

BAB 3

ANALISIS DAN PERANCANGAN


3.1 Analysis Masalah

Flappy bird memiliki komponen-komponen yang dinamis mulai dari posisi burung, pipa dan celah antar pipa yang beragam, sehingga memiliki *state space* yang besar dan Perubahan beberapa *pixel* saja merupakan *state* yang berbeda. Berdasarkan penelitian Moritz [1] penggunaan *Q-Learning* saja memiliki kekurangan yaitu untuk mengetahui *Q-value* suatu *action* pada *state* tertentu *agent* harus mencobanya terlebih dahulu sehingga butuh sangat banyak percobaan untuk mendapatkan kemampuan yang baik pada *agent* dalam memainkan permainan. Maka menambahkan *action value function approximation* untuk memprediksi *Q-value* pada *Q-Learning* dan diharapkan dapat menggeneralisasi *state* sehingga *agent* bisa memperkecil jumlah percobaan dengan tetap mendapatkan hasil yang baik [3]. Pada penelitian Mnih dan kawan-kawan [4] menjelaskan penggunaan CNN sebagai *action value function approximation* pada *Q-Learning* dengan *input* citra dari keadaan permainan dan mendapatkan hasil yang baik dimana tiga dari tujuh permainan Atarai 2600 berhasil melampaui kemampuan manusia yaitu *breakout* dengan skor 168, *enduro* dengan skor 470 dan *pong* dengan skor 20. Pada penelitian yang dilakukan Ajay Rao dan kawan-kawan [5] yang mengimplementasikan *Q-Learning* dengan CNN sebagai *action value function approximation* pada delapan permainan berbeda, dijelaskan bahwa penggunaan CNN sebagai *action value function approximation* dapat menggeneralisir *state space* yang dinamis dan cocok diterapkan pada kasus *autonomus systems*.

Maka dari itu pada penelitian ini akan mengimplementasikan CNN sebagai *action value function approximation* pada *Q-Learning* untuk memainkan permainan *flappy bird* dan akan dilihat pengaruhnya jumlah percobaan pada proses pembelajaran dan skor yang didapat *agent* dalam memainkan permainan.

3.2 Analisis Proses

Analisis proses adalah tahapan untuk menganalisis metode yang akan digunakan pada sistem. Sistem yang akan dibangun terdapat dua tahap utama yang akan dilakukan, yaitu tahap eksplorasi dan eksloitasi. Satu kali iterasi pada tahap ini sama dengan satu *frame* pada permainan. Adapun Gambaran tahapan yang akan dilakukan dapat dilihat pada Gambar 3.1 Tahapan Proses yang Akan Dilakukan.



Gambar 3.1 Tahapan Proses yang Akan Dilakukan

Tahap pertama adalah eksplorasi. Pada tahap ini *agent* akan mempelajari cara memainkan permainan *flappy bird*, tahap ini dimulai dari *agent* mendapat *current state* dari permainan berupa citra keadaan permainan, lalu dilakukan *preprocessing* terhadap citra tersebut. *Preprocessing* terdiri dari pemotongan citra, konversi ke *grayscale*, *resize* dan *thresholding*. Setelah *preprocessing* lalu *agent* akan memilih *action* dengan probabilitas *epsilon*, setelah *action* didapat dan dieksekusi di permainan *agent* akan mendapat *reward*, *next state* dan *terminal* sebagai umpan balik. Lalu, akan dilakukan *preprocessing* terhadap *next state* yang telah didapat, tahapan *preprocessing* sama dengan yang sebelumnya hanya saja *input*-nya sekarang adalah *next state*. Setelah itu, masukan *current state* hasil *preprocessing*, *action*, *reward*, *next state* dan *terminal* (disebut *experience*) ke dalam *reply memory* dan melatih model CNN dengan data latih (*experience*) yang diambil secara acak dari *reply memory* sebanyak 32 buah (*batch*). Terakhir, lakukan perubahan *next*

state hasil *preprocessing* menjadi *current state* dan proses diulangi dari tahap memilih *action* dengan probabilitas epsilon. Tahap eksplorasi ini memiliki kondisi henti yaitu ketika *agent* menyentuh skor 20 dan saat *agent* sudah memainkan permainan selama 1000000 *frame* [4]. Alasan pengambilan kondisi henti tersebut karena pada skor 20 dianggap sudah cukup besar dan *agent* sudah bisa melewati berbagai macam *state*, untuk nilai lainnya akan diujikan pada bagian pengujian.

Tahap kedua adalah eksplotasi. Pada tahap ini *agent* akan menggunakan model CNN yang telah dilatih pada tahap eksplotasi. Tahap ini diawali dengan *agent* mendapat *current state* dari permainan, lalu *current state* tersebut dilakukan *preprocessing* yang tahapannya sama dengan yang sebelumnya. Selanjutnya *agent* akan memilih *action* menggunakan model CNN yang telah dilatih pada tahap eksplorasi dengan *input current state* yang telah di *preprocessing*. Output dari model CNN adalah nilai *Q-value* (regresi) dari masing-masing *action* yang bisa dilakukan *agent* (model CNN memiliki 2 output sesuai *action* yang bisa dilakukan, yaitu 0 untuk turun dan 1 untuk naik). Setelah *Q-value* dari setiap *action* didapatkan, lalu akan dipilih *action* dengan *Q-value* terbesar. Lalu *action* dieksekusi dan *agent* mendapat *next state* sebagai umpan balik dari permainan. Proses akan diulang dari tahap *preprocessing current state*.

3.3 Analisis Data Masukan

Adapun data masukan yang digunakan antara lain:

1) *State*

State yang akan diinputkan pada sistem adalah citra dari keadaan (*state*) permainan *flappy bird*. Ada dua jenis *state*, yaitu *current state* yang merupakan keadaan saat ini atau keadaan sebelum *action* dieksekusi dan *next state* adalah keadaan setelah *action* dieksekusi. Contoh *state* dapat dilihat pada Gambar 3.2 *State Permainan*.



Gambar 3.2 State Permainan

2) Action

Pada permainan *flappy bird* terdapat 2 *action* yang bisa dilakukan *agent* dan setiap *action* diberi nilai *integer*. Berikut adalah *action* yang dapat dilakukan:

1. Nilai 0 untuk turun
2. Nilai 1 untuk naik

3) Reward

Reward adalah nilai yang didapat *agent* untuk setiap *action* yang dilakukan pada *state* tertentu. *Reward* yang digunakan pada penelitian ini antara lain:

1. +1 ketika berhasil melewati celah pipa.
2. 0.1 ketika burung hidup.
3. -1 ketika burung mati.

Penetuan *reward* didasarkan pada tujuan dari permainan, pada permainan *flappy bird* pemain harus harus melewati pipa sebanyak banyaknya maka ketika berhasil melewati pipa harus diberi *reward* maksimal, dan ketika mati harus diberi *reward* minimal. Namun ada kondisi dimana burung tetap hidup namun tidak melewati pipa, situasi ini bukan situasi yang buruk namun tidak bisa disebut baik karena belum melakukan tujuan utama permainan sehingga, kondisi ini akan diberi *reward* dengan nilai positif yang kecil.

4) Terminal

Terminal adalah status permainan setelah *action* dilakukan, tipe data dari *terminal* adalah *boolean*. *Terminal* bernilai *True* jika setelah *action* dilakukan permainan berakhir, dalam *flappy bird* permainan berakhir jika burung menabrak pipa atau tanah. *Terminal* bernilai *false* jika burung masih bertahan hidup setelah *action* dilakukan.

3.4 Analisis Preprocessing

Preprocessing adalah suatu proses untuk mengolah data masukan asli (disebut *state*) sebelum data tersebut diolah pada tahap selanjutnya. Masukan data asli adalah citra dari keadaan *state* pada permainan. Citra tersebut akan melalui proses *preprocessing* meliputi pemotongan, konversi citra RGB ke *grayscale* dan *thresholding*.

1) Pemotongan


Pemotongan citra adalah proses dimana membuang sebagian bagian dari citra dengan koordinat tertentu. Pada proses ini citra asal yang memiliki ukuran 288x512 akan dilakukan pemotongan pada sumbu Y dimana akan dipertahankan *pixel* pada sumbu Y dari koordinat 0 sampai 400 dan sisanya yaitu koordinat 401 sampai 512 sedangkan sumbu X tidak akan dilakukan pemotongan, maka didapatkan:

$$\begin{aligned} Y_{top} &= 0 && \text{(Batas atas citra yang dipertahankan)} \\ Y_{bottom} &= 400 && \text{(Batas bawah citra yang dipertahankan)} \\ X_{left} &= 0 && \text{(Batas kiri Citra yang dipertahankan)} \\ X_{right} &= 288 && \text{(Batas kanan Citra yang dipertahankan)} \end{aligned}$$

Sehingga didapatkan koordinat titik pojok kiri atas citra yang akan dipertahankan yaitu (X_{left}, Y_{top}), koordinat titik pojok kanan bawah yang akan dipertahankan yaitu (X_{right}, Y_{bottom}). Maka citra yang terdapat pada koordinat (0, 0) sampai koordinat (288, 400) akan dipertahankan dan citra dengan koordinat diluar jangkauan tersebut yaitu koordinat (0, 401) sampai koordinat (288, 512) akan dibuang. Ukuran citra setelah pemotongan adalah selisih dari koordinat paling ujung disetiap sumbu.

$$\begin{aligned}
 X' &= X_{right} - X_{left} \\
 &= 288 - 0 \\
 &= 288 \\
 Y' &= Y_{bottom} - Y_{top} \\
 Y' &= 400 - 0 \\
 Y' &= 400
 \end{aligned}$$

Adapun ilustrasi pemotongan dapat dilihat pada Gambar 3.3 Proses Pemotongan.



