

Identifikasi Persediaan Makanan di dalam Lemari Pendingin Berbasis Raspberry Pi Menggunakan Algoritma *Deep Learning*

Faisal Candrasyah Hasibuan^{1*}, Andri Ulus Rahayu²

Program Studi S1 Teknik Komputer Universitas Telkom, Bandung

Program Studi Teknik Elektro Universitas Siliwangi, Tasikmalaya

¹faicanhasfcb@telkomuniversity.ac.id

²andriulusr@unsil.ac.id

Abstrak—Sistem ini dibuat atas dasar permasalahan yang terjadi dalam kehidupan sehari-hari, salah satunya yaitu tidak terpantaunya persediaan bahan makanan di lemari pendingin. Ketika dibutuhkan suatu bahan makanan dari lemari pendingin dan ternyata tidak ada, maka akan menjadi masalah. Oleh karena itu, dibuatlah sebuah sistem yang mampu mengidentifikasi objek makanan di dalam lemari pendingin. Masukan dari sistem ini berupa foto objek makanan yang diambil menggunakan Raspberry Pi Camera dan terhubung langsung dengan Raspberry Pi di dalam lemari pendingin. Setelah diproses dengan algoritma pembelajaran mesin, maka keluaran yang dihasilkan berupa identifikasi objek makanan yang terdapat di dalam lemari pendingin tersebut. Objek makanan yang diuji berupa pisang, mentimun, brokoli, dan jeruk. Dari hasil pengujian, terlihat bahwa program mengidentifikasi objek dengan benar pada objek pisang dan jeruk yang ditunjukkan dengan confidence level tertinggi sebesar 56,98% dan 45,88%. Identifikasi objek mentimun dikenali sebagai zukini dengan confidence level tertinggi sebesar 78,61%. Adapun identifikasi objek paling rendah terdapat pada objek brokoli dengan confidence level kurang dari 1%.

Kata kunci: *Deep Belief Network, Deep Learning, Lemari Pendingin, Machine learning, Raspberry Pi.*

Abstract—This system is made based on problems that occur in everyday life, one of which is the lack of monitoring of food supplies in the refrigerator. It will be a problem when there is a need for a food item from the refrigerator and it does not exist. Therefore, a system is made that can identify food objects in the refrigerator. The input from this system is in the form of photos of food objects taken using the Raspberry Pi Camera and connected directly to the Raspberry Pi in the refrigerator. After being processed with machine learning algorithms, the resulting output identifies food objects in the refrigerator. The food objects tested were bananas, cucumbers, broccoli, and oranges. The test results show that the program correctly identified the object on the banana and orange object, which was indicated by the highest confidence levels of 56.98% and 45.88%, respectively. The identification of the cucumber object was recognized as zucchini with the highest confidence level of 78.61%.

The lowest object identification was found in broccoli, with a confidence level of less than 1%.

Keywords: *Deep Belief Network, Deep Learning, Deep Belief Network, Machine learning, Raspberry Pi, Refrigerator.*

I. PENDAHULUAN

Sistem ini dibuat atas dasar permasalahan yang terjadi dalam kehidupan sehari-hari. Salah satunya yaitu tidak terkontrolnya persediaan bahan makanan di lemari pendingin. Pengguna harus melihat secara langsung untuk mengetahui sisa persediaan bahan makanan yang disimpan[1]. Masalah akan timbul jika baru diketahuinya persediaan makanan yang dibutuhkan telah habis atau ada bahan makanan yang sudah terlalu lama disimpan. Oleh karena itu, dibuatlah sebuah sistem kecerdasan buatan yang mampu mengidentifikasi objek makanan di dalam lemari pendingin.

Beberapa penelitian yang menggunakan algoritma kecerdasan buatan, pembelajaran mesin, dan pengenalan citra, di antaranya ada yang memanfaatkan jaringan syaraf tiruan untuk mengidentifikasi tingkat kematangan buah pisang[2]. Ada pula yang memanfaatkan *deep belief network* untuk pengenalan plat nomor kendaraan [3]. Raspberry Pi digunakan sebagai pengendali dan pemroses utama karena sudah paket lengkap, memiliki kemampuan GPIO seperti Arduino, tetapi memiliki prosesor *multicore* yang mendukung komputasi kompleks. Penelitian-penelitian yang menggunakan Raspberry Pi untuk keperluan sistem otomatisasi ataupun pembelajaran mesin seperti sistem pemberi pakan kucing otomatis yang dapat dimonitor melalui aplikasi *mobile*[4], membedakan benda berdasarkan warna dan bentuk[5], pemrosesan gambar untuk sistem kamera keamanan[6], dan pendeteksi sidik jari[7].

