



UNIVERSITAS
GADJAH MADA



Deep Learning untuk Identifikasi Ikan

Anifuddin Azis, S.Si., M.Kom.

Departemen Ilmu Komputer dan Elektronika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Gadjah Mada



UNIVERSITAS
GADJAH MADA

Deep Learning



Deep Learning

- Salah satu algoritma kecerdasan buatan yang ada adalah jaringan syaraf tiruan / *artificial neural network* (ANN)
- Jaringan syaraf dengan jumlah *layer* yang banyak disebut sebagai ***deep learning***. Semakin banyak *layer* maupun jumlah *neuron* yang dipakai, maka proses pembelajarannya akan semakin lama, karena dalam perhitungannya diperlukan **kompleksitas** yang **besar**.



Deep Learning

- Dahulu *deep learning* belum dapat diimplementasikan karena ketersediaan data yang terbatas dan kekuatan komputasi yang masih minim
- Namun pada era big data dan ditambah dengan perkembangan teknologi komputasi, *deep learning* menjadi berkembang dengan pesat dan dapat digunakan untuk menyelesaikan beberapa permasalahan, salah satunya untuk identifikasi ikan



Deep Learning

- Klasifikasi pada data dilakukan dengan memanfaatkan fitur / ciri (misal garis, bentuk, warna, tekstur) yang ada pada data
- Dengan ekstraksi fitur secara manual, hasilnya belum tentu baik
- Salah satu arsitektur deep learning, yaitu *convolutional neural network*, mampu mengekstraksi fitur dengan perlahan-lahan belajar mengenali data



Convolutional Neural Network

- Umumnya terdiri dari *convolutional layer*, *batch normalization*, fungsi aktivasi ReLU, lalu *max pooling*
- *Convolutional layer* melakukan operasi **konvolusi** pada citra untuk **mengekstraksi fitur** atau ciri.
- Konvolusi dilakukan oleh beberapa **filter/kernel** dengan ukuran tertentu

```
inputs = Input(shape=image_size + (3,), name='input')  
conv1 = Conv2D(8, (7, 7), name='block1_conv')(inputs)
```



Convolutional Layer

7	2	3	3	8
4	5	3	8	4
3	3	2	8	4
2	8	7	2	7
5	4	4	5	4

*

1	0	-1
1	0	-1
1	0	-1

=

6		

$7 \times 1 + 4 \times 1 + 3 \times 1 + 2 \times 0 + 5 \times 0 + 3 \times 0 + 3 \times -1 + 3 \times -1 + 2 \times -1 = 6$

Citra

Kernel

Fitur



Batch Normalization

- Teknik untuk meningkatkan kemampuan pembelajaran pada ANN
- Hasil fitur pada *convolutional layer* dinormalisasi

```
inputs = Input(shape=image_size + (3,), name='input')  
conv1 = Conv2D(8, (7, 7), name='block1_conv')(inputs)  
conv1 = BatchNormalization(name='block1_bnorm')(conv1)
```



Batch Normalization

Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift (Ioffe dan Szegedy, 2015)

Input: Values of x over a mini-batch: $\mathcal{B} = \{x_{1\dots m}\}$;

Parameters to be learned: γ, β

Output: $\{y_i = \text{BN}_{\gamma,\beta}(x_i)\}$

$$\mu_{\mathcal{B}} \leftarrow \frac{1}{m} \sum_{i=1}^m x_i \quad // \text{ mini-batch mean}$$

$$\sigma_{\mathcal{B}}^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_{\mathcal{B}})^2 \quad // \text{ mini-batch variance}$$

$$\hat{x}_i \leftarrow \frac{x_i - \mu_{\mathcal{B}}}{\sqrt{\sigma_{\mathcal{B}}^2 + \epsilon}} \quad // \text{ normalize}$$

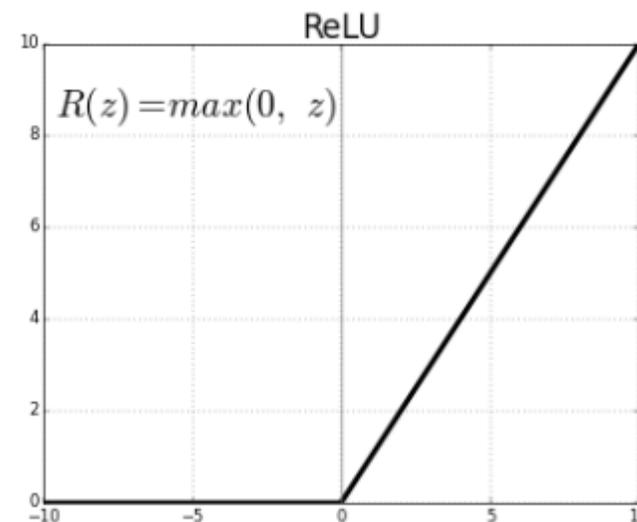
$$y_i \leftarrow \gamma \hat{x}_i + \beta \equiv \text{BN}_{\gamma,\beta}(x_i) \quad // \text{ scale and shift}$$