Gambar 3.3 Proses Pemotongan

Setelah melalui proses pemotongan, ukuran citra akan berubah dari asalnya $288 \text{ pixels} \times 512 \text{ pixels}$ menjadi $288 \text{ pixels} \times 400 \text{ pixels}$.

2) Konversi Citra RGB ke *Grayscale*

Citra yang menjadi masukan awalnya memiliki tiga channel warna yaitu *red*, *blue* dan *green*. Pada proses konversi citra RGB ke *grayscale* ini, channel pada citra akan berubah menjadi satu dan ini dapat meringankan proses komputasi pada sistem. Adapun tabel sample nilai RGB dari citra dapat dilihat pada Tabel 3.1 Nilai Pixel RGB dari Citra.

Tabel 3.1 Nilai Pixel RGB dari Citra

x, y	0	1	2	3	286	287
0	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]
1	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]
2	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]
3	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]	[202 192 78]
.....
398	[112 226 94]	[112 226 94]	[112 226 94]	[112 226 94]	[112 226 94]	[112 226 94]
399	[112 226 94]	[112 226 94]	[112 226 94]	[112 226 94]	[112 226 94]	[112 226 94]

Perhitungan konversi citra RGB ke *grayscale* dapat menggunakan persamaan (2.1), berikut adalah persamaannya.

$$Gray(x,y) = 0.299 * R + 0.587 * G + 0.114 * B \quad (2.1)$$

Berikut adalah contoh perhitungan yang akan menghitung nilai *grayscale* untuk *pixel* ke (0, 0).


$$\begin{aligned} Pixel(0, 0) &= 0.299 * 202 + 0.587 * 192 + 0.114 * 78 \\ &= 182 \end{aligned}$$

Lakukan konversi nilai RGB ke *Grayscale* ke seluruh pixel pada citra. Hasil perhitungan secara keseluruhan dapat dilihat pada Tabel 3.2 Nilai *Pixel Grayscale*.

Tabel 3.2 Nilai Pixel Grayscale

x, y	0	1	2	3	286	287
0	182	182	182	182	182	182
1	182	182	182	182	182	182
2	182	182	182	182	182	182
3	182	182	182	182	182	182
.....
398	177	177	177	177	177	177
399	177	177	177	177	177	177

Citra hasil konversi ke derajat keabuan dapat dilihat pada Gambar 3.4 Citra *Grayscale*.



Gambar 3.4 Citra *Grayscale*

3) *Resize*

Resize akan merubah ukuran citra sesuai dengan yang dikehendaki. *Resize* dapat memperkecil atau memperbesar citra, pada penelitian ini citra akan di *resize* menjadi lebih kecil sehingga akan terjadi pengurangan beberapa *pixel*. Ukuran awal citra adalah 288 *pixels* x 512 *pixels*, ukuran tersebut akan di *resize* menjadi 32 *pixels* x 32 *pixels* [22]. Pada proses penurunan ukuran akan diambil nilai tengah dari suatu kernel untuk mewakili kernel tersebut [9]. Penentuan ukuran kernel diambil dari hasil bagi ukuran citra awal dengan citra hasil. Berikut perhitungan ukuran kernel untuk sumbu x.

$$\begin{aligned} \text{kernelX} &= \text{panjang sumbu X citra awal} / \text{panjang } \textit{resize} \text{ sumbu X} \\ &= 288 / 32 \\ &= 9 \end{aligned}$$

Berikut perhitungan ukuran kernel untuk sumbu y.

$$\begin{aligned} \text{kernelY} &= \text{panjang sumbu Y citra awal} / \text{panjang } \textit{resize} \text{ sumbu Y} \\ &= 400 / 32 \\ &= 12,5 \end{aligned}$$

Setelah hasil perhitungan didapat ukuran kernel sumbu X 9 dan sumbu Y 12,5. Pada nilai pixel citra hasil *resize* *pixel* ke 0,0 akan mencakup kernel pada pixel ke-0 sampai ke-8 sumbu X dan pixel ke-0 sampai ke-11,5 sumbu Y, maka akan dicari

pixel tengah yang akan menjadi perwakila kernel tersebut, berikut perhitungan penentuan koordinat nilai tengah pada kernel.

$$\begin{aligned} \text{sumbuX} &= X_{\text{AwalKernel}} + ((X_{\text{AkhirKernel}} - X_{\text{AwalKernel}}) / 2) \\ &= 0 + ((8 - 0) / 2) \\ &= 0 + (4) \\ &= 4 \end{aligned}$$

$$\begin{aligned} \text{sumbuY} &= Y_{\text{AwalKernel}} + ((Y_{\text{AkhirKernel}} - Y_{\text{AwalKernel}}) / 2) \\ &= 0 + ((11,5 - 0) / 2) \\ &= 0 + 5,75 \\ &= 5,75 \end{aligned}$$

Karena nilai pixel pada pojok kiri atas dan kanan bawah sudah diketahui, tinggal mencari tahu nilai pixel pada pojok kiri dan kanan bawah dari bagian dasar kernel. Berikut perhitungan untuk mencari tahu nilai pojok kiri dan kanan bawah menggunakan interpolasi terhadap sumbu Y menggunakan persamaan (2.3).

$$f(x, y) = \frac{y_2-y}{y_2-y_1} \cdot f(x, y_1) + \frac{y-y_1}{y_2-y_1} \cdot f(x, y_2) \quad (2.3)$$

$$\begin{aligned} \text{Pixel}(0, 11.5) &= \frac{12-11,5}{12-11} \cdot \text{pixel}(0, 11) + \frac{11,5-11}{12-11} \cdot \text{pixel}(0, 12) \\ &= \frac{12-11,5}{12-11} \cdot 182 + \frac{11,5-11}{12-11} \cdot 182 \\ &= 182 \end{aligned}$$

$$\begin{aligned} \text{Pixel}(8, 11.5) &= \frac{12-11,5}{12-11} \cdot \text{pixel}(8, 11) + \frac{11,5-11}{12-11} \cdot \text{pixel}(8, 12) \\ &= \frac{12-11,5}{12-11} \cdot 182 + \frac{11,5-11}{12-11} \cdot 182 \\ &= 182 \end{aligned}$$

Setelah nilai pojok kiri dan kana bawah diketahui, selanjutnya cari nilai tengah bagian bawah kernel menggunakan interpolasi terhadap sumbu X.

$$\begin{aligned} \text{Pixel}(4, 11.5) &= \frac{8-4}{8-0} \cdot \text{pixel}(0, 11.5) + \frac{4-0}{8-0} \cdot \text{pixel}(8, 11.5) \\ &= \frac{8-4}{8-0} \cdot 182 + \frac{4-0}{8-0} \cdot 182 \\ &= 182 \end{aligned}$$

Setelah nilai tengah bagian atas dan dasar kernel diketahui, selanjutnya hitung nilai tengah dari kernel tersebut menggunakan interpolasi terhadap sumbu Y, Berikut perhitungannya.


$$\begin{aligned}
 Pixel(4, 5.75) &= \frac{11.5-5.75}{11.5-0} \cdot pixel(4, 0) + \frac{5.75-0}{11.5-0} \cdot pixel(4, 11.5) \\
 &= \frac{11.5-5.75}{11.5-0} \cdot 182 + \frac{5.75-0}{11.5-0} \cdot 182 \\
 &= 182
 \end{aligned}$$

Jadi, nilai pixel yang akan menjadi perwakilan dari kernel dari $pixel(0, 0)$ sampai $(8, 11.5)$ adalah nilai $pixel(4, 5.75)$ yaitu 182 dan menjadi nilai pada citra hasil *resize* di $pixel(0,0)$. Perhitungan tersebut dilakukan terhadap seluruh kernel, untuk keseluruhan proses *resize* dapat dilihat pada Tabel 3.3 Nilai Pixel Citra Hasil *Resize*.

Tabel 3.3 Nilai Pixel Citra Hasil *Resize*

x, y	0	1	2	3	30	31
0	182	182	182	182	18	182
1	182	182	182	182	18	182
2	182	182	182	182	18	182
3	182	182	182	182	18	182
.....
30	177	174	174	173	0	177
31	177	177	177	177	0	177

Citra hasil proses *resize* dapat dilihat pada Gambar 3.5 Citra Hasil Proses *Resize*.



