

BAB 2

LANDASAN TEORI

Telaah literatur dilakukan untuk memberikan landasan teori yang menjadi dasar pengetahuan yang dibutuhkan untuk melakukan penelitian. Komponen yang dimanfaatkan dalam penelitian diuraikan dalam bab ini.

2.1 Machine Learning

Machine Learning atau Pembelajaran Mesin merupakan *subset* dari kecerdasan buatan yang mempelajari bagaimana komputer, sebagai mesin, mampu melakukan sebuah tugas melalui informasi yang sebelumnya dimiliki dan berkembang berdasarkan kesalahan yang dilakukan sebelumnya [19]. Pembelajaran mesin dilakukan dengan tujuan umum mengenali pola pada data untuk memahami bagaimana masalah yang belum dikenali sebelumnya ditangani berdasarkan pola tersebut [20].

2.2 Deep Learning

Deep Learning atau Pembelajaran Dalam merupakan bidang dalam Pembelajaran Mesin yang memanfaatkan jaringan saraf artifisial berlapis dalam [21]. Pembelajaran dalam disebut demikian karena data diproses melalui jaringan saraf bertingkat. Pembelajaran dalam dapat digunakan untuk mempelajari struktur pada sebuah data berdimensi tinggi berdasarkan komposisi data dengan rekayasa minimal dari pencipta sistem [22]. Karena sifatnya yang mampu mempelajari fitur rumit yang mungkin sulit ditemukan manusia, pembelajaran dalam menjadi metode yang handal untuk melakukan pengolahan citra secara umum.

2.3 Artificial Neural Network

Artificial Neural Network atau Jaringan Saraf Artifisial merupakan sistem pengolahan informasi dalam pembelajaran dalam yang bertujuan untuk mengenali hubungan dalam data dengan meniru kinerja pikir manusia dalam mempelajari sesuatu contoh atau pola dalam menyelesaikan masalah [23]. Jaringan Saraf Artifisial toleran terhadap eror sehingga dapat beradaptasi terhadap *input* yang berbeda, bahkan menggunakan eror tersebut untuk menyesuaikan bobot parameter

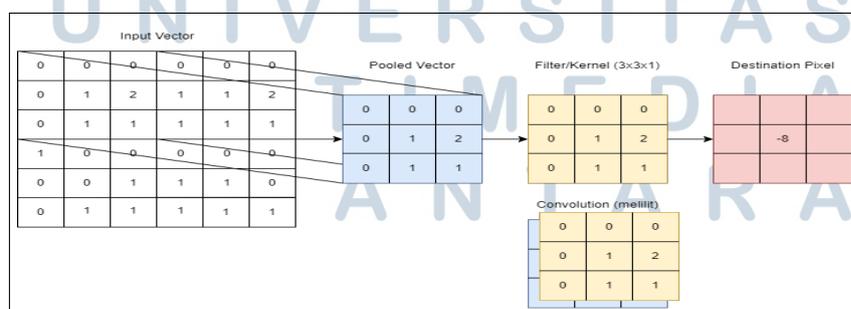
model guna mengurangi eror pada iterasi berikutnya [24]. Dalam penelitian ini, pembelajaran yang dilakukan merupakan *supervised learning* karena data yang digunakan dalam pelatihan. *Supervised learning* merupakan pembelajaran yang dilakukan melalui data dengan label *output* yang sudah di ketahui dan hasil klasifikasi dibandingkan dengan label yang sudah ada pada data tersebut [25].

2.4 Convolutional Neural Network

Convolutional Neural Network atau Jaringan Saraf Konvolusional merupakan jenis jaringan saraf artifisial umpan maju yang melibatkan struktur konvolusi untuk melakukan ekstraksi fitur pada data tanpa perlu dilakukan secara manual [26]. Algoritma jaringan saraf ini umumnya digunakan untuk mengenali pola pada citra karena dapat mengurangi bobot parameter yang diolah oleh setiap neuron [27]. Pengurangan bobot pada neuron dilakukan dengan membagi data sesuai ukuran kernel konvolusi untuk diproses oleh setiap neuron yang terhubung dengan neuron lain yang mengolah data yang berdekatan [28]. Terdapat beberapa jenis lapisan dalam arsitektur *Convolutional Neural Network*, yakni *convolution layer*, *pooling layer*, dan *fully-connected layer*.

2.4.1 Convolution Layer

Convolution layer atau kernel merupakan matriks yang menjadi filter tersebar pada keseluruhan data *input*. Kernel melakukan filter pada data sepanjang dimensi spasial saat menelusuri data untuk memetakan aktivasi secara dua dimensi [27]. Pada lapisan konvolusi tingkat pertama, kernel digunakan untuk mendeteksi fitur kasat mata seperti tepi dan lengkung dari citra, sedangkan pada tingkat yang lebih tinggi digunakan untuk mengenali fitur yang lebih abstrak [28]. Ilustrasi *convolution layer* dapat dilihat pada Gambar 2.1.