Masukan dari sistem ini adalah foto objek makanan yang diambil menggunakan Raspberry Pi Camera yang terhubung langsung dengan Raspberry Pi di dalam lemari pendingin. Keluaran yang dihasilkan berupa identifikasi objek makanan yang terdapat di dalam lemari pendingin tersebut. Harapan


lebih lanjut dari sistem ini adalah terhubung langsung dengan sistem belanja daring yang ada di supermarket. Ketika persediaan makanan yang ada di lemari pendingin habis, lemari pendingin tersebut dapat memesan bahan makanan secara otomatis ke supermarket langganan pengguna.

II. METODE

A. Artificial Neural Network (ANN)

Secara umum, Neural Network (NN) atau Artificial Neural Network (ANN) adalah jaringan dari sekelompok unit pemroses kecil yang dimodelkan berdasarkan jaringan syaraf manusia. ANN ini merupakan sistem adaptif yang dapat mengubah strukturnya untuk memecahkan masalah berdasarkan informasi eksternal maupun internal yang mengalir melalui jaringan tersebut. Secara sederhana, ANN adalah sebuah alat pemodelan data statistik non-linear. ANN dapat digunakan untuk memodelkan hubungan yang kompleks antara masukan dan keluaran untuk menemukan pola-pola pada data.

Secara mendasar, sistem pembelajaran merupakan proses penambahan pengetahuan pada ANN yang sifatnya kontinuitas, sehingga pada saat digunakan, pengetahuan tersebut akan dieksploitasikan secara maksimal dalam mengenali suatu objek. Neuron adalah bagian dasar dari pemrosesan suatu Neural Network. Di bawah ini merupakan bentuk dasar dari suatu neuron.



Gambar 1. Bentuk dasar neuron [9]

Pada Gambar 1 di atas, bagian Input merupakan masukan yang digunakan baik saat pembelajaran maupun dalam mengenali suatu objek. Weight, beban yang selalu berubah setiap kali diberikan input sebagai proses pembelajaran. Processing Unit merupakan tempat berlangsungnya proses pengenalan suatu objek berdasarkan pembebanan yang diberikan. Output, keluaran dari hasil pengenalan suatu objek.

B. Deep Learning

Deep learning adalah salah satu algoritma pembelajaran mesin yang berbasis tidak terarah (*unsupervised learning*) dan terdiri dari banyak level dalam fitur dan ekstraksi data. Fitur yang lebih tinggi didapat dari fitur yang lebih rendah untuk membentuk sebuah representasi hierarki.

Terdapat beberapa jenis arsitektur *deep learning*. Namun, yang akan dibahas di sini adalah arsitektur yang digunakan dalam sistem identifikasi objek pada penelitian ini.

1. Deep Belief Network

Deep Belief Network adalah sebuah model yang generatif dan terdiri dari beberapa lapisan unit tersembunyi. DBN dapat dilihat sebagai sebuah modul *learning* sederhana yang dibentuk di setiap *layer*. DBN dapat digunakan untuk data pra-latih DNN secara generatif dengan menggunakan bobot belajar (*learned weight*) sebagai bobot awal (*initial weights*). *Backpropagation* atau algoritma diskriminatif lainnya kemudian dapat diaplikasikan untuk *fine tuning* bobot-bobot tersebut. Hal ini sangat membantu terutama ketika data latih yang tersedia sangat terbatas. Data pra-latih ini berada di area yang dekat dengan bobot optimal jika dibandingkan dengan inisialisasi acak. Hal ini membuat kapabilitas pemodelan meningkat dan konvergensi pada fase *fine tuning* menjadi lebih cepat.

Sebuah DBN dapat dilatih dalam *unsupervised* secara efektif, *layer* per *layer* yang mana setiap *layer*-nya biasanya dibentuk dari *Restricted Boltzman Machines* (RBM). RBM berbentuk graf tidak berarah (*undirected*), model berbasis energi generatif dengan *layer input* dan *layer tersembunyi* tunggal. Hubungan hanya ada di antara unit *layer input* yang terlihat dan unit yang tersembunyi di *layer tersembunyi*. Tidak ada hubungan antara yang terlihat dengan yang terlihat (*visible-visible*) atau yang tersembunyi dengan yang tersembunyi (*hidden-hidden*).