Gambar 3.5 Citra Hasil Proses *Resize*

4) *Thresholding*

Thresholding adalah metode yang membuat nilai citra hanya terdiri dari dua nilai. *Thresholding* memiliki ambang batas p penelitian ini akan menggunakan metode *thresh binary inverted* dengan nilai ambang batas 127, nilai maksimal 255 dan minimal 0, untuk persamaan dapat dilihat pada persamaan (2.2)


$$f(x, y) = \begin{cases} 0, & img(x, y) > 127 \\ 255, & img(x, y) \leq 127 \end{cases} \quad (2.2)$$

Setelah dilakukan operasi pada persamaan diatas, didapat kan hasil *thresh binary inverted* seperti pada Tabel 3.4 Nilai Pixel Hasil *Tresh Binary Inverted*.

Tabel 3.4 Nilai Pixel Hasil *Tresh Binary Inverted*

x, y	0	1	2	3	30	31
0	0	0	0	0	255	0
1	0	0	0	0	255	0
2	0	0	0	0	255	0
3	0	0	0	0	255	0
.....
30	0	0	0	0	255	0
31	0	0	0	0	255	0


Citra hasil *thresh binary inverted* dapat dilihat pada Gambar 3.6 Citra Hasil *Tresh Binary Inverted*.



Gambar 3.6 Citra Hasil *Tresh Binary Inverted*

3.5 Analisis Pemilihan Action dengan Probabilitas Epsilon

Proses pemilihan action dengan probabilitas epsilon terdiri dari beberapa tahapan yang dapat dilihat pada Gambar 3.7 Tahapan Proses Memilih Action dengan Probabilitas Epsilon.



Gambar 3.7 Tahapan Proses Memilih Action dengan Probabilitas Epsilon

Pertama-tama insialisasi nilai awal epsilon yaitu 1.0, akhir epsilon 0.0001 dan nilai awal akan terus berkurang di setiap frame-nya sebesar 0.0000198. Selanjutnya bangkitkan nilai *random* antara 0 sampai 1, lalu bandingkan dengan epsilon jika

nilai *random* lebih kecil dari nilai epsilon, maka *agent* akan memilih *action* secara acak antara 0 atau 1. Jika nilai *random* lebih besar dari nilai epsilon, maka *agent* akan memilih *action* dengan nilai *Q-value* terbesar yang didapat dari *output feedforward CNN* dengan *input-an current state*. Setelah *action* terpilih, *agent* akan mengeksekusi *action* tersebut di permainan dan mendapatkan *feedback* berupa *next state reward* dan *terminal*. Rekaman yang berisi *current state*, *action*, *reward*, *next state* dan *terminal* dari proses ini disebut *experience*.


3.6 Analysis Reply Memory

Reply memory adalah sebuah wadah yang akan menyimpan data *experience*, satu *experience* terdiri dari *current state*, *reward*, *action*, *next state* dan *terminal* yang dikumpulkan disetiap *framanya* pada proses eksplorasi dengan maksimal jumlah data *experience* sebanyak 1000000. Data yang terdapat pada reply memory akan digunakan sebagai data latih pada proses pelatihan CNN, pengambilan data akan dilakukan secara acak berjumlah 32 buah. Penggunaan *reply memory* bertujuan untuk memutus korelasi antar satu data latih dengan yang lainnya yang dapat menyebabkan *agent* cenderung melakukan satu *action* saja. Selain itu, penggunaan *reply memory* dapat meningkatkan efisiensi *agent* dalam belajar dari pada belajar langsung dari data yang baru saja didapat tanpa menyimpannya terlebih dahulu di *reply memory* [4].

3.7 Analysis Metode *Q-Learning* yang Dikombinasikan dengan *Convolutional Neural Network (CNN)*

Pada metode pengkombinasian ini CNN akan digunakan sebagai *action value function approximation* pada *Q-Learning* yang akan memprediksi nilai *Q-value* untuk setiap *action* pada kondisi tertentu (*state* permainan menjadi *inputan*) dan *agent* akan menentukan *action* yang akan diambil dengan membandingkan *Q-value* setiap *action*, *action* dengan *Q-value* terbesar yang akan dipilih. Pada proses pelatihan CNN, *target* yang akan digunakan untuk menghitung nilai *loss* adalah

persamaan *value iteration update* yang terdapat pada metode *Q-learning*. Pengkombinasian *Q-Learning* dengan CNN dapat menggeneralisasi *state* sehingga dapat mengurangi jumlah percobaan pada proses pembelajaran dengan tetap memberikan hasil yang baik pada *agent*. Adapun arsitektur dari CNN dapat dilihat pada Gambar 3.8 Arsitektur CNN.




Gambar 3.8 Arsitektur CNN


Pada arsitektur CNN yang digunakan pada penelitian ini memiliki input berukuran 32×32 , *convolutional layer A* dengan ukuran 5×5 memiliki 3 buah filter, 3 *stride* dengan fungsi aktivasi ReLU dan akan menghasilkan feature map $10 \times 10 \times 3$, selanjutnya *convolutional layer B* dengan ukuran 7×7 memiliki 3 buah filter, 1 *stride* dengan fungsi aktivasi ReLU dan akan meghasilkan feature map $4 \times 4 \times 3$ dan terakhir *Fully-connected layer* dengan input layer 48 node, *hidden layer* 10 node dengan fungsi aktivasi ReLu dan *output layer* dengan 2 buah node (sejumlah *action* yang bisa dilakukan *agent*) dan fungsi aktivasi *linear* [4] [10] [22]. Keluaran yang dihasilkan berisi perkiraan nilai *Q-value* untuk setiap *action* yang bisa dilakukan *agent* (nilai 0 untuk diam dan 1 untuk *flap*). Semua bobot pada setiap layer akan diisi nilai acak dengan rentang nilai -0.5 sampai 0.5 dan untuk nilai biasnya akan diisi 0 [23].

3.7.1. Analisis Pelatihan CNN

Pada proses pelatihan CNN data latih yang akan digunakan adalah sample acak yang diambil dari *reply memory*. Sample tersebut yang berisi *current state* setelah *preprocessing*, *action*, *reward*, *next state* setelah *preprocessing* dan *terminal*. Pengambilan data latih dilakukan secara acak sejumlah 32 buah di *reply memory*. Berikut adalah contoh sample acak dari *reply memory* yang akan digunakan pada proses pelatihan, untuk *current state* dapat dilihat pada Gambar 3.9 *Current State*, untuk *Next State* dapat dilihat pada Gambar 3.10 *Next State*, nilai *action*-nya adalah 0, nilai *reward*-nya adalah -1 dan *terminal*-nya *True*.



Gambar 3.9 Current State



Gambar 3.10 Next State

Selanjutnya CNN akan dilatih dengan data latih tersebut. Pada proses pelatihan CNN terdapat beberapa tahap antara lain *feedforward* dan *backpropagation*.

3.7.1.1. Feedforward

Pada tahap *feedforward* akan dilakukan proses CNN dari awal masukan melewati *convolutional layer A*, *convolutional layer B* dan *fully-connected layer* hingga dihasilkan 2 buah output yang berisi *Q-Value* untuk masing-masing *action*.

1. Convolutional Layer A

Pada *convolutional layer* akan dilakukan konvolusi antara matriks citra masukan dengan matriks-matriks pada filter A. Filter akan digeser hingga keseluruhan permukaan dan menghasilkan *feature map* FA. Pada *convolutional layer* A terdapat 3 filter berukuran 5x5 dengan *stride* 3. Citra yang menjadi inputan telah dijelaskan pada bagian analisis pelatihan CNN, yaitu Gambar 3.9 *Current State* dan nilai pixelnya dapat dilihat pada Tabel 3.5 Nilai Pixel Citra Masukan C (*Current State*).

Tabel 3.5 Nilai Pixel Citra Masukan C (*Current State*)

x, y	0	1	2	3	4	5	6	30	31
0	0	0	0	0	0	0	0	255	0
1	0	0	0	0	0	0	0	255	0
2	0	0	0	0	0	0	0	255	0
3	0	0	0	0	0	0	0	255	0
4	0	0	0	0	0	0	0	255	0
5	0	0	0	0	0	0	0	255	0
6	0	0	0	0	0	0	0	255	0
.....
30	0	0	0	0	0	0	255	255	255
31	0	0	0	0	0	0	0	255	255

Bobot filter A1 dapat dilihat pada Tabel 3.6 Bobot *Convolutional Filter* A1 dan untuk bias nya diisi 0.