Gambar 2.1. Ilustrasi contoh convolution layer

2.4.2 Activation Function

Activation Function atau fungsi aktivasi merupakan fungsi yang menentukan sinyal *output* berdasarkan perhitungan *input* dan beban neuron yang mengolahnya. *Activation function* digunakan dalam jaringan saraf untuk menentukan besaran stimulus yang mampu mengaktifkan respons dari neuron [29]. Penerapan *activation function* memungkinkan jaringan berlapis ganda untuk mendeteksi fitur non-linier [28]. Beberapa fungsi aktivasi yang digunakan dalam *Convolutional Neural Network* dikalkulasi berdasarkan persamaan-persamaan berikut.

$$\text{Linear}(x) = x \quad (2.1)$$

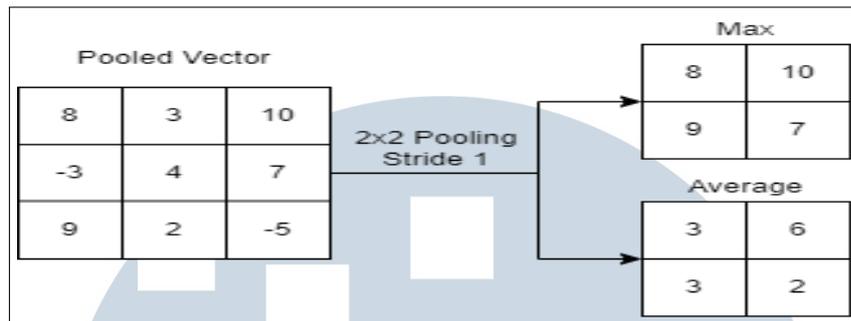
$$\text{Sigmoid}(x) = \frac{1}{1 + \exp^{-x}} \quad (2.2)$$

$$\text{ReLU}(x) = \max(0, x) \quad (2.3)$$

$$\text{BinaryStep}(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases} \quad (2.4)$$

2.4.3 Pooling Layer

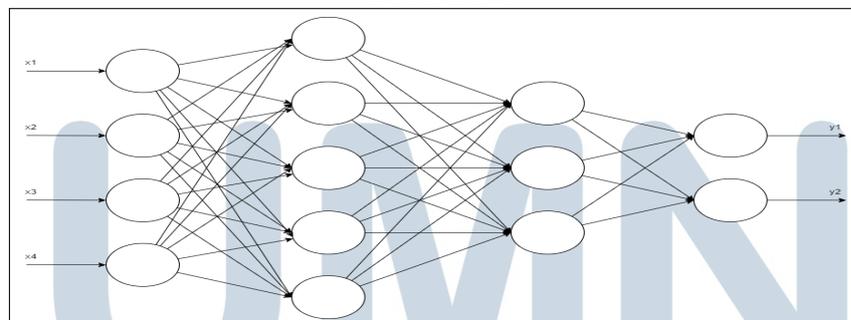
Pooling layer merupakan matriks yang melakukan pengumpulan matriks kernel dan menggunakan korelasi lokal pada citra berdasarkan hasil konvolusi kernel tersebut untuk melakukan *downsampling* pada citra yang mengurangi kompleksitas dimensi namun tetap mempertahankan informasi penting pada citra tersebut [26]. Konsep *Pooling Layer* juga dapat digunakan untuk pemetaan hasil konvolusi terhadap kelas yang dihubungkan secara langsung kepada *Fully-Connected Layer* yang mewakili kelas yang dikenal sebagai *Global Pooling Layer* [30]. Dalam arsitektur *Convolutional Neural Network* umumnya tipe *pooling* yang digunakan adalah *max pooling* yang mencari nilai tertinggi dalam setiap wilayah kernel, *min pooling* yang mencari nilai terendah dalam setiap wilayah kernel, dan *average pooling* yang mencari nilai rata-rata dalam setiap wilayah kernel [31]. Perbedaan dan visualisasi dari kedua tipe *pooling* diilustrasikan pada Gambar 2.2.



Gambar 2.2. Ilustrasi pooling layer

2.4.4 Fully-Connected Layers

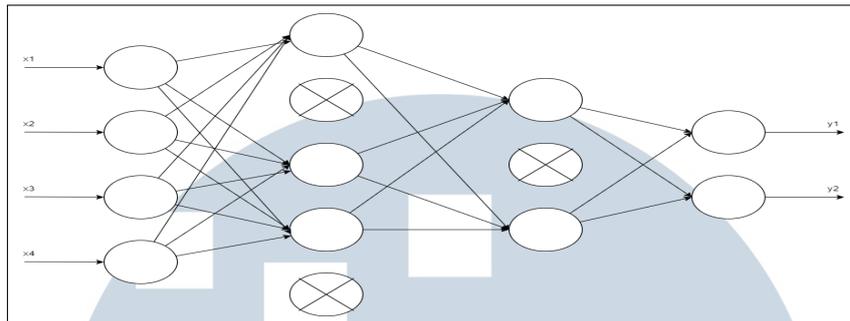
Fully-Connected Layers atau yang juga umum disebut *Dense Layer* merupakan lapisan yang terdiri atas jaringan neuron yang terhubung pada seluruh lapisan sebelumnya pada arsitektur *Convolutional Neural Network* tanpa terhubung pada tingkatan tersebut [27]. *Fully-connected Layers* digunakan untuk melakukan prediksi berdasarkan penalaran dari informasi yang telah diperoleh dari neuron pada tingkat sebelumnya dengan fungsi aktivasi yang ditetapkan [28]. Bentuk *Fully-Connected Layers* diilustrasikan pada Gambar 2.3.



