

Membangun Model Pengidentifikasi Kesegaran Daging dengan Metode Jaringan Syaraf Konvolusi (CNN) Jenis Resnet-50

Herianto¹, Adam Arif Budiman², Linda Nur Afifa³, Timor Setyaningsih⁴, Tri Amin Ridho⁵

Program Studi Teknologi Informasi Universitas Darma Persada^{1,2,3,4,5}

E-mail: heri.unsada@gmail.com¹, ariadam@gmail.com², afycena@gmail.com³,
timor_setyaningsih@ft.unsada.ac.id⁴, triaminridhounsada@gmail.com⁵

ABSTRAK

Penelitian yang dilakukan bertujuan mengembangkan model yang dapat mengidentifikasi kesegaran daging menggunakan metode *deep learning*. Kesegaran daging adalah faktor krusial dalam industri pangan untuk memastikan kualitas dan keselamatan konsumen. Namun, pengukuran kesegaran daging secara visual oleh manusia dapat menjadi subjektif dan memakan waktu. Oleh karena itu penelitian ini memanfaatkan kemajuan dalam bidang *deep learning* untuk mengatasi masalah tersebut. Dalam penelitian ini dilakukan pengumpulan dataset berupa gambar daging dalam berbagai kondisi kesegaran. Kemudian, digunakan teknik transfer learning pada arsitektur model jaringan saraf konvolusi (CNN=*Convolution Neural Network*) jenis Resnet-50 yang sudah terbukti, untuk melatih model. Dengan memanfaatkan fitur-fitur visual dari gambar daging yang dihasilkan oleh model, diperoleh tingkat akurasi yang tinggi dalam mengidentifikasi tingkat kesegaran daging. Hasil eksperimen menunjukkan bahwa model *deep learning Resnet-50* dapat dengan tepat mengklasifikasikan daging menjadi beberapa kategori tingkat kesegaran, seperti segar, setengah segar, dan tidak segar. Selain itu, juga dilakukan analisis perbandingan dengan metode tradisional dan menunjukkan bahwa model *deep learning* lebih unggul dalam kecepatan dan akurasi mencapai 96,5%. Penelitian ini diharapkan dapat memberikan kontribusi penting dalam industri pangan, membantu dalam penanganan daging yang berkualitas rendah, dan memastikan keselamatan konsumen. Selain itu, pendekatan yang digunakan dalam penelitian ini dapat diadaptasi untuk masalah pengenalan kualitas produk lainnya dalam bidang industri dan manufaktur.

Kata kunci : *Kesegaran daging, Deep learning, Model identifikasi, Industri pangan*

ABSTRACT

The research aims to develop a model capable of identifying meat freshness using deep learning methods. Meat freshness is a crucial factor in the food industry to ensure consumer quality and safety. However, visually assessing meat freshness by humans can be subjective and time-consuming. Therefore, this research leverages advancements in the field of deep learning to address this issue. In this study, a dataset of meat images in various freshness conditions is collected. Subsequently, transfer learning techniques are applied to the architecture of a Convolution Neural Network (CNN), specifically the Resnet-50 model, which has proven to be effective, to train the model. By utilizing the visual features extracted from the meat images generated by the model, a high level of accuracy in identifying meat freshness levels is achieved. Experimental results demonstrate that the Resnet-50 deep learning model accurately classifies meat into several freshness categories, such as fresh, semi-fresh, and not fresh. Additionally, a comparison analysis with traditional methods indicates that the deep learning model outperforms them in terms of both speed and accuracy, achieving a 96.5% accuracy rate. This research is expected to make a significant contribution to the food industry, aiding in the handling of low-quality meat and ensuring consumer safety. Furthermore, the approach used in this research can be adapted to address quality recognition issues in other product categories within the industrial and manufacturing sectors.