Aktivasi ReLU

- Fitur hasil *batch normalization* dikenai fungsi ReLU
- Mampu meningkatkan performa pembelajaran ANN tanpa dengan komputasi yang lebih ringan

```
inputs = Input(shape=image_size + (3,), name='input')  
conv1 = Conv2D(8, (7, 7), name='block1_conv')(inputs)  
conv1 = BatchNormalization(name='block1_bnorm')(conv1)  
conv1 = ReLU(name='block1_relu')(conv1)
```





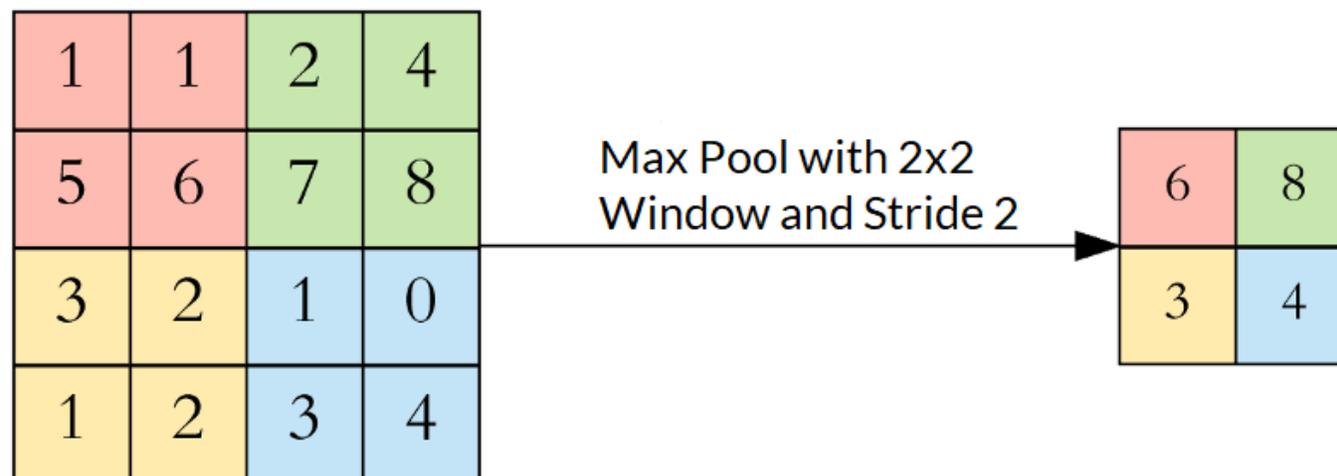
Max Pooling

Pooling layer melakukan operasi berupa *pooling* pada data untuk **mereduksi dimensi** serta **mengurangi** banyaknya **parameter** yang digunakan.

```
inputs = Input(shape=image_size + (3,), name='input')
conv1 = Conv2D(8, (7, 7), name='block1_conv')(inputs)
conv1 = BatchNormalization(name='block1_bnorm')(conv1)
conv1 = ReLU(name='block1_relu')(conv1)
conv1 = MaxPooling2D((2, 2), name='block1_pool')(conv1)
```



Max Pooling





UNIVERSITAS
GADJAH MADA

Eksperimen



Latar Belakang

- **Ekosistem perairan** mengandung banyak kekayaan hewani seperti ikan. Ahli biologi kelautan melakukan pengamatan pada keberagaman jenis ikan dengan **menentukan keberadaan dan populasi spesies ikan** pada suatu kawasan perairan.
- Dikembangkannya **sistem kamera tertanam** untuk mengambil data berupa video dimana **pengamat tidak perlu masuk ke dalam air** secara langsung.
- Hasil video dianalisa secara **manual**, tetapi hal tersebut membutuhkan **waktu yang lebih banyak** dan **usaha yang lebih besar** (Spampinato et al., 2010).



Penelitian Terdahulu

1. Tamoe, et al. (2018)
 - Pengenalan spesies ikan pada video yang diambil pada kondisi di perairan laut.
 - Dataset : The Fish Recognition Ground-Truth dari Fish4Knowledge (27370 citra, 23 kelas)
 - Metode : augmentasi data, *transfer learning* pada arsitektur model AlexNet, klasifikasi dengan *linear SVM*.
 - Akurasi : 99%



Penelitian Terdahulu

2. Rathi, et al. (2017)

- Klasifikasi spesies ikan secara otomatis menggunakan metode yang baru.
- Dataset : The Fish Recognition Ground-Truth dari Fish4Knowledge (27142 citra, 21 kelas)
- Metode : teknik pengolahan citra (*Otsu's thresholding, Erosion, dan Dilation*), *Convolutional Neural Network*
- Akurasi : 96,26%



Penelitian Terdahulu

3. Deep dan Dash (2019)

- Klasifikasi spesies ikan pada citra yang diambil pada perairan bawah laut.
- Dataset : The Fish Recognition Ground-Truth dari Fish4Knowledge (27370 citra, 23 kelas)
- Metode : *preprocessing* dengan *laplacian kernel*, DeepCNN dengan algoritma klasifikasi *k-Nearest Neighbor*.
- Akurasi : 98,79 %