Gambar 2.3. Ilustrasi fully-connected layer

2.4.5 Dropout Layer

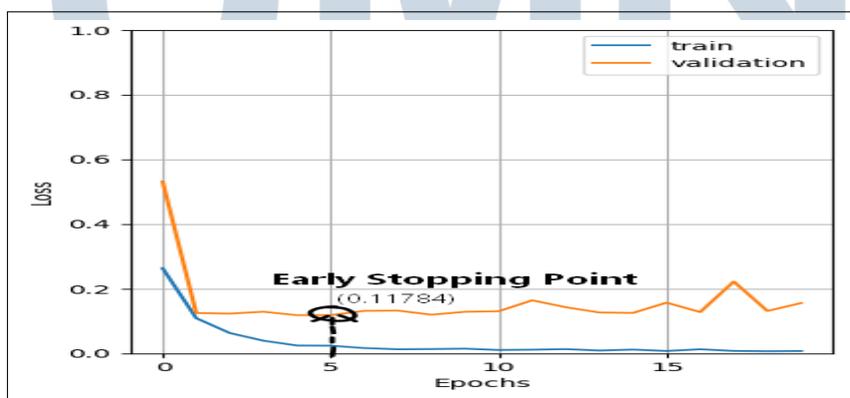
Dropout merupakan sebuah metode regularisasi yang digunakan untuk menghindari *overfitting* dalam sebuah sistem jaringan saraf dengan sementara mengabaikan beberapa unit neuron secara acak. Penggunaan *Dropout* umumnya dilakukan pada *fully-connected layers* untuk meningkatkan varietas bagi neuron yang aktif setelah *dropout* agar dapat memahami fitur yang memberikan hasil benar untuk konteks yang lebih umum [32]. *Dropout* yang dilakukan pada *fully-connected layers* diilustrasikan sebagai Gambar 2.4.



Gambar 2.4. Ilustrasi dropout

2.5 Early Stopping

Generalisasi model merupakan sebuah isu yang perlu diperhatikan dalam pembelajaran mesin *supervised learning* karena model dapat berfungsi dengan baik pada set data latih namun tidak sesuai dengan set data uji yang menandakan bahwa model hanya bisa menghafal data daripada memahami hubungan yang ada pada data [33]. Fenomena tersebut dikenal dengan *overfitting* dan salah satu cara mencegahnya adalah dengan *Early Stopping*, yang merupakan sebagai salah satu proses regularisasi yang dapat digunakan dalam pembelajaran mesin untuk menghindari *overfitting* terhadap data latih. *Early stopping* dapat dilakukan pada pembelajaran mesin yang menggunakan iterasi dalam prosesnya dan dapat dilakukan dengan mempertimbangkan metrik yang dievaluasi pada set data evaluasi yang mewakili sifat data pada kasus nyata atau setidaknya pada set data uji [34]. Gambar 2.5 merupakan ilustrasi konvergensi antara data latih dan data validasi beserta titik yang baik untuk melakukan *Early Stopping*.



Gambar 2.5. Ilustrasi contoh Early Stopping

2.6 Confusion Matrix

Confusion Matrix merupakan tabel pengujian yang digunakan dalam pembelajaran mesin berbasis klasifikasi yang diawasi. Komponen matriks tersebut berupa baris yang merupakan data sebenarnya dan kolom yang merupakan data hasil klasifikasi mesin dan sel pada persilangan keduanya diisi dengan warna yang semakin gelap untuk menggambarkan densitas data [35]. Jumlah baris dan kolom pada matriks berdasarkan jumlah kelas yang ada, jika kelas berjumlah n , maka ukuran matriks adalah $n \times n$ yang berdasarkan deskripsi menginformasikan tingkat polimerisasi dalam kategori dan penyebaran antar kategori [36]. *Confusion Matrix* mampu memvisualisasikan hasil klasifikasi benar baik dalam bentuk *true positive* maupun *true negative*, dan juga eror tipe satu (*false positive*) dan tipe dua (*false negative*) akibat kesalahan dalam pemberian label. Gambar 2.6 mengilustrasikan penempatan label dari *Confusion Matrix*.

True Values	False	True Negative	False Positive
	True	False Negative	True Positive
		False	True
		Predicted Values	

Gambar 2.6. Penempatan label pada confusion matrix

Berdasarkan nilai yang divisualisasikan oleh *confusion matrix*, metrik evaluasi model yang dibangun dapat dihitung melalui perhitungan

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.5)$$

$$Precision = \frac{TP}{TP + FP} \quad (2.6)$$

$$Recall = \frac{TP}{TP + FN} \quad (2.7)$$

$$F1 - score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (2.8)$$

Pada perhitungan metrik, TP merupakan *true positive*, TN merupakan *true negative*, FP merupakan *false positive*, dan FN merupakan *false negative* [37].