RBM dapat ditumpuk (*stacked*) dan dilatih dengan pendekatan *greedy* untuk membentuk *Deep Belief Networks* (DBN). DBN adalah model grafis yang belajar untuk mengekstrak representasi hirarkis yang mendalam dari data latih. Model tersebut membentuk *joint distribution* x diantara *observed vector* dan l *hidden layer* h^k seperti ditunjukkan dalam persamaan:

$$P(x, h^1, \dots, h^l) = \left(\prod_{k=0}^{l-2} P(h^k | h^{k+1}) \right) P(h^{l-1}, h^l)$$


yang mana $x = h^0$, $P(h^{k-1} | h^k)$ adalah sebuah *conditional distribution* untuk unit terlihat yang dikondisikan dalam unit tersembunyi di RBM sebagai $P(h^{l-1}, h^l)$ level k , dan sebagai *joint distribution visible-hidden* di level atas RBM.

Prinsip *greedy layer-wise unsupervised training* dapat diaplikasikan ke DBN dengan RBM sebagai *building block* di tiap *layer*-nya. Prosesnya sebagai berikut.

1. Latih *layer* pertama sebagai RBM yang memodelkan *raw input* $x = h^0$ sebagai *layer* yang terlihat.
2. Gunakan *layer* pertama untuk mendapatkan representasi input yang akan digunakan sebagai data untuk *layer* kedua. Dua solusi umum tercipta.

- Representasi ini bisa dipilih sebagai *mean activation* $p(h^{(1)}) = 1|h^{(0)}$ atau contoh dari $p(h^{(1)}|h^{(0)})$
- Latih *layer* kedua sebagai RBM, ambil data yang telah ditransformasi (sampel atau *mean activations*) sebagai contoh *training* (untuk *layer* RBM yang terlihat).
 - Ulangi langkah 2 dan 3 sesuai jumlah *layer* yang diperlukan, di setiap iterasi lakukan penyebaran ke atas (*propagating upward*) baik sampel maupun nilai rata-rata.
 - Fine-tune* semua parameter dari arsitektur *deep* ini sehubungan dengan proxy untuk DBN-loglikelihood, atau sehubungan dengan kriterium pembelajaran terarah (setelah menambahkan perlengkapan pembelajaran extra untuk mengonversi representasi yang telah dipelajari menjadi prediksi terarah, contohnya sebuah *classifier liner*).

Berikut adalah ilustrasi dalam melatih sebuah *Deep Belief Network* dengan membangun multi *Restricted Boltzmann Machines* ditumpuk di setiap atasnya. Setiap *layer* terdiri dari banyak *node* yang berkontribusi untuk *layer* selanjutnya.



Gambar 2. Training Deep Belief Network [10]

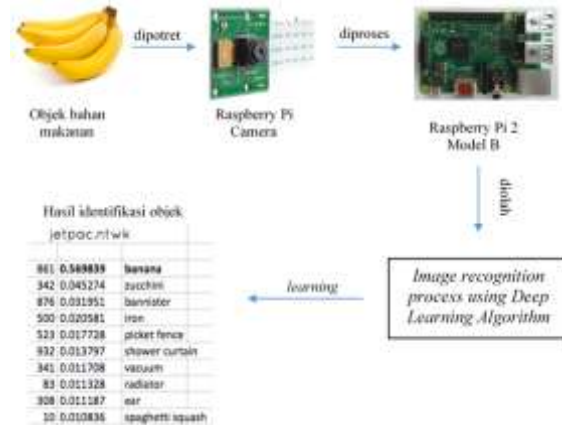
Mengapa algoritma tersebut bekerja? Ambil contoh sebuah DBN yang memiliki 2 *layer* dengan *hidden layer* h^1 dan h^2 (dengan parameter *weight* $W^{(1)}$ dan $W^{(2)}$, didirikan untuk derivasi rinci yaitu $\log p(x)$ yang dapat ditulis sebagai :

$$\log p(x) = KL(Q(h^{(1)}|x)) || p(h^{(1)}|x) + H_{Q(h^{(1)}|x)} + \sum_h Q(h^{(1)}|x)(\log p(h^{(1)}) + \log p(x|h^{(1)}))$$

$KL(Q(h^{(1)}|x)||p(h^{(1)}|x))$ merepresentasikan perbedaan KL di antara posterior $Q = (h^{(1)}|x)$ dari RBM pertama jika berdiri sendiri, dan probabilitas $p(h^{(1)}|x)$ untuk *layer* yang sama tetapi didefinisikan oleh keseluruhan DBN. Sebagai contoh, mempertimbangkan *prior* $p(h^{(1)}, h^{(2)})$ didefinisikan oleh level atas RBM. $HQ(h^{(1)}|x)$ adalah entropi dari distribusi $Q(h^{(1)}|x)$.