Dataset

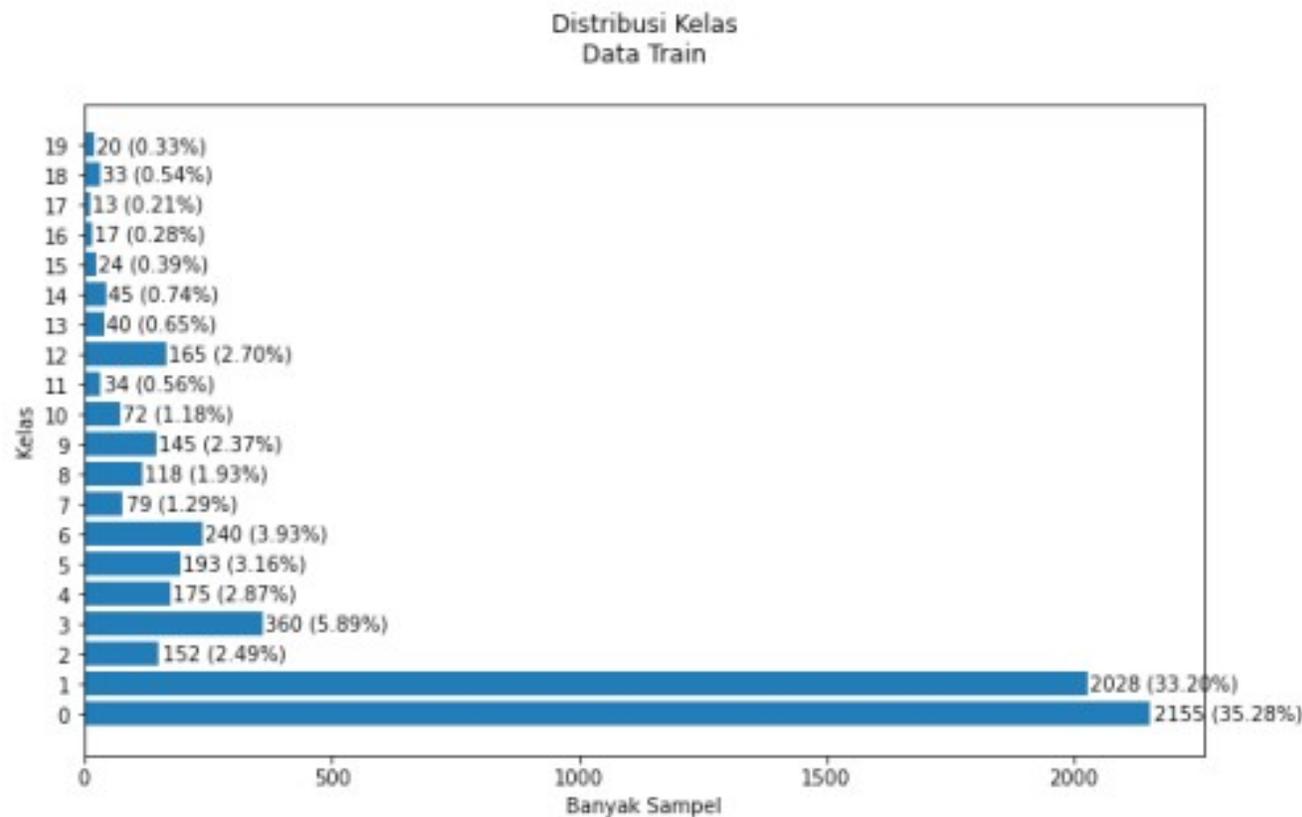
- Sumber : [Fish4Knowledge](#)
- Terdiri dari 20 kelas
 - *Zanclus cornutus* (ikan Moris), *Scaridae* (ikan Kakatua), *Lutjanus fulvus* (kakap merah), dsb.
- Data latih ~6.000 citra, data validasi ~1.500 citra





Dataset

- Bersifat *imbalanced* – persebaran kelas tidak merata





Evaluasi

- Keberhasilan mesin dalam belajar diukur dengan ukuran evaluasi
- Ukuran evaluasi yang umum digunakan: *loss* (error), akurasi, dan F1 *score*



Evaluasi - Loss

- Semakin menurun nilai loss (nilai error) menandakan bahwa mesin berhasil mempelajari data
- Rumus :

$$L = \frac{1}{m} \sum_{k=1}^m \sum_{i=0}^{c-1} y_i^{(k)} \log(p_i^{(k)})$$

dengan banyak data, adalah banyak kelas, adalah vektor label asli.
dengan m banyak data, c adalah banyak kelas, $y^{(k)}$ adalah vektor label asli.
dari data ke- k , dan p adalah vektor label yang diprediksi oleh CNN dari
data ke- k