Tabel 3.6 Bobot *Convolutional Filter* A1


x, y	0	1	2	3	4
0	0,05	0,34	0,38	0,11	0,29
1	0,21	0,27	-0,45	0,24	-0,17
2	0,41	0,22	0,36	-0,18	-0,14
3	0,23	-0,24	-0,45	-0,07	-0,03
4	0,01	-0,14	0,46	0,35	0,22

Proses pada *convolutional layer* A adalah operasi konvolusi antara citra masukan C dengan Tabel 3.6 Bobot *Convolutional Filter* A1, dimulai dari pojok kiri atas citra lalu bergeser hingga pojok kanan bawah, setiap hasil konvolusi ditambahkan dengan bias. Berikut ini adalah contoh operasi konvolusi menggunakan persamaan (2.5) citra C terhadap filter A1 yang menghasilkan pixel baris satu kolom 1 pada *feature map* FA1.

$$FA1_{ij} = \sum_{m=0}^4 \sum_{n=0}^4 A1_{m,n} C_{i*3+m, j*3+n} + bA_0 \quad (2.5)$$

$$\begin{aligned} FA1_{0,0} &= (A1_{0,0} * C_{0,0} + A1_{0,1} * C_{0,1} + A1_{0,2} * C_{0,2} + \dots + A1_{4,4} * C_{4,4}) + bA_0 \\ &= (0,05*0 + 0,34*0 + 0,38*0 + \dots + 0,22*0) + 0 \\ &= 0 \end{aligned}$$

Proses tersebut terus diulang hingga seluruh permukaan citra terkena, untuk visualisasinya dapat dilihat pada Gambar 3.11 Visualisasi 1 Operasi pada *Convolution Layer A1*




Gambar 3.11 Visualisasi 1 Operasi pada Convolution Layer A1

Setelah itu geser filter ke kanan sebanyak nilai *stride* yaitu 3 dan lakukan kembali operasi konvolusi.

$$\begin{aligned} FA1_{0,1} &= (A1_{0,0} \cdot C_{0,3} + A1_{0,1} \cdot C_{0,4} + A1_{0,2} \cdot C_{0,5} + \dots + A1_{4,4} \cdot C_{4,7}) + bA_0 \\ &= (0,05*0 + 0,34*0 + 0,38*0 + \dots + 0,22*0) + 0 \\ &= 0 \end{aligned}$$

Berikut adalah visualisasi operasi konvolusi filter A1 yang menghasilkan FA[1]0,1 dapat dilihat pada Gambar 3.12 Visualisasi 2 Operasi Convolution Layer A1



Gambar 3.12 Visualisasi 2 Operasi Convolution Layer A1

Hasil proses keseluruhan pada filter A1 dapat dilihat pada tabel Tabel 3.7 *Feature Map FA1*.

Tabel 3.7 Feature Map FA1

x, y	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	234,6	538,05
1	0	0	0	0	0	0	0	0	234,6	538,05
2	0	0	0	0	0	0	0	48,45	137,7	538,05
3	0	0	0	0	0	0	0	30,6	257,55	293,25
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	56,1	226,95	173,4
7	0	0	0	0	0	0	0	-79,05	160,65	313,65
8	0	0	0	0	0	0	0	0	234,6	538,05
9	0	38,25	7,65	58,65	0	0	0	0	234,6	538,05

Langkah selanjutnya adalah jalankan fungsi aktivasi pada *feature map* FA1 , setiap pixel pada FA1 akan dimasukan ke dalam fungsi aktivasi ReLU yang akan mengubah setiap nilai negative menjadi 0, berikut perhitungannya menggunakan persamaan (2.7).

$$f(x) = \max(0, x) \quad (2.7)$$

$$\begin{aligned} RA1_{0,0} &= \max(0, FA1_{0,0}) \\ &= \max(0, 0) \\ &= 0 \end{aligned}$$

Hasil dari fungsi aktivasi dapat dilihat pada Tabel 3.8 *Feature Map ReLU RA1*.

Tabel 3.8 Feature Map ReLU RA1

x,y	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	234,6	538,05
1	0	0	0	0	0	0	0	0	234,6	538,05
2	0	0	0	0	0	0	0	48,45	137,7	538,05
3	0	0	0	0	0	0	0	30,6	257,55	293,25
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	56,1	226,95	173,4
7	0	0	0	0	0	0	0	0	160,65	313,65
8	0	0	0	0	0	0	0	0	234,6	538,05
9	0	38,25	7,65	58,65	0	0	0	0	234,6	538,05

Selanjutnya proses konvolusi dilakukan terhadap citra C dengan bobot pada filter A2. Bobot filter A2 dapat dilihat pada Tabel 3.9 Bobot *Convolutional Filter* A2 dan biasnya diisi 0.

Tabel 3.9 Bobot Convolutional Filter A2

x,y	0	1	2	3	4
0	0,07	0,21	0,34	-0,31	-0,43
1	-0,35	0,14	-0,48	-0,27	-0,25
2	0,05	0,15	-0,11	0,05	0,16
3	-0,18	0,13	-0,45	-0,23	0,35
4	-0,27	0,29	0,39	0,22	0,15

Proses ini akan menghasilkan *feature map* FA2. Berikut hasil proses konvolusi dapat dilihat pada Tabel 3.10 *Feature Map* FA2.

Tabel 3.10 Feature Map FA2

x,y	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	-221,85	-155,55
1	0	0	0	0	0	0	0	0	-221,85	-155,55
2	0	0	0	0	0	0	0	127,5	-114,75	-155,55
3	0	0	0	0	0	0	0	-173,4	-267,75	-165,75
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	38,25	267,75	160,65
7	0	0	0	0	0	0	0	-22,95	-45,9	-234,6
8	0	0	0	0	0	0	0	0	-221,85	-155,55
9	0	-20,4	-45,9	-45,9	0	0	0	0	-221,85	-155,55

Setelah itu jalankan fungsi aktivasi ReLU pada *feature map* FA2. Hasil dari fungsi aktivasi ReLU dapat dilihat pada Tabel 3.11 *Feature Map* ReLU RA2.

Tabel 3.11 Feature Map ReLU RA2

x, y	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	127,5	0	0
3	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	38,25	267,75	160,65
7	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	0	0

Terakhir, lakukan proses konvolusi terhadap citra C dengan bobot pada filter terakhir A3. Bobot filter A3 dapat dilihat Tabel 3.12 Bobot *Convolutional Filter* A3 dan biasnya diisi 0.

Tabel 3.12 Bobot Convolutional Filter A3

x, y	0	1	2	3	4
0	0,22	-0,22	0,24	-0,03	0,19
1	-0,26	-0,04	-0,41	0,25	0,36
2	-0,17	0,48	-0,31	0,3	-0,44
3	-0,46	-0,19	-0,21	0,46	0,22
4	0,36	0,39	0,34	0,02	0,47

Proses ini menghasilkan *feature map* FA3 yang dapat dilihat pada Tabel 3.13 *Feature Map* FA3.

Tabel 3.13 Feature Map FA3

x, y	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	369,75	193,8
1	0	0	0	0	0	0	0	0	369,75	193,8
2	0	0	0	0	0	0	0	175,95	420,75	193,8
3	0	0	0	0	0	0	0	140,25	86,7	-63,75
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	119,85	311,1	283,05
7	0	0	0	0	0	0	0	-20,4	379,95	140,25
8	0	0	0	0	0	0	0	0	369,75	193,8
9	0	237,15	132,6	-117,3	0	0	0	0	369,75	193,8

Setelah itu jalankan fungsi aktivasi ReLU pada *feature map* FA3. Hasil dari fungsi aktivasi dapat dilihat pada Tabel 3.14 *Feature Map* ReLU RA3.

Tabel 3.14 Feature Map ReLU RA3

x,y	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	369,75	193,8
1	0	0	0	0	0	0	0	0	369,75	193,8
2	0	0	0	0	0	0	0	175,95	420,75	193,8
3	0	0	0	0	0	0	0	140,25	86,7	0
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	119,85	311,1	283,05
7	0	0	0	0	0	0	0	0	379,95	140,25
8	0	0	0	0	0	0	0	0	369,75	193,8
9	0	237,15	132,6	0	0	0	0	0	369,75	193,8

Hasil dari *convolutional layer A*, yaitu *Feature Map RA1*, *RA2* dan *RA3* akan digunakan pada layer selanjutnya, yaitu *convolutional layer B*.

2. Convolutional Layer B

Pada *convolutional layer B* akan dilakukan proses yang sama seperti pada *convolutinal layer A* hanya saja *inputannya* rangkap tiga, yaitu *feature map RA1*, *RA2* dan *RA3*. Pada *convolutional layer B* terdapat 3 filter berukuran 7x7 dengan *stride* 1. Pertama-tama akan dilakukan proses konvolusi antara *feature map RA1*, *RA2* dan *RA3* dengan bobot pada filter B1. Bobot pada filter B1 dapat dilihat pada Tabel 3.15 Bobot *Convolutional Filter B1* dan biasnya diisi 0.