C. Sistem Kerja Alat

Berikut gambaran umum sistem yang menunjukkan alur berjalannya sistem dari mulai *input*, proses, dan *output*.



Gambar 3. Gambaran umum sistem



Gambar 4. Flowchart sistem

Dari gambar 3, dapat dilihat bahwa Raspberry Pi Camera berperan sebagai perangkat *input* sistem yang dibuat. Kamera ini akan mengambil gambar yang ada di lemari pendingin yang merupakan objek yang akan diolah datanya. Kemudian, Raspberry Pi 2 akan mengolah gambar yang sudah diambil. Dilakukan proses *image recognition* dengan menggunakan

algoritma *Deep Learning* untuk mengidentifikasi objek makanan. Setelah melalui proses *learning*, objek makanan akan teridentifikasi dengan tingkat kepercayaan (*confidence level*) tertentu. Sistem kerja alat dijelaskan dalam sebuah flowchart pada Gambar 4.

III. HASIL DAN PEMBAHASAN

Percobaan dilakukan dengan memasukkan Raspberry Pi, Raspberry Pi Camera, dan *power bank* sebagai catu daya, ke dalam lemari pendingin bersamaan dengan objek bahan makanan.



Gambar 5. Implementasi sistem di dalam lemari pendingin



Gambar 6. Set Raspberry Pi

Kemudian dilakukan uji program pada 4 objek bahan makanan: pisang, mentimun, brokoli, dan jeruk. Pertama-tama, gambar objek bahan makanan diambil dengan menggunakan kamera Raspberry Pi. Kemudian, gambar tersebut diolah menggunakan algoritma *Deep Learning* dengan arsitektur Deep Belief Network. Terdapat 2 data latih (*pre trained neural networks*) yang digunakan, masing-masing bernama *jetpac.ntwk* dan *ccv2012.ntwk*. Kedua data latih ini diadopsi dari ImageNet [11] yang terdiri dari 999 dan 1000 data.



Gambar 7. Kamera Raspberry Pi

Objek pertama yang diuji adalah pisang. Berikut merupakan gambar yang diambil dari kamera dan hasil identifikasi objek pisang. Pisang menempati urutan pertama objek dengan tingkat kepercayaan paling tinggi yang dikenali sebagai pisang. Dengan menggunakan data latih *jetpac.ntwk* didapatkan *confidence level* pisang sebesar 56,98%; sedangkan *ccv2012.ntwk* sebesar 36,88%.



Gambar 8. Hasil potret objek pisang

jetpac.ntwk		ccv2012.ntwk			
861	0.569839	banana	322	0.368846	banana
342	0.045274	zucchini	738	0.081959	zucchini
876	0.031951	bannister	570	0.053678	radiator
500	0.020581	iron	908	0.042067	bath towel
523	0.017728	picket fence	746	0.029723	shower curtain
932	0.013797	shower curtain	827	0.028204	swab
341	0.011708	vacuum	836	0.023038	sweatshirt
83	0.011328	radiator	793	0.013164	suit
308	0.011187	ear	717	0.010681	bannister
10	0.010836	spaghetti squash	835	0.010132	cardigan

Gambar 9. Hasil identifikasi objek pisang

Berikut ini hasil pengujian program pada mentimun sebagai objek kedua. Dapat dilihat bahwa objek diidentifikasi paling tinggi sebagai zucchini, padahal seharusnya mentimun. Zucchini memang memiliki bentuk seperti mentimun. Mentimun memiliki *confidence level* tertinggi kedua setelah Zucchini di data latih *ccv2012.ntwk* dengan 5,87%.