Evaluasi - Akurasi

- Umumnya juga menggunakan akurasi:

$$= \frac{\text{banyak data yang diprediksi benar}}{\text{banyak data}}$$

- Karena data bersifat *imbalanced*, maka model bias ke kelas mayoritas → akurasi menjadi tidak representatif / tidak mewakili kemampuan pembelajaran model yang sesungguhnya



Evaluasi - F1 score

- Lebih representatif pada data *imbalanced*
- Lebih representatif pada data *imbalanced*
- Dihitung untuk setiap kelas, kemudian dihitung rata-ratanya

$$F_1 \text{ kelas } c = \frac{2p_c r_c}{p_c + r_c}$$

$$\text{rerata } F_1 = \sum_{k=0}^{19} (F_1 \text{ kelas } k)$$



Evaluasi - F1 score

$$p_c = \textit{precision kelas } c = \frac{TP_c}{TP_c + FP_c}$$

$$r_c = \textit{recall kelas } c = \frac{TP_c}{TP_c + FN_c}$$

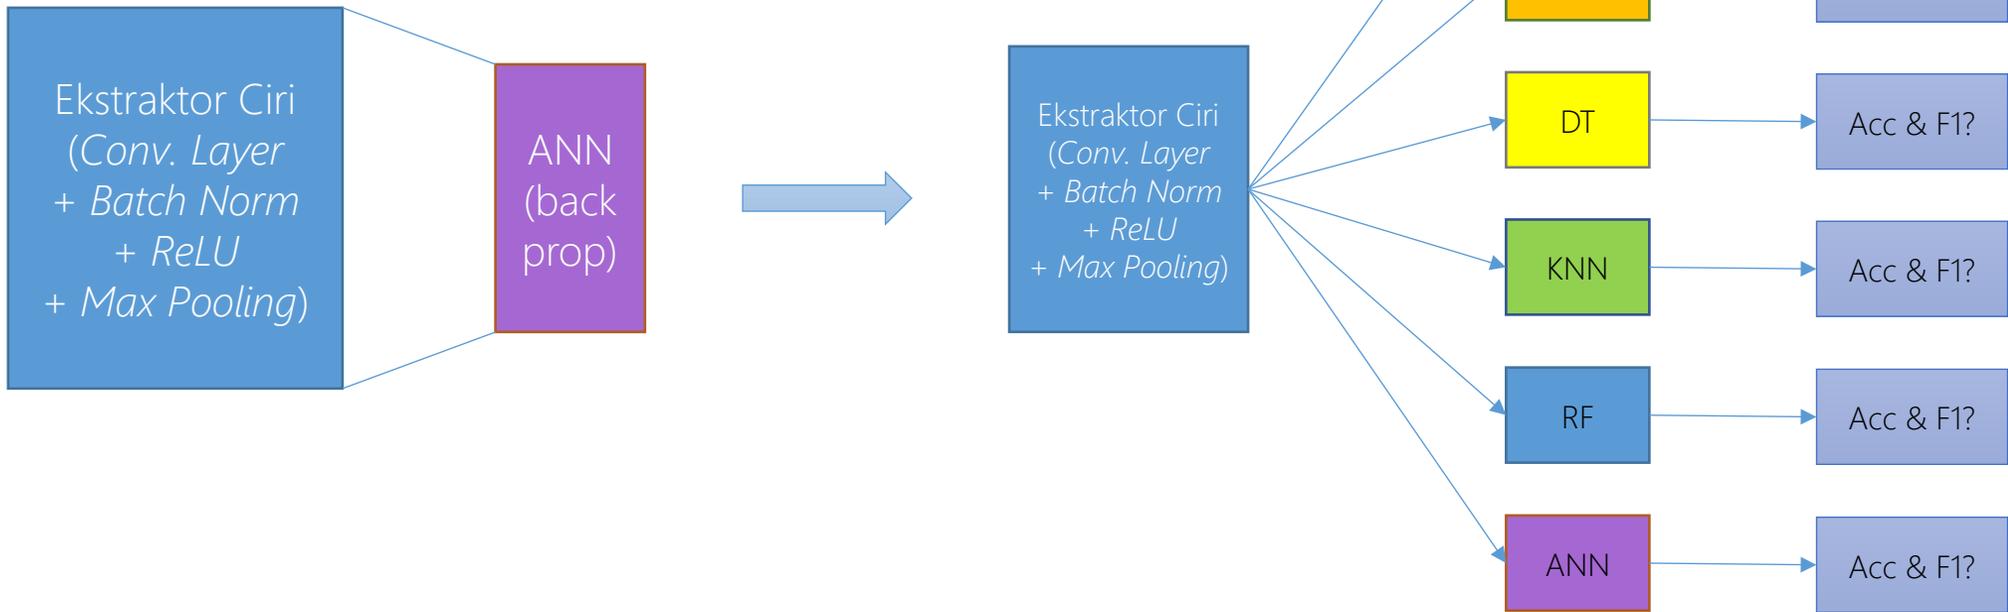
- = banyak data kelas c yang diprediksi benar sebagai kelas c
- TP_c = banyak data kelas c yang diprediksi benar sebagai kelas c
- FP_c = banyak data yang bukan kelas c tetapi diprediksi sebagai kelas c
- FN_c = banyak data kelas c tetapi diprediksi sebagai bukan kelas c