Tabel 3.15 Bobot Convolutional Filter B1


x,y	0	1	2	3	4	5	6
0	0,31	-0,14	0,44	0,25	0,44	-0,36	0,05
1	-0,47	0,09	0,28	0,05	0,4	-0,06	0,09
2	-0,29	0,4	0,25	0,36	0,33	-0,2	0,36
3	-0,1	0,34	-0,1	-0,49	-0,37	-0,18	-0,19
4	-0,01	-0,01	0,21	-0,26	0,43	-0,45	-0,26
5	0,19	0,34	0,1	0,31	0,33	0,17	0,45
6	-0,43	0,06	-0,39	0,03	0,21	0,22	-0,02

Proses konvolusi akan dimulai dari pojok kiri atas lalu bergeser hingga pojok kanan bawah, setiap hasil konvolusi ditambahkan dengan bias. Berikut perhitungannya.

$$FB1_{i,j} = \sum_{c=1}^3 \sum_{m=0}^6 \sum_{n=0}^6 B1_{m,n} \cdot RAc_{i+1+m, j+1+n} + bB_0 \quad (2.5)$$

$$\begin{aligned} FB1_{0,0} &= (B1_{0,0} \cdot RA1_{0,0} + B1_{0,1} \cdot RA1_{0,1} + B3_{0,2} \cdot RA1_{0,2} + \dots + B1_{6,6} \cdot RA3_{6,6}) + bB_0 \\ &= (0,31*0 + -0,14*0 + 0,44*0 + \dots + -0,02*0) + 0 \\ &= 0 \end{aligned}$$

Berikut adalah visualisasi operasi konvolusi filter B1 yang menghasilkan FB1_{0,0} dapat dilihat pada Gambar 3.13 Visualisasi 1 operasi *Convolution Layer B1*.




Gambar 3.13 Visualisasi 1 operasi Convolution Layer B1

Setelah itu geser filter ke kanan sebanyak nilai *stride* yaitu 1 dan lakukan kembali operasi konvolusi.

$$\begin{aligned}
 FB1_{0,1} &= (B1_{0,0} \cdot RA1_{0,1} + B1_{0,1} \cdot RA1_{0,2} + B3_{0,2} \cdot RA1_{0,3} + \dots + B1_{6,6} \cdot RA3_{6,7}) + bB_0 \\
 &= (0,31*0 + -0,14*0 + 0,44*0 + \dots + -0,02*119,85) + 0 \\
 &= 89,9385
 \end{aligned}$$

Berikut adalah visualisasi operasi konvolusi filter B1 yang menghasilkan FB1_{0,1} dapat dilihat pada Gambar 3.14 Visualisasi 2 operasi *Convolution Layer B1*.



Gambar 3.14 Visualisasi 2 operasi Convolution Layer B1

Hasil proses keseluruhan pada filter B1 dapat dilihat Tabel 3.16 *Feature Map FB1*.

Tabel 3.16 Feature Map FB1

x, y	0	1	2	3
0	0	89,9385	150,1119	145,554
1	0	189,567	537,336	680,468
2	0	-22,721	-152,75	47,991
3	-36,414	-165,04	-173,43	-211,75

Langkah selanjutnya jalankan fungsi aktivasi ReLU pada *feature map* FA1. Berikut perhitungannya menggunakan persamaan (2.7).

$$f(x) = \max(0, x) \quad (2.7)$$

$$\begin{aligned} RB1_{0,0} &= \max(0, FB1_{0,0}) \\ &= \max(0, 0) \\ &= 0 \end{aligned}$$

Hasil keseluruhan dari fungsi aktivasi ReLU menghasilkan *feature map* RB1 yang dapat dilihat pada Tabel 3.17 *Feature Map ReLU RB1*.

Tabel 3.17 Feature Map ReLU RB1

x, y	0	1	2	3
0	0	89,9385	150,1185	145,554
1	0	189,567	537,336	680,4675
2	0	0	0	47,991
3	0	0	0	0

Selanjutnya proses konvolusi dilakukan terhadap *feature map* RA1, RA2 dan RA3 dengan bobot pada filter B2. Bobot filter B2 dapat dilihat pada Tabel 3.18 Bobot *Convolutional Filter* B2 dan biasnya diisi 0.

Tabel 3.18 Bobot Convolutional Filter B2

x, y	0	1	2	3	4	5	6
0	-0,39	0,41	-0,16	-0,18	0,4	0,41	0,06
1	0,33	0,21	0,12	0,34	0	0,07	0,13
2	0,46	-0,04	0,4	-0,2	-0,44	0,36	-0,12
3	-0,34	-0,08	-0,11	-0,16	0,1	-0,14	0,4
4	-0,39	0,26	-0,22	0,1	-0,05	-0,17	-0,39
5	0,14	-0,16	-0,22	0,26	0,4	0,42	-0,13
6	-0,26	-0,43	0,12	0,4	0,01	0,22	0,33

Proses ini akan menghasilkan *feature map* FB2. Berikut hasil proses konvolusi dapat dilihat pada Tabel 3.19 *Feature Map* FB2.

Tabel 3.19 Feature Map FB2

x, y	0	1	2	3
0	0	96,798	601,316	856,775
1	0	-2,601	317,297	1052,1
2	0	-40,214	12,9795	630,003
3	-78,132	-28,943	231,387	631,508

Setelah itu jalankan fungsi aktivasi ReLU pada *feature map* FB2. Hasil dari fungsi aktivasi dapat dilihat pada Tabel 3.20 *Feature Map* ReLU RB2.

Tabel 3.20 Feature Map ReLU RB2

x, y	0	1	2	3
0	0	96,798	601,3155	856,7745
1	0	0	317,2965	1052,1045
2	0	0	12,9795	630,003
3	0	0	231,387	631,5075

Terakhir, lakukan proses konvolusi terhadap RA1, RA2 dan RA3 dengan filter terakhir B3 untuk menghasilkan *feature map* FB3. Bobot filter B3 dapat dilihat pada Tabel 3.21 Bobot *Convolutional* B3 dan biasnya diisi 0.

Tabel 3.21 Bobot *Convolutional* B3

x, y	0	1	2	3	4	5	6
0	0,36	-0,32	0,39	-0,26	-0,31	0	-0,19
1	0,03	0,25	0,08	0,26	0,17	0,1	-0,41
2	-0,37	-0,16	-0,37	0,07	0,06	0,41	-0,4
3	-0,29	0,15	0,04	0,32	-0,2	-0,15	-0,3
4	0,13	0,21	0,37	-0,17	-0,49	-0,44	0,34
5	0,49	-0,48	-0,11	-0,03	0,41	0,29	-0,43
6	0,46	-0,24	0,03	0,29	0,4	0,43	-0,48

Proses ini akan menghasilkan feature map FB3. Berikut hasil proses konvolusi dapat dilihat pada Tabel 3.22 *Feature Map* FB3.

Tabel 3.22 Feature Map FB3

x, y	0	1	2	3
0	0	-294,83	-865,29	-459,15
1	0	-304,73	-920,12	-218,61
2	0	-64,082	-572,99	-684,42
3	-44,88	-1,938	-654,99	-744,93

Setelah itu jalankan fungsi aktivasi ReLU pada *feature map* FB3. Hasil dari fungsi aktivasi dapat dilihat pada Tabel 3.23 *Feature Map* ReLU RB3.

Tabel 3.23 Feature Map ReLU RB3

x, y	0	1	2	3
0	0	0	0	0
1	0	0	0	0
2	0	0	0	0
3	0	0	0	0

Feature Map RB1, RB2 dan RB3 akan digunakan pada layer selanjutnya, yaitu *fully-connected layer*. *Fully-connected layer* adalah sebuah *neural network* yang memiliki *input layer*, *hidden layer* dan *output layer*. Berikut adalah operasi-operasi yang terjadi di masing-masing layer.

3. Input Layer (Flatten)

Pada *input layer* akan terjadi penggabungan dari matriks *feature map* RB1, RB2 dan RB3. Matriks akan diratakan menjadi sebuah vektor dengan panjang sejumlah keseluruhan pixel dari RB1, RB2 dan RB3. Total pixel dari ketiga *feature map* adalah 48, sehingga *input layer* X memiliki 48 node. Berikut adalah vektor dari *input layer* X.

Tabel 3.24 Input Layer X

Xi	Nilai	Xi	Nilai	Xi	Nilai
0	0	16	0	32	0
1	89,9385	17	96,798	33	0
2	150,119	18	601,316	34	0
3	145,554	19	856,775	35	0
4	0	20	0	36	0
5	189,567	21	0	37	0
6	537,336	22	317,297	38	0
7	680,468	23	1052,1	39	0
8	0	24	0	40	0
9	0	25	0	41	0
10	0	26	12,9795	42	0
11	47,991	27	630,003	43	0
12	0	28	0	44	0
13	0	29	0	45	0
14	0	30	231,387	46	0
15	0	31	631,508	47	0

Selanjutnya nilai dari *input layer* X akan digunakan pada *hidden layer* Z.

4. Hidden Layer

Setiap node pada *input layer* X akan mengirimkan sinyal pada setiap node di *hidden layer* Z. Bobot pada *hidden layer* Z dapat dilihat pada Tabel 3.25 Bobot *Hidden Layer* V dan untuk nilai biasnya semua bernilai 0.