Keyword : *Meat freshness, Deep learning, Identification model, Food industry*

1. PENDAHULUAN

Dalam industri pangan yang terus berkembang, memastikan kualitas dan keamanan produk daging menjadi sangat penting. Salah satu faktor kunci yang berpengaruh besar terhadap kepuasan konsumen dan kesehatan adalah kesegaran daging. Kesegaran daging tidak hanya memengaruhi rasa dan tekstur produk akhir, tetapi juga memiliki peran vital dalam mencegah penyakit akibat konsumsi makanan yang kurang segar. Oleh karena itu, penilaian dan identifikasi yang akurat terhadap kesegaran daging menjadi perhatian utama baik bagi produsen maupun konsumen. Secara tradisional, kesegaran daging dinilai melalui pemeriksaan visual subjektif oleh ahli manusia yang terlatih, suatu metode yang rentan terhadap variasi penilaian dan prosedur yang memakan waktu. Seiring dengan perkembangan teknologi, muncul kebutuhan yang semakin meningkat untuk pendekatan yang inovatif dan efisien dalam mengatasi masalah ini. Deep learning, khususnya Convolutional Neural Networks (CNN), telah muncul sebagai alat yang kuat untuk tugas pengenalan dan klasifikasi gambar. Potensi deep learning untuk otomatisasi dan peningkatan akurasi dalam identifikasi kesegaran daging menjadikannya solusi yang menjanjikan bagi industri pangan. Penelitian ini bertujuan untuk mengatasi tantangan yang disebutkan di atas dengan menyajikan studi komprehensif tentang pembangunan model untuk mengidentifikasi kesegaran daging menggunakan metode CNN. Tujuan utama dari penelitian ini adalah memanfaatkan kemampuan *deep learning* untuk menciptakan sistem yang akurat dan efisien dalam mengkategorikan daging ke dalam tingkatan kesegaran, seperti segar, setengah segar, dan tidak segar. Pemanfaatan CNN, yang telah

membuktikan efektivitasnya dalam analisis gambar, akan memungkinkan untuk mengekstrak dan menganalisis fitur visual dari gambar daging dan membuat penilaian kesegaran yang tepat. Penelitian ini mendemonstrasikan kelayakan dan superioritas metode berbasis *deep learning* dibandingkan dengan pendekatan tradisional dalam hal akurasi dan kecepatan. Diharapkan bahwa penelitian ini akan memberikan kontribusi signifikan bagi industri pangan dengan menyediakan alat yang dapat diandalkan untuk menilai kesegaran daging dengan cepat dan konsisten, sehingga meningkatkan kualitas dan keamanan produk daging serta, pada akhirnya, melindungi kesehatan konsumen. Selain itu, pendekatan dan teknik yang dikembangkan dalam penelitian ini berpotensi dapat diadaptasi dan diperluas untuk mengatasi tantangan penilaian kualitas dalam kategori produk lainnya di sektor industri dan manufaktur.

2. LANDASAN TEORI

2.1. Daging Sapi

Daging Sapi merupakan hasil dari peternakan sapi sebagai bahan makanan sumber protein hewani yang mengandung gizi 19% protein, 70% air, 5% lemak dan 2,5% mineral. Kadar air ini bisa mempengaruhi pertumbuhan mikro organisme, sehingga terjadinya pembusukan pada daging sapi.

Daging sapi segar mempunyai ciri-ciri warnanya merah berserabut halus, sedikit lemak warna lemaknya kekuningan dan baunya amis segar. Daging sapi kurang segar atau setengah segar warna dagingnya merah pucat, kadar airnya banyak dan mengeluarkan aroma amis dan sedikit busuk. Daging sapi yang sudah busuk warnanya ke biru-biruan atau kehijau-hijauan, teksturnya sangat lembek dan berlendir lengket, serta baunya sangat tidak sedap.

2.2. Terminologi Dasar

Kajian pada topik penelitian ini menggunakan beberapa terminologi mendasar seperti berikut :

Artificial Intelligence

Kecerdasan buatan merupakan perangkat lunak atau sebuah program komputer yang mekanismenya untuk belajar, kemudian menggunakan pengetahuannya untuk membuat keputusan dalam situasi baru, seperti yang dilakukan manusia (Supriyadi, 2020).

Machine Learning

Pembelajaran mesin adalah cabang kecerdasan buatan yang penelitiannya berfokus pada desain dan analisis algoritma untuk memungkinkan komputer belajar.

Deep Learning

Deep Learning adalah Sub-bidang dari *artificial intelligence* (AI) atau *machine learning* (ML) yang berfokus kepada pembuatan model *neural network* yang mampu membuat keputusan data yang akurat (Kelleher, J. D, 2019)

2.3. Convolutional Neural Network

Convolutional Neural Networks (CNN) adalah metode pembelajaran mendalam yang berawal dari pengembangan *multilayer perceptron* (MLP) yang dirancang untuk memproses data dua dimensi dalam bentuk gambar. Pada *convolutional neural network* tersusun atas beberapa *feature learning* dan *classification* yaitu sebagai berikut.