Skenario

1. Menggunakan model *hybrid* : ekstraksi fitur dengan CNN, algoritma klasifikasi dengan algoritma lain
2. Model CNN yang awal, yaitu yang algoritma klasifikasinya adalah *artificial neural network*, dilatih untuk ekstraksi fitur
3. Fitur yang diperoleh diklasifikasi dengan berbagai macam algoritma dan masing-masing dievaluasi (termasuk dengan ANN yang dilatih sebelumnya):
 1. *Logistic regression*
 2. *Support vector machine*
 3. *Decision tree*
 4. *K-nearest neighbor*
 5. *Random forest*
 6. *ANN/backprop*

Ilustrasi Skenario



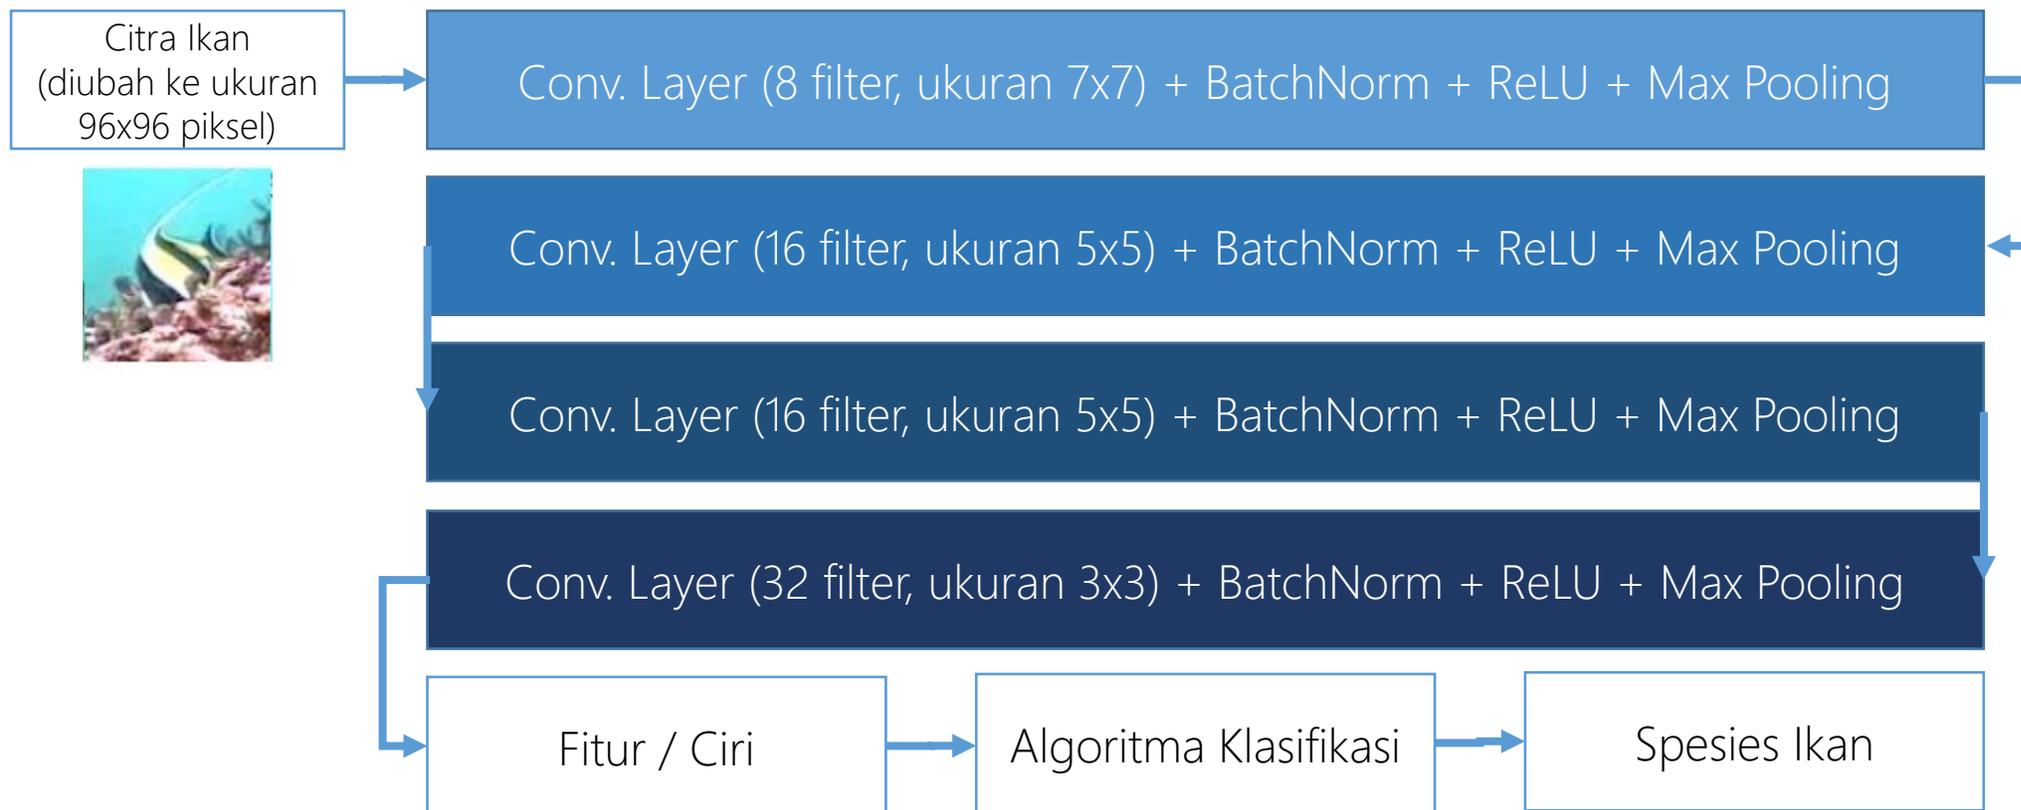
Dilatih terlebih dahulu

Klasifikasi dengan berbagai algoritma dan dievaluasi



Hasil Akhir

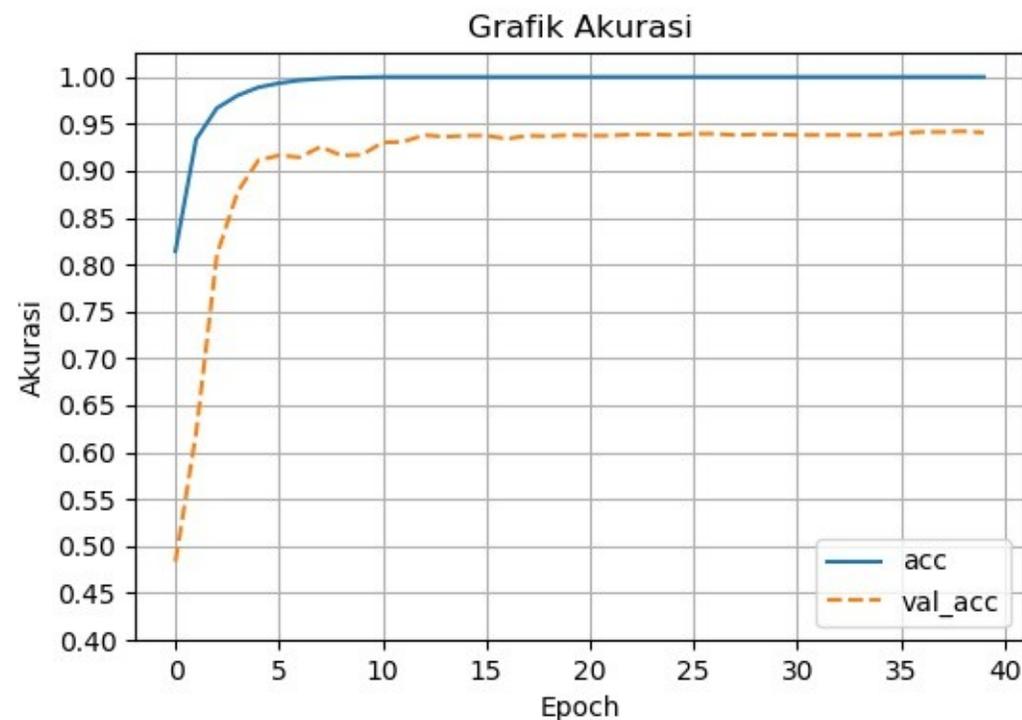
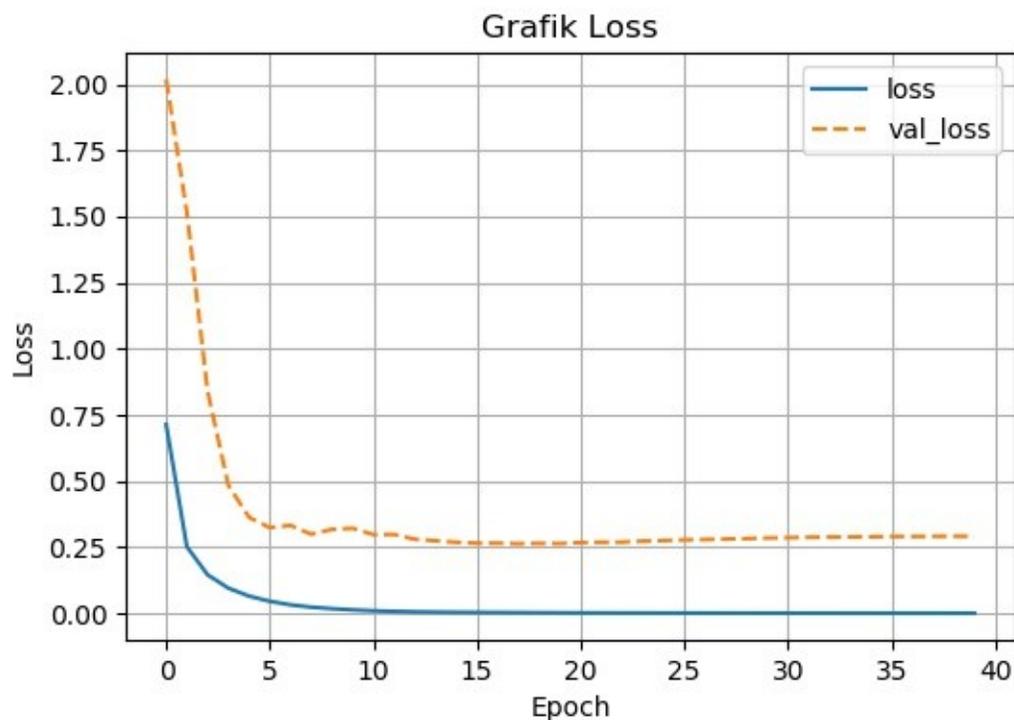
Arsitektur terbaik untuk ekstraksi ciri :