Tabel 3.25 Bobot Hidden Layer V

x, y	0	1	2	3	4	5	6	7	8	9
0	-0,14	0,13	0,15	-0,33	0,35	-0,34	-0,41	0,35	0,19	-0,26
1	-0,48	0,25	-0,28	0,35	0,38	0,39	-0,3	-0,41	-0,35	-0,06
2	-0,3	-0,42	0,47	0,07	0,21	0,25	-0,28	0,16	0,09	0,35
3	0,04	0,36	-0,02	0,47	0,15	0,16	0,26	0,45	-0,42	-0,12
4	0,24	0,2	0,34	-0,12	0,37	0,44	0,04	-0,16	-0,21	0,18
5	-0,06	0,48	-0,19	0,49	-0,08	0,36	0,23	-0,19	0,19	-0,23
6	0,03	0,22	-0,27	-0,33	0,1	-0,17	-0,09	0	-0,28	-0,19
.....
44	0,24	0,21	-0,48	-0,17	-0,06	-0,41	0,3	0,3	-0,44	0,05
45	0,1	-0,19	-0,49	-0,42	0,27	-0,38	-0,08	0,14	0,01	-0,13
46	0,13	-0,31	-0,3	0,42	-0,08	-0,35	-0,1	0,29	0,19	-0,25
47	0,29	-0,08	0,12	-0,35	0,24	-0,15	0	0,49	-0,19	-0,42

Proses perhitungan pada *hidden layer Z* menggunakan persamaan (2.9). Berikut adalah contoh perhitungannya.

$$z_in_i = \sum_{j=0}^{n=47} X_j * V_{j,i} + bV_i \quad (2.9)$$

$$\begin{aligned} z_in_0 &= (X_0 * V_{0,0} + X_1 * V_{1,0} + X_2 * V_{2,0} + X_3 * V_{3,0} + \dots + X_{47} * V_{47,0}) + bV_0 \\ &= (0 * -0,14 + 89,9385 * -0,48 + 150,119 * -0,3 + 145,554 * 0,04 + \dots + 0 * 0,29) + 0 \\ &= 1098,70932 \end{aligned}$$

Hidden layer Z memiliki 10 node sehingga pada proses perhitungan akan menghasilkan 10 nilai *z_in*. Hasil perhitungan *z_in* keseluruhan dapat dilihat pada Tabel 3.26 Nilai *z_in*.

Tabel 3.26 Nilai *z_in*

i	z_in
0	1098,70932
1	1207,1009
2	-375,77795
3	629,970105
4	103,58559
5	-458,21715
6	101,162325
7	661,017885
8	-407,46603
9	63,602865

Selanjutnya jalankan fungsi aktivasi ReLU pada setiap nilai z_{in} dan menghasilkan nilai Z. Berikut adalah contoh perhitungannya menggunakan persamaan (2.7).

$$\begin{aligned} f(x) &= \max(0, x) \\ Z_1 &= \max(0, z_{in_1}) \\ &= \max(0, 1098,70932) \\ &= 1098,70932 \end{aligned} \tag{2.7}$$

Hasil dari fungsi aktivasi dapat dilihat pada Tabel 3.27 Nilai Z.

Tabel 3.27 Nilai Z

<i>i</i>	Z
0	1098,70932
1	1207,1009
2	0
3	629,970105
4	103,58559
5	0
6	101,162325
7	661,017885
8	0
9	63,602865

5. Output Layer

Ini adalah tahap terakhir dari *feedforward*. Hasil perhitungan di *hidden layer Z* akan digunakan pada perhitungan di *output layer Y*. *Output layer Y* memiliki 20 bobot dapat dilihat pada Tabel 3.28 Bobot *Output Layer W* dan biasnya bernilai 0.

Tabel 3.28 Bobot Output Layer W

x,y	0	1
0	0,21	0,27
1	-0,35	-0,09
2	-0,09	0,27
3	-0,15	-0,21
4	0,61	0,32
5	0,32	-0,19
6	0,11	0,37
7	0,36	-0,16
8	0,35	0,34
9	-0,43	0,04

Proses perhitungan pada *output layer Y* menggunakan persamaan (2.9). Berikut adalah contoh perhitungannya.

$$y_in_i = \sum_{j=0}^{n=9} Z_j * W_{j,i} + bW_i \quad (2.9)$$

$$\begin{aligned} y_in_0 &= (Z_0*W_{0,0} + Z_1*W_{1,0} + Z_2*W_{2,0} + \dots + Z_9*W_{9,0}) + bW_0 \\ &= (1098,70932*0,21 + 1207,1009*-0,35 + 0*-0,09 + \dots + 63,6202865*-0,43) + 0 \\ &= -1,3196 \end{aligned}$$

Hasil perhitungan y_in keseluruhan dapat dilihat pada Tabel 3.29 Nilai y_in .

Tabel 3.29 Nilai y_in

<i>i</i>	y_in
0	-1,3195995
1	23,07741585

Selanjutnya jalankan fungsi aktivasi *linear* pada setiap nilai y_in untuk menghasilkan nilai keluaran Y , dengan persamaan (2.8).

$$\varphi(x) = x \quad (2.8)$$

$$\begin{aligned} Y &= \varphi(y_in_0) \\ &= -1,3196 \end{aligned}$$

Hasil perhitungan Y dapat dilihat pada Tabel 3.30 Nilai *Output Y*.

Tabel 3.30 Nilai *Output Y*

<i>i</i>	Y
0	-1,3195995
1	23,07741585

3.7.1.2. Backpropagation

Pada tahap ini akan dilakukan beberapa proses perhitungan. Pertama akan dihitung gradien dari *loss function* terhadap semua bobot di setiap layer dengan mencari turunan parsial dari fungsi tersebut dan selanjutnya akan dilakukan penyesuaian bobot dengan menggunakan Adam *Oprimizer* dengan $\alpha = 0,001$, $\beta_1 = 0,9$, $\beta_2 = 0,999$ dan $\epsilon = 10^{-8}$.

1. Perhitungan Nilai *Loss*

Perhitungan nilai *Loss* menggunakan sebuah fungsi *Loss*. Fungsi tersebut akan mengukur seberapa bagus peforma dari sebuah model dalam melakukan

prediksinya terhadap target. Pada metode CNN yang dikombinasikan dengan *Q-Learning*, penentuan target berdasarkan *terminal* [4]. Terminal adalah status yang menandakan apakah pada *next state* permainan berakhir atau tidak, bernilai *True* jika permainan berakhir dan *False* jika sebaliknya. Adapun penentuan nilai target berdasarkan persamaan (2.10).

$$\text{Set } Y' = \begin{cases} r, & \text{terminal} = \text{True} \\ r + \gamma \max_a Q(S_{t+1}, a'; \theta), & \text{terminal} = \text{False} \end{cases} \quad (2.10)$$

Dimana r adalah *reward* yang didapatkan, γ adalah *discount rate* dengan nilai 0,99 dan $\max_a Q(S_{t+1}, a'; \theta)$ adalah *output* dengan nilai maksimal dari *feedforward CNN* dengan *input next state*.

Karena status *terminal* data latih bernilai *True* (sudah dijelaskan pada bagian awal sub bab pelatihan CNN) maka nilai target adalah *reward* yang didapat, yaitu - 1. Nilai target tersebut ditempatkan pada *action* yang diambil, pada data latih ini *action* yang diambil adalah 0 dan untuk *action* selain 0 akan diberi nilai 0 baik pada vektor target maupun vektor hasil prediksi [5]. Nilai vektor target Y' dapat dilihat pada Tabel 3.31 Nilai Target Y' dan nilai vektor prediksi Y dapat dilihat pada Tabel 3.32 Nilai Prediksi Y .

Tabel 3.31 Nilai Target Y'

Y'	Nilai
0	-1
1	0

Tabel 3.32 Nilai Prediksi Y

Y	Nilai
0	-1,3195995
1	0

Pada kasus ini, CNN digunakan untuk regresi dan *loss function* yang biasa digunakan adalah *mean squared error* menggunakan persamaan (2.11)

$$L = \frac{1}{n} \sum_{i=1}^n (Y_{i-1} - Y'_{i-1})^2 \quad (2.11)$$

dimana L adalah nilai loss, Y adalah hasil prediksi dan Y' adalah target prediksi.

$$\begin{aligned} L &= \frac{1}{2} ((Y_0 - Y'_0)^2 + (Y_1 - Y'_1)^2) \\ &= \frac{1}{2} ((-1,3195995 - (-1))^2 + (0 - 0)^2) \end{aligned}$$

$$= 0,051072$$

2. Perhitungan Gradien Terhadap Bobot W

Setelah perhitungan nilai loss, selanjutnya akan dilakukan perhitungan gradien terhadap bobot $W_{i,j}$. Perhitungan akan menggunakan rumus *chain rule* berdasarkan persamaan. Berikut adalah perhitungan gradien pada bobot $W_{i,j}$ berdasarkan persamaan (2.12).

$$\begin{aligned}\frac{\partial L}{\partial W_{j,i}} &= \frac{\partial L}{\partial Y_i} \frac{\partial Y_i}{\partial y_{in_i}} \frac{\partial y_{in_i}}{\partial W_{j,i}} \\ \frac{\partial L}{\partial W_{j,i}} &= 2(Y_i - Y'_i) * 1 * Z_j \\ \frac{\partial L}{\partial W_{0,0}} &= 2((-1,3195995) - (-1)) * 1 * 1098,70932 \\ &= -702,2938986\end{aligned}\tag{2.12}$$

Hasil dari perhitungan $\frac{\partial L}{\partial W}$ keseluruhan dapat dilihat pada Tabel 3.33 Matriks Gradien $\frac{\partial L}{\partial W}$.

