perlu adanya penambahan *dataset* yang bervariasi dan lebih banyak sehingga terjadi *underfitting*.

DAFTAR RUJUKAN

Aditya, Yanuar R.. (2018). Recurrent Neural Network (RNN). *Universitas Gadjah Mada Menara Ilmu Machine Learning*. Retrieved February 20, 2022 (<https://machinelearning.mipa.ugm.ac.id/2018/07/01/recurrent-neural-network-rnn/>).

- Al-Amin, Md, Tasfia Anika Bushra, and Md Nazmul Hoq. (2019). Prediction of Potato Disease from Leaves Using Deep Convolution Neural Network towards a Digital Agricultural System. *1st International Conference on Advances in Science, Engineering and Robotics Technology 2019, ICASERT 2019* 2019(Icasert), (pp. 1–5). doi: 10.1109/ICASERT.2019.8934933.
- Alzubaidi, Laith, Jinglan Zhang, Amjad J. Humaidi, Ayad Al-Dujaili, Ye Duan, Omran Al-Shamma, J. Santamaría, Mohammed A. Fadhel, Muthana Al-Amidie, and Laith Farhan. (2021). *Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions*. Vol. 8. Springer International Publishing.
- Asif, Md Khalid Rayhan, Md Asfaqur Rahman, and Most Hasna Hena. (2020). CNN Based Disease Detection Approach on Potato Leaves. *Proceedings of the 3rd International Conference on Intelligent Sustainable Systems, ICISS 2020*, (pp. 428–32). doi: 10.1109/ICISS49785.2020.9316021.
- Bean, John C. (n.d.) "Arsitektur Neural Network." *Book Architectural Neural Network*. BPS. (2020). *Luas Panen Dan Produksi Kentang 2018-2020*.
- Cheng, Danni, and Manhua Liu. (2017). "Combining Convolutional and Recurrent Neural Networks for Alzheimer's Disease Diagnosis Using PET Images. *IST 2017 - IEEE International Conference on Imaging Systems and Techniques, Proceedings 2018-Janua(Mci)*, (pp. 1–5). doi: 10.1109/IST.2017.8261461.
- Fakhri, Iman Nur, Jondri, and Rian Febrian Umbara. (2019). Analisis Sentimen Pada Kuisiner Kepuasan Terhadap Layanan Dan Fasilitas Kampus Universitas Dengan Menggunakan Klasifikasi Support Vector Machine (SVM). *E-Proceeding of Engineering*, 6(2), 8682–91.
- Hanifa, Aini, Sugih Ahmad Fauzan, Muhammad Hikal, and Muhammad Bahrul Ashfiya. (2021). Perbandingan Metode LSTM Dan GRU (RNN) Untuk Klasifikasi Berita Palsu Berbahasa Indonesia. *Dinamika Rekayasa*, 17(1), 33. doi: 10.20884/1.dr.2021.17.1.436.
- Ilahiyah, Sarirotul, and Agung Nilogiri. (2018). Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *JUSTINDO (Jurnal Sistem Dan Teknologi Informasi Indonesia)*, 3(2), 49–56.
- Izudin, Azam. (2021). Potensi Ekpor Dan Produksi Kentang Indonesia Menuju Modern. *Retizen.Republika.Co.Id*. Retrieved January 4, 2022 (<https://retizen.republika.co.id/posts/14518/potensi-ekpor-dan-produksi-kentang-indonesia-menuju-modern>).
- Junaedi, Fadlur dan Rochmandan Hartarto. (2020). Implementasi Transfer Learning Untuk Identifikasi Ordo Tumbuhan Melalui Daun. *I(6)*, 672–79.

- Lee, Soojin, Ramy Hussein, and Martin J. McKeown. (2019). A Deep Convolutional-Recurrent Neural Network Architecture for Parkinson's Disease EEG Classification. *GlobalSIP 2019 - 7th IEEE Global Conference on Signal and Information Processing, Proceedings*, (pp. 14–17). doi: 10.1109/GlobalSIP45357.2019.8969309.
- Mahmud, Kamal Hasan, Adiwijaya, and Said Al Faraby. (2019). Prosiding Klasifikasi Citra Multi-Kelas Menggunakan Convolutional Neural Network. *E-Proceeding of Engineering*, 6(1), 2127–36.
- Rozaqi, Abdul Jalil, Andi Sunyoto, and M. rudyanto Arief. (2021). Deteksi Penyakit Pada Daun Kentang Menggunakan Pengolahan Citra Dengan Metode Convolutional Neural Network. *Creative Information Technology Journal*, 8(1), 22. doi: 10.24076/citec.2021v8i1.263.