Hasil Akhir

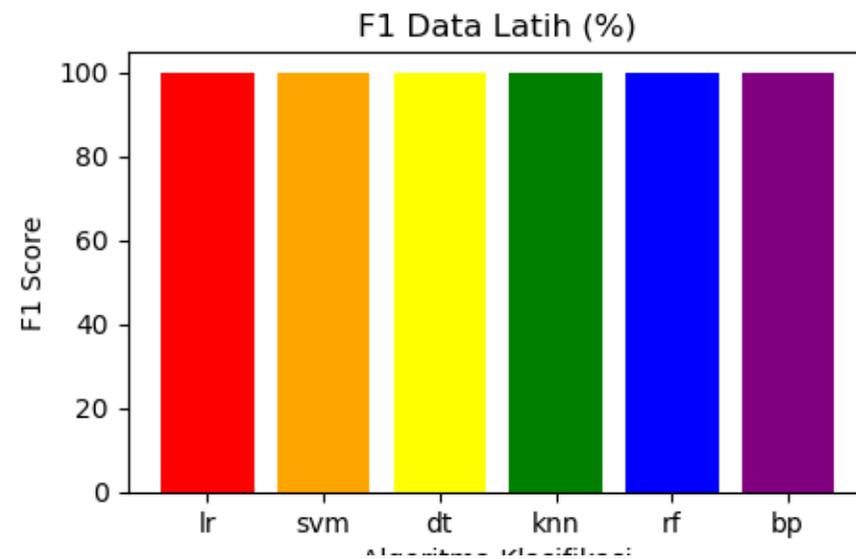
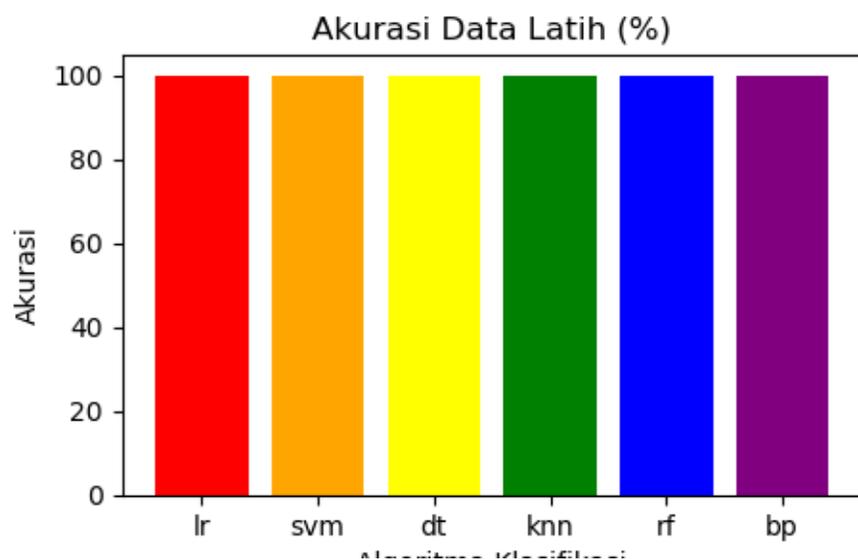
- Model dilatih sampai berhenti belajar (40 epoch atau iterasi)
- Semakin lama nilai *loss* menurun dan akurasi meningkat, menandakan mesin berhasil belajar mengklasifikasi data