Tabel 3.33 Matriks Gradien $\frac{\partial L}{\partial W}$

j, i	0	1
0	-702,2938986	0
1	-771,577685	0
2	0	0
3	-402,6762611	0
4	-66,21180554	0
5	0	0
6	-64,66285698	0
7	-422,5219711	0
8	0	0
9	-40,65488771	0

Setelah gradien $\frac{\partial L}{\partial W}$ diketahui, selanjutnya lakukan perhitungan nilai bobot W, baru menggunakan Adam Optimizer dengan $\alpha = 0,001$, $\beta_1 = 0,9$ $\beta_2 = 0,999$ dan $\epsilon = 10^{-8}$. Berikut tahapan-tahapan perhitungannya, dimulai dari menghitung nilai m_t menggunakan persamaan (2.17).

$$m_t = \beta_1 * m_{t-1} + (1 - \beta_1) * \frac{\partial L}{\partial W_{0,0}}\tag{2.17}$$

$$m_I = 0,9 * 0 + (1 - 0,9) * -702,2938986$$

$$m_I = -70,22938986$$

Selanjutnya, hitung nilai v_I menggunakan persamaan (2.18).

$$v_t = \beta_2 * v_{t-1} + (1 - \beta_2) * \frac{\partial L}{\partial w_{0,0}}^2 \quad (2.18)$$

$$v_I = 0,999 * 0 + (1 - 0,999) * -702,2938986^2$$

$$v_I = 493,2167201$$

Lalu hitung nilai \hat{m}_I menggunakan persamaan (2.19).

$$\hat{m}_t = m_t / (1 - \beta_1^t) \quad (2.19)$$

$$\hat{m}_I = -70,22938986 / (1 - 0,9^1)$$

$$\hat{m}_I = -702,2938986$$

Setelah itu lakukan perhitungan nilai \hat{v}_I menggunakan persamaan (2.20).

$$\hat{v}_t = v_t / (1 - \beta_2^t) \quad (2.20)$$

$$\hat{v}_I = 493,2167201 / (1 - 0,999^1)$$

$$\hat{v}_I = 493216,7201$$

Terakhir, lakukan perhitungan bobot baru menggunakan persamaan (2.21).

$$W'_{0,0} = W_{0,0} - \alpha * \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon) \quad (2.21)$$

$$W'_{0,0} = W_{0,0} - \alpha * \hat{m}_I / (\sqrt{\hat{v}_I} + \epsilon)$$

$$W'_{0,0} = 0,21 - 0,001 * -702,2938986 / (\sqrt{493216,7201} + 10^{-8})$$

$$W'_{0,0} = 0,211$$

Hasil perhitungan W' keseluruhan dapat dilihat pada Tabel 3.34 Bobot Baru W'

Tabel 3.34 Bobot Baru W'

x, y	0	1
0	0,211	0,27
1	-0,349	-0,09
2	-0,09	0,27
3	-0,149	-0,21
4	0,611	0,32
5	0,32	-0,19
6	0,111	0,37
7	0,361	-0,16
8	0,35	0,34
9	-0,429	0,04

3. Perhitungan Gradien Terhadap Bobot V

Setelah menghitung gradien pada bobot W, selanjutnya akan dilakukan perhitungan terhadap bobot V. Perhitungan gradien pada bobot V berdasarkan persamaan (2.13) dapat dilihat di bawah ini.

$$\begin{aligned}\frac{\partial L}{\partial V_{k,j}} &= \sum_i^m \frac{\partial L}{\partial Y_i} \frac{\partial Y_i}{\partial y_{in_i}} \frac{\partial y_{in_i}}{\partial Z_j} \frac{\partial Z_j}{\partial z_in_j} \frac{\partial z_in_j}{\partial V_{k,j}} \\ \frac{\partial L}{\partial V_{k,j}} &= \sum_{i=0}^1 -(Y_i - Y'_i) * 1 * W_{j,i} * \begin{cases} 1 & z_in_j \geq 0 \\ 0 & z_in_j < 0 \end{cases} * X_k \\ \frac{\partial L}{\partial V_{0,0}} &= \sum_{i=0}^1 2(Y_i - Y'_i) * 1 * W_{0,i} * \begin{cases} 1 & z_in_0 \geq 0 \\ 0 & z_in_0 < 0 \end{cases} * X_0 \\ &= (2((-1,3195995) - (-1)) * 1 * 0,21 * 1 * 0) + \\ &\quad (2(0 - 0) * 1 * 0,27 * 1 * 0) \\ &= 0\end{aligned}\tag{2.13}$$

Hasil perhitungan $\frac{\partial L}{\partial V}$ keseluruhan dapat dilihat pada Tabel 3.35 Matriks Gradien $\frac{\partial L}{\partial V}$.

Tabel 3.35 Matriks Gradien $\frac{\partial L}{\partial V}$

j, i	0	1	2	3	4	9
0	0	0	0	0	0	0
1	-12,07260584	20,12100974	0	8,623289889	-35,06804555	24,72009768
2	-20,15067497	33,58445828	0	14,39333926	-58,532913	41,26090589
3	-19,53797396	32,56328994	0	13,95569569	-56,75316246	40,00632764
4	0	0	0	0	0	0
5	-25,44591773	42,40986289	0	18,17565552	-73,91433247	52,10354584
....
44	0	0	0	0	0	0
45	0	0	0	0	0	0
46	0	0	0	0	0	0
47	0	0	0	0	0	0

Setelah melakukan perhitungan gradien $\frac{\partial L}{\partial V}$, selanjutnya akan dilakukan perhitungan nilai bobot V baru. Perhitungan bobot baru menggunakan Adam Optimizer. Pertama-tama hitung dahulu m_I menggunakan persamaan (2.17).

$$m_t = \beta_1 * m_{t-1} + (1 - \beta_1) * \frac{\partial L}{\partial V_{0,0}}\tag{2.17}$$

$$m_I = 0,9 * 0 + (1 - 0,9) * 0$$

$$m_I = 0$$

Selanjutnya, hitung nilai v_I menggunakan persamaan (2.18).

$$v_t = \beta_2 * v_{t-1} + (1 - \beta_2) * \frac{\partial L}{\partial V_{0,0}}^2\tag{2.18}$$

$$v_I = 0,999 * 0 + (1 - 0,999) * 0^2$$

$$v_I = 0$$

Lalu hitung nilai \hat{m}_I menggunakan persamaan (2.19).

$$\begin{aligned} \hat{m}_t &= m_t / (1 - \beta_1^t) \\ \hat{m}_I &= 0 / (1 - 0,9^1) \\ \hat{m}_I &= 0 \end{aligned} \tag{2.19}$$

Setelah itu lakukan perhitungan nilai \hat{v}_I menggunakan persamaan (2.20).

$$\begin{aligned} \hat{v}_t &= v_t / (1 - \beta_2^t) \\ \hat{v}_I &= 0 / (1 - 0,999^1) \\ \hat{v}_I &= 0 \end{aligned} \tag{2.20}$$

Terakhir, lakukan perhitungan bobot baru menggunakan persamaan (2.21).

$$\begin{aligned} V'_{0,0} &= V_{0,0} - \alpha * \hat{m}_I / (\sqrt{\hat{v}_I} + \epsilon) \\ V'_{0,0} &= V_{0,0} - \alpha * \hat{m}_I / (\sqrt{\hat{v}_I} + \epsilon) \\ V'_{0,0} &= -0,14 - 0,001 * 0 / (\sqrt{0} + 10^{-8}) \\ V'_{0,0} &= -0,14 \end{aligned} \tag{2.21}$$

Hasil dari perhitungan bobot baru \hat{v} keseluruhan dapat dilihat pada Tabel 3.28 Bobot *Output Layer*.