Convolution Layer

Konvolusi merupakan sebuah operasi dari dua fungsi. fungsi yang pertama adalah nilai masukan berupa nilai piksel pada suatu lokasi pada citra. Fungsi kedua adalah matriks kernel atau disebut *filter*. *Filter* atau kernel tersebut kemudian dipindahkan ke titik berikutnya dalam gambar, yang disebut *stride*. Dalam konvolusi terdapat *padding* yang dimana merupakan bentuk manipulasi pada citra atau gambar

masukkan dengan menambahkan *piksel* yang berisi nilai 0 di setiap tepi citra atau gambar, sehingga dapat disebut sebagai *zero padding*. Perhitungan menentukan dimensi *feature map*.

$$H = \frac{I-K+P}{s} + 1 \quad (1)$$

Batch Normalization

Batch Normalization pertama kali diperkenalkan oleh Ioffe pada tahun 2015 untuk menormalisasikan lapisan masukan dengan mengatur dan menskalakan lapisan aktivasi yang dapat meningkatkan kecepatan komputasi, kinerja dan stabilitas jaringan (Ioffe, 2015).

Rectified Linear Unit (ReLU)

ReLU merupakan fungsi aktivasi, dimana g menunjukkan fungsi *pixel-wise* yang bersifat *non-linear*, yang berarti nilai keluarannya dari fungsi ReLU ini. jika bernilai x positif maka akan menjadi bernilai x dan jika x negatif maka akan menjadi bernilai 0.

$$g(x) = \max(0, x) \quad (2)$$

Pooling Layer

Pooling Layer merupakan komponen lain dalam CNN yang bertujuan mengurangi resolusi lebar dan tinggi dari *feature map* (Castiglioni et.al., 2021).

Flatten

Flatten merupakan sebuah fungsi untuk gambar dari *convolusi* yang berbentuk *multidimensional array* menjadi satu dimensi *array* yang menjadi nilai *input* atau masukan pada dalam proses klasifikasi.

Fully Connected Layer

Fully connected layer merupakan setiap *neuron* pada *layer* sebelumnya terhubung dengan setiap *neuron*. Pada lapisan ini menggunakan nilai keluaran dari lapisan *feature map* sebagai nilai *input* dan menghitung probabilitas untuk diklasifikasi ke dalam berbagai kelas.

Softmax


Softmax adalah fungsi aktivasi yang digunakan untuk mengklasifikasi secara *linear* yang memperhitungkan nilai-nilai probabilitas terhadap suatu kelas. Pada hasil nilai keluaran tiap-tiap kelas memiliki rentang nilai 0 sampai 1 (Nwankpa, C.E. et.al., 2018).

Cross Entropy

Cross entropy adalah metode yang paling sering digunakan oleh jaringan saraf untuk menghitung urutan solusi yang berpusat pada arah yang optimal. Dalam *cross entropy*, ini digunakan sebagai *loss function* untuk memaksimalkan efisiensi pembelajaran, menghitung nilai kesalahan (Zhou, Yangfan et.al., 2019).

2.4. Resnet

Arsitektur ini memiliki performa yang baik dalam menyelesaikan masalah model CNN yaitu masalah *vanishing gradient*, dimana *gradien* yang terdapat pada *layer* terakhir mulai menghilang meninggalkan *layer* berikutnya tidak berubah. Masalah ini membuat sistem lebih lambat untuk dilatih dan rentan terhadap kesalahan. Menghadapi masalah tersebut, model ResNet membuat blok residual dimana setiap *layer* pada arsitektur CNN ResNet memiliki blok sebagai fungsi identitas [9].



Gambar 1 Arsitektur ResNet-50

2.5. Confusion Matrix

Confusion matrix adalah parameter yang dapat mengukur kinerja model klasifikasi.

		Nilai Aktual	
		Positive	Negative
Nilai Prediksi	Positive	TP	FP
	Negative	FN	TN

Gambar 2 Confusion Matrix

2.6. Akurasi

Nilai akurasi merupakan perbandingan antara data yang terklasifikasi benar dengan total data. Nilai akurasi dapat diperoleh dengan persamaan berikut ini.

$$akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

2.7. Precision (Specifity)

Precision merupakan sebuah nilai hasil klasifikasi daging sapi segar yang tidak diidentifikasi sebagai daging setengah segar dan busuk. Untuk menghitung *precision* gunakan persamaan berikut ini.