Hasil Akhir

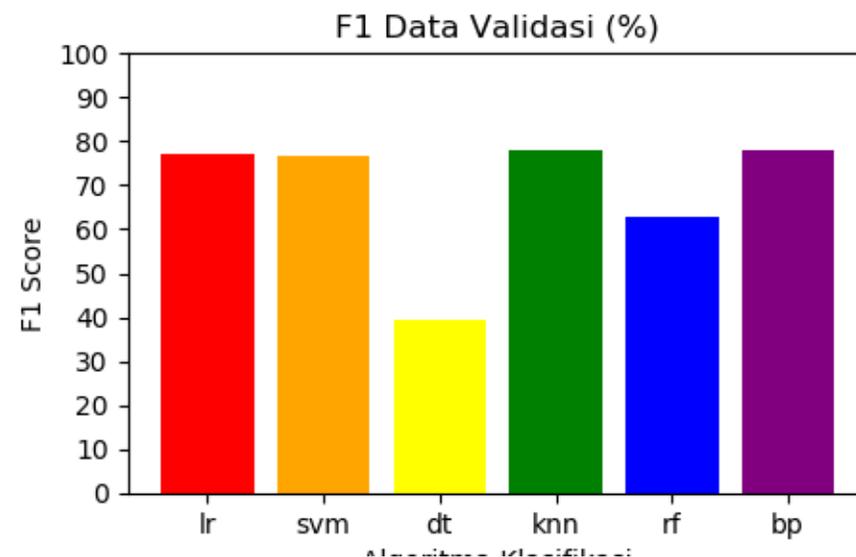
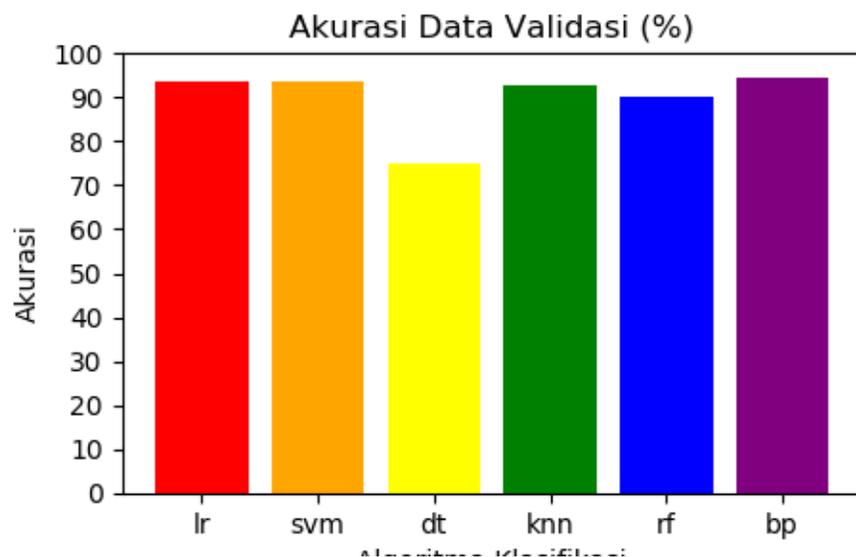
- Akurasi dan F1 data latih 100% untuk semua algoritma klasifikasi → model berhasil mempelajari data latih dengan baik





Hasil Akhir

- Algoritma perceptron memiliki akurasi dan F1 score tertinggi, diikuti dengan KNN
- F1 score lebih rendah dibandingkan akurasi → F1 score lebih representatif





Hasil Akhir

Algoritma klasifikasi terbaik:

1. ANN
(F1 data validasi 77,84%, akurasi data validasi 94,2%)
2. K-Nearest Neighbor
(F1 data validasi 77,75%, akurasi data validasi 92,56%)



Penerapan

Model yang sudah diperoleh dapat digunakan untuk:

1. Aplikasi mobile untuk identifikasi ikan
2. Monitoring area perikanan berbasis kamera



Referensi

- Spampinato, C., Giordano, D., Di Salvo, R., Chen-Burger, Y.-H. J., Fisher, R. B., and Nadarajan G. (2010) 'Automatic fish classification for underwater species behavior understanding,' in *Proceedings of the first ACM international workshop on Analysis and retrieval of tracked events and motion in imagery streams*. ACM, pp. 45–50.
- Tamou, A. B., Benzinou, A., Nasreddine, K. and Ballihi, L. (2018) 'Transfer Learning with deep Convolutional Neural Network for Underwater Live Fish Recognition,' in *2018 IEEE International Conference on Image Processing, Applications and Systems (IPAS)*, Sophia Antipolis, France, pp. 204-209, doi: 10.1109/IPAS.2018.8708871.
- Rathi, D., Jain, S. and Indu, S. (2017) 'Underwater Fish Species Classification using Convolutional Neural Network and Deep Learning,' in *2017 Ninth International Conference on Advances in Pattern Recognition (ICAPR)*, Bangalore, pp. 1-6, doi: 10.1109/ICAPR.2017.8593044.
- Deep, B. V. and Dash, R. (2019) 'Underwater Fish Species Recognition Using Deep Learning Techniques,' in *2019 6th International Conference on Signal Processing and Integrated Networks (SPIN)*, Noida, India, pp. 665-669, doi: 10.1109/SPIN.2019.8711657



UNIVERSITAS
GADJAH MADA

Terima Kasih