REFERENSI

- [1] D. A. Muktiawan, "Rancang Bangun Monitoring Alat Penyimpanan Kebutuhan Pokok Melalui Android Berbasis Mikrokontroler," in *Prosiding SNRT (Seminar Nasional Riset Terapan)*, 2016, vol. 5662, pp. 9–10, doi: ISSN 2541-5670 (Online).
- [2] T. Meilany Siregar, L. A. Harahap, and A. Rohanah, "IDENTIFIKASI KEMATANGAN BUAH PISANG (Musa paradisiaca) DENGAN TEKNIK JARINGAN SYARAF TIRUAN (Identification of Banana Maturity (Musa paradisiaca) with Artificial Neural Network)," *J. Rekayasa Pangan dan Pertan.*, vol. 3, no. 2, pp. 261–265, Aug. 2015, Accessed: May 20, 2021. [Online]. Available: <http://download.garuda.ristekdikti.go.id/article.php?article=1434485&val=4140&title=IDENTIFICATION OF BANANA MATURITY MUSA PARADISIACA WITH ARTIFICIAL NEURAL NETWORK>.
- [3] M. Michael, F. Tanoto, E. Wibowo, F. Lutan, and A. Dharma, "Pengenalan Plat Kendaraan Bermotor dengan Menggunakan Metode Template Matching dan Deep Belief Network," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 19, no. 1, pp. 27–36, 2019, doi: 10.30812/matrik.v19i1.475.
- [4] N. Angraini, D. F. Rahman, L. K. Wardhani, and N. Hakiem, "Mobile-based monitoring system for an automatic cat feeder using Raspberry Pi," *Telkomnika (Telecommunication Comput. Electron. Control.)*, vol. 18, no. 2, pp. 1038–1046, Apr. 2020, doi: 10.12928/TELKOMNIKA.V18I2.14819.
- [5] F. Humani, K. Adi, and C. E. Widodo, "Aplikasi Pengolahan Citra Pada Raspberry Pi Untuk Membedakan Benda Berdasarkan Warna Dan Bentuk," *Youngster Phys. J.*, vol. 5, no. 4, pp. 157–162, Oct. 2016, Accessed: May 20, 2021. [Online]. Available: <https://ejournal3.undip.ac.id/index.php/bfd/article/view/14055>.
- [6] R. Arif Candra, D. Nur Ilham, E. Sipahutar, D. Politeknik Aceh Selatan, and D. Politeknik ATI Padang, "METHOMIKA: Jurnal Manajemen Informatika & Komputerisasi Akuntansi PERANCANGAN SMART SECURITY CAMERA DENGAN MODEL IMAGE PROCESSING MENGGUNAKAN RASPBERRY PI," *METHOMIKA J. Manaj. Inform. Komputerisasi Akunt.*, vol. 3, no. 2, pp. 105–111, 2019.
- [7] J. Sapes and F. Solsona, "Fingerscanner: Embedding a fingerprint scanner in a raspberry pi," *Sensors (Switzerland)*, vol. 16, no. 2, Feb. 2016, doi: 10.3390/s16020220.
- [8] J. W. G. Putra, "Pengenalan Konsep Pembelajaran Mesin dan Deep Learning," *Comput. Linguist. Nat. Lang. Process. Lab.*, vol. 4, pp. 1–235, 2019, [Online]. Available: <https://www.researchgate.net/publication/323700644>.
- [9] G. Ciaburro, *MATLAB for Machine Learning*, vol. 1, no. 1. Packt, 2018.
- [10] C. C. Aggarwal, "Restricted Boltzmann Machines," *Neural Networks and Deep Learning*, pp. 235–270, 2018.
- [11] S. V. Lab, S. University, and P. University, "ImageNet," <https://image-net.org/index.php>, 2020. <https://image-net.org/index.php> (diakses 27 Maret, 2021).
- [12] D. Krisrenanto, M. Rivai, and F. Budiman, "Identifikasi Jumlah dan Tingkat Aktivitas Orang Berbasis Pengolahan Citra Menggunakan Raspberry Pi," *J. Tek. ITS*, vol. 6, no. 1, p. A-110-A-115, 2017, doi: 10.12962/j23373539.v6i1.21397.
- [13] L. Liu *et al.*, "Deep Learning for Generic Object Detection: A Survey," *Int. J. Comput. Vis.*, vol. 128, no. 2, pp. 261–318, Feb. 2020, doi: 10.1007/s11263-019-01247-4.
- [14] B. Petrovska, I. Stojanovic, and T. Atanasova-Pacemska, "Classification of Small Sets of Images with Pre-trained Neural Networks," *Int. J. Eng. Manuf.*, vol. 8, no. 4, pp. 40–55, Jul. 2018, doi: 10.5815/ijem.2018.04.05.
- [15] Y. Rizk, N. Hajj, N. Mitri, and M. Awad, "Deep belief networks and cortical algorithms: A comparative study for supervised classification," *Appl. Comput. Informatics*, vol. 15, no. 2, pp. 81–93, Jul. 2019, doi: 10.1016/j.aci.2018.01.004.