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

2.8. Recall (Sensitifivty)

Recall atau *sensitifivty* merupakan sebuah nilai hasil klasifikasi daging sapi segar yang diidentifikasi sebagai daging sapi segar. Untuk menghitung *recall* menggunakan persamaan berikut ini :

$$Recall = \frac{TP}{TP+FN} \quad (5)$$


2.9. F1 Score

F1 Score merupakan rata-rata harmonik dari *precision* dan *recall* [10]. Formula *F1-Score* dapat ditulis menggunakan persamaan berikut ini.

$$F1\ Score = 2 \times \frac{precision \times recall}{precision+recall} \quad (6)$$

3. METODOLOGI

Proses yang dilakukan pada penelitian ini mengacu ke metodologi CRISP-DM (*Cross Industry Standard Process for Data Mining*) seperti berikut :




Gambar 3 Metodologi CRISP-DM

Metodologi CRISP-DM merupakan standar proses datamining yang bersifat terbuka, terdiri dari 6 tahap : (1) Business Understanding, (2) Data Understanding, (3) Data Preparation, (4) Modelling, (5) Evaluation, dan (6) Deployment.

4. HASIL DAN PEMBAHASAN

Dataset

Dataset pada penelitian ini berupa image (file gambar) yang dikelompokkan kepada tiga bagian yaitu : image daging segar (a), image daging setengah segar (b), dan image daging busuk (c), seperti contoh berikut :




Gambar 4. Klasifikasi Kesegaran Daging

Masing-masing dari ketiga status kesegaran di atas terdiri dari 560 image, sehingga totalnya ada 1680 image. Selanjutnya dataset tersebut dibagi menjadi 2 bagian yaitu dataset training dan testing, dengan proporsi 70% untuk data training yaitu : 1176, dan 30% untuk dataset testing yaitu : 504.

Proses Training

Proses training dilakukan dengan menggunakan algoritma CNN (Convolution Neural Network) dengan Arsitektur ResNet-50.

Berikut ini merupakan visualisasi selama proses *training* berdasarkan perubahan besar epoch dan akurasi :



Gambar 5 Grafik Proses Training

Dari percobaan yang dilakukan diperoleh hasil optimal *batch size* berjumlah 16, *epoch* teroptimal 25 kali dengan *target size* RGB sebesar 224 × 224.

Pengujian

Pengujian model yang dilatih menggunakan 168 data uji untuk setiap kelas, sehingga total data uji adalah 504 data. Berikut cuplikan hasil klasifikasi yang diperoleh dari hasil pengujian.

Tabel 1. Tabel Testing Dataset

No	Nama File	Aktual	Prediksi
1	busukTest1	Busuk	Busuk
2	busukTest2	Busuk	Busuk
3	busukTest3	Busuk	Busuk
...
168	segarTest1	Segar	Segar
169	segarTest2	Segar	Segar
170	segarTest3	Segar	Segar
...
502	setengahSegar Test166	Setengah Segar	Setengah Segar
503	setengahSegar Test167	Setengah Segar	Setengah Segar
504	setengahSegar Test168	Setengah Segar	Setengah Segar

Dalam matriks konfusi hasil pengujian model di atas diringkas seperti berikut :

		AKTUAL		
		Busuk	Segar	Setengah Segar
PREDIKSI	Busuk	166	0	2
	Segar	0	168	0
	Setengah Segar	0	1	167

Gambar 6 Confusion Matrix

Evaluasi Model

Dalam percobaan dengan model CNN dan Arsitektur ResNet-50. Dari 1680 *dataset* daging sapi dilakukan dua tahap yaitu *training* model dengan sebesar 70% dan *testing* model sebesar 30%. Dari masing-masing model yang di *training* memiliki tingkat akurasi dan *loss* sendiri. Berdasarkan percobaan yang telah dilakukan, berikut perbandingan hasil *training* dari hasil pelatihan dari setiap model dan perbandingan hasil *testing* dari setiap model.

Tabel 2. Akurasi Model CNN

No	Model Training	Akurasi	Akurasi Validation
1	ResNet-50	98,2%	96,5%

Tabel 3. Hasil Pengujian F1-Score

No	Model Testing	Akurasi	Precision	Recall	F1-Score
2	ResNet-50	99,4%	99,4%	99,4%	99,3%


Pada pengujian data daging sapi segar dengan 168 data daging sapi segar, 168 data terklasifikasi ke dalam kategori segar, 0 data terklasifikasi ke dalam kategori setengah segar, 0 data terklasifikasi ke dalam kategori busuk. Pada pengujian data daging sapi setengah segar dengan 168 data daging sapi setengah segar, 1 data terklasifikasi ke dalam kategori segar, 167 data terklasifikasi ke dalam kategori setengah segar, 0 data terklasifikasi ke dalam kategori busuk. Pada pengujian data daging sapi busuk dengan 168 data daging sapi busuk, 0 data terklasifikasi ke dalam kategori segar, 2 data terklasifikasi ke dalam kategori setengah segar, 166 data terklasifikasi ke dalam kategori busuk. Dari hasil-hasil tersebut selanjutnya dilakukan perhitungan tingkat *precision*, *recall* dan *f1-score* dalam mengklasifikasi kesegaran daging sapi.

Berikut ini hasil tingkat *precision*, *recall* dan *f1-score* dari model ResNet-50 berdasarkan hasil pengujian yang telah dilakukan.

Tabel 4. Nilai F1-Score berdasarkan Status Kesegaran

Tingkat Kesegaran	Precision	Recall	F1-Score
Segar	99,4%	100%	99,6%
Setengah Segar	98,8%	99,4%	99%
Busuk	100%	98,8%	99,3%

Selanjutnya Model yang dihasilkan dideploy ke bentuk aplikasi web menggunakan framework python flask dengan interface utama saat pengujian daging seperti berikut :



Gambar 7. Interface aplikasi

5. KESIMPULAN

1. Model CNN yang terbaik yang digunakan pada penelitian ini adalah arsitektur ResNet-50 dan merupakan model yang paling optimal untuk memahami pola citra kesegaran daging sapi.
2. Arsitektur CNN ResNet-50 dalam mengklasifikasi kesegaran daging sapi yang digunakan memiliki jumlah *batch size* 16, *epoch* 25 dan *target size* RGB sebesar 224×224 .
3. Nilai akurasi pada model yang digunakan adalah 99,4%, *precision* sebesar 99,4%, *recall* sebesar 99,4% dan *f1-score* sebesar 99,3%

DAFTAR PUSTAKA

- Castiglioni, Isabella et.al. (2021). AI Applications to medical images: From machine learning to deep learning. *Physica Medica* 83, 9-24.

- He, K et.al. (2016). Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.
- Herianto, et.al. (2021), Evaluasi Kinerja Datamining Pada Dataset Pendaftaran Mahasiswa Baru Dengan Class Yang Tidak Seimbang, *Jurnal IKRAITH-INFORMATIKA Vol 5 No 3 November 2021*
- Kelleher, J. D. (2019). *Deep Learning*. MIT Press.
- Lasniari et.al. (2022). Klasifikasi Citra Daging Babi Menggunakan Deep Learning Arsitektur ResNet-50 dengan Augmentasi Citra. *Jurnal Sistem Komputer dan Informatika* 6(4), 450-457.
- Loffe, Sergey & Szegedy, Christian. (2015). Batch Normalization: Accelerating Deep Neural Network Training by Reducing Internal Covariate Shift. <https://doi.org/10.48550/arXiv.1502.03167>.
- Mellinia, Z. F. D. & Zuliarso, Eri. (2022). Implementasi Model CNN dan Tensorflow Dalam Pendeteksian Jenis Daging Hewan Ternak. *Jurnal Teknologi Terapan (J-TIT)*, 9(1), 54-61
- Nwankpa, C.E. et.al. (2018). Activation Functions: Comparison of Trends in Practice and Research For Deep Learning. <https://doi.org/10.48550/arXiv.1811.03378>.
- Russell, S. J., & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach*. Pearson Education, Inc. Retrieved 9 15, 2023, from <http://aima.cs.berkeley.edu/>
- Shearer, P.M. (1999). *Introduction to seismology*. Cambridge: Cambridge University Press.
- Subakti, H., Romli, I., Nur Syamsiyah, S. T., Budiman, A. A., Kom, M., Herianto, et.al. (2022). *Artificial Intelligence*. Media Sains Indonesia.
- Zhou, Yangfan et.al. (2019). MPCE: A Maximum Probability based Cross Entropy Loss Function for Neural Network Classification. *IEEE Access* 7, 146331-146341.