Tabel 3.36 Bobot Baru V

x,y	0	1	2	3	4	5	6	7	8	9
0	-0,14	0,13	0,15	-0,33	0,35	-0,34	-0,41	0,35	0,19	-0,26
1	-0,479	0,249	-0,28	0,349	0,381	0,39	-0,299	-0,409	-0,35	-0,061
2	-0,299	-0,421	0,47	0,069	0,211	0,25	-0,279	0,161	0,09	0,349
3	0,041	0,359	-0,02	0,469	0,151	0,16	0,261	0,451	-0,42	-0,121
4	0,24	0,2	0,34	-0,12	0,37	0,44	0,04	-0,16	-0,21	0,18
5	-0,059	0,479	-0,19	0,489	-0,079	0,36	0,231	-0,189	0,19	-0,231
....
44	0,24	0,21	-0,48	-0,17	-0,06	-0,41	0,3	0,3	-0,44	0,05
45	0,1	-0,19	-0,49	-0,42	0,27	-0,38	-0,08	0,14	0,01	-0,13
46	0,13	-0,31	-0,3	0,42	-0,08	-0,35	-0,1	0,29	0,19	-0,25
47	0,29	-0,08	0,12	-0,35	0,24	-0,15	0	0,49	-0,19	-0,42

4. Perhitungan Gradien Terhadap Bobot Filter B

Selanjutnya akan dilakukan perhitungan gradien terhadap bobot pada filter B menggunakan rumus *chain rule*, berikut adalah persamaannya (2.15)

$$\frac{\partial L}{\partial b_i} = \frac{\partial L}{\partial x_i} \frac{\partial x_i}{\partial f_B i} \frac{\partial f_B i}{\partial b_i} \tag{2.15}$$

Sebelum melakukan perhitungan terhadap gradien filter B, perlu dihitung terlebih dahulu nilai dari $\frac{\partial L}{\partial x}$ menggunakan persamaan (2.14).

$$\begin{aligned}
 \frac{\partial L}{\partial X_k} &= \sum_j^n \sum_i^m \frac{\partial L}{\partial Y_i} \frac{\partial Y_i}{\partial y_{in_i}} \frac{\partial y_{in_i}}{\partial Z_j} \frac{\partial Z_j}{\partial z_{in_j}} \frac{\partial z_{in_j}}{\partial X_k} \\
 \frac{\partial L}{\partial X_k} &= \sum_{j=0}^9 \sum_{i=0}^1 2(Y_i - Y'_i) * 1 * W_{j,i} * \begin{cases} 1 & z_{in_j} \geq 0 \\ 0 & z_{in_j} < 0 \end{cases} * V_{k,j} \\
 \frac{\partial L}{\partial X_0} &= \sum_{j=0}^9 \sum_{i=0}^1 2(Y_i - Y'_i) * 1 * W_{0,i} * \begin{cases} 1 & z_{in_j} \geq 0 \\ 0 & z_{in_j} < 0 \end{cases} * V_{0,j} \\
 &= (2((-1,3195995) - (-1)) * 1 * 0,21 * 1 * -14) + (2(0 - 0) * 1 * 0,27 * 1 * \\
 &\quad -14) + \dots + (2((-1,3195995) - (-1)) * 1 * -0,43 * 1 * -0,26) + \\
 &\quad (2(0 - 0) * 1 * 0,04 * 1 * -0,26) \\
 &= -0,243406979
 \end{aligned} \tag{2.14}$$

Hasil perhitungan $\frac{\partial L}{\partial X}$ keseluruhan dapat dilihat pada Tabel 3.37 Matriks $\frac{\partial L}{\partial X}$.

Tabel 3.37 Matriks $\frac{\partial L}{\partial X}$

i	aL / aX	i	aL / aX	i	aL / aX
0	-0,243406979	16	-0,324329573	32	-0,110325747
1	0,104700796	17	0,256766238	33	-0,124452045
2	-0,049793602	18	0,099011925	34	0,113841342
3	-0,093067374	19	-0,289429307	35	-0,103933757
4	-0,059765106	20	-0,129693477	36	-0,367347665
5	0,157946073	21	0,008629186	37	0,064431259
6	-0,071334608	22	-0,021541006	38	-0,01303966
7	0,066221016	23	-0,199749687	39	-0,284251795
8	0,390486669	24	-0,158585272	40	0,260857112
9	-0,226020766	25	-0,181148997	41	-0,216624541
10	-0,129246038	26	0,087186744	42	0,251333047
11	0,25574352	27	0,252419685	43	0,341076586
12	-0,036753942	28	-0,096391209	44	-0,054523675
13	-0,022371965	29	0,035795144	45	-0,263797427
14	0,059829026	30	0,046469767	46	-0,143755855
15	0,071142849	31	0,274216371	47	-0,412155515

Setelah nilai $\frac{\partial L}{\partial X}$ diketahui, susun nilai-nilai tersebut menjadi matriks 4x4 berjumlah

3 buah. Matriks $\frac{\partial L}{\partial X_1}$ dapat dilihat pada Tabel 3.38 Matriks $\frac{\partial L}{\partial X_1}$.

Tabel 3.38 Matriks $\frac{\partial L}{\partial x_1}$

i, j	0	1	2	3
0	-0,243406979	0,104700796	-0,049793602	-0,093067374
1	-0,059765106	0,157946073	-0,071334608	0,066221016
2	0,390486669	-0,226020766	-0,129246038	0,25574352
3	-0,036753942	-0,022371965	0,059829026	0,071142849

Sedangkan untuk nilai pada matriks $\frac{\partial L}{\partial x_2}$ dapat dilihat pada Tabel 3.39 Matriks $\frac{\partial L}{\partial x_2}$.

Tabel 3.39 Matriks $\frac{\partial L}{\partial x_2}$

i, j	0	1	2	3
0	-0,324329573	0,256766238	0,099011925	-0,289429307
1	-0,129693477	0,008629186	-0,02154101	-0,199749687
2	-0,158585272	-0,181148997	0,087186744	0,252419685
3	-0,096391209	0,035795144	0,046469767	0,274216371

Matriks terakhir, matriks $\frac{\partial L}{\partial x_3}$ dapat dilihat pada Tabel 3.40 Matriks $\frac{\partial L}{\partial x_3}$.

Tabel 3.40 Matriks $\frac{\partial L}{\partial x_3}$

i, j	0	1	2	3
0	-0,110325747	-0,124452045	0,113841342	-0,10393376
1	-0,367347665	0,064431259	-0,01303966	-0,2842518
2	0,260857112	-0,216624541	0,251333047	0,341076586
3	-0,054523675	-0,263797427	-0,143755855	-0,41215552

Setelah menyusun matriks $\frac{\partial L}{\partial x}$ menjadi 4x4x3 yang terdiri dari $\frac{\partial L}{\partial x_1}$, $\frac{\partial L}{\partial x_2}$ dan $\frac{\partial L}{\partial x_3}$.

Selanjutnya melakukan perhitungan untuk mencari gradien $\frac{\partial L}{\partial FB_i}$.

$$\begin{aligned}\frac{\partial L}{\partial FB_i} &= \frac{\partial L}{\partial X_i} \frac{\partial X_i}{\partial FB_i} \\ \frac{\partial L}{\partial FB_{1,0,0}} &= \frac{\partial L}{\partial X_{1,0,0}} \frac{\partial X_{1,0,0}}{\partial FB_{1,0,0}} \\ &= \frac{\partial L}{\partial X_{1,0,0}} * \begin{cases} 1 & FB_{1,0,0} \geq 0 \\ 0 & FB_{1,0,0} < 0 \end{cases} \\ &= -0,243406979 * 1 \\ &= -0,243406979\end{aligned}$$

Hasil keseluruhan perhitungan dari matriks $\frac{\partial L}{\partial FB_1}$ dapat dilihat pada Tabel 3.41

Matriks $\frac{\partial L}{\partial FB_1}$.

Tabel 3.41 Matriks $\frac{\partial L}{\partial FB1}$

i,j	0	1	2	3
0	-0,243406979	0,104700796	-0,049793602	-0,093067374
1	-0,059765106	0,157946073	-0,071334608	0,066221016
2	0,390486669	0	0	0,25574352
3	0	0	0	0

Lakukan proses yang sama untuk matriks $\frac{\partial L}{\partial X2}$, menghasilkan $\frac{\partial L}{\partial FB2}$ dapat dilihat pada Tabel 3.42 Matriks $\frac{\partial L}{\partial FB2}$ dan $\frac{\partial L}{\partial X3}$ menghasilkan $\frac{\partial L}{\partial FB3}$ yang dapat dilihat pada Tabel 3.43 Matriks $\frac{\partial L}{\partial FB3}$.

Tabel 3.42 Matriks $\frac{\partial L}{\partial FB2}$

i,j	0	1	2	3
0	-0,324329573	0,256766238	0,099011925	-0,289429307
1	-0,129693477	0	-0,02154101	-0,199749687
2	-0,158585272	0	0,087186744	0,252419685
3	0	0	0,046469767	0,274216371

Tabel 3.43 Matriks $\frac{\partial L}{\partial FB3}$


i,j	0	1	2	3
0	-0,110325747	0	0	0
1	-0,367347665	0	0	0
2	0,260857112	0	0	0
3	0	0	0	0

Setelah perhitungan $\frac{\partial L}{\partial FB}$, untuk mendapatkan gradien $\frac{\partial L}{\partial B}$ lakukan operasi konvolusi antara $\frac{\partial L}{\partial FB1}$ dengan *featuure map* RA1, RA2 dan RA3. Berikut adalah perhitungannya.

$$\frac{\partial L}{\partial B1_{ij}} = \sum_{c=1}^3 \sum_{m=0}^3 \sum_{n=0}^3 \frac{\partial L}{\partial FB1_{m,n}} \cdot RAC_{i*1+m, j*1+n} \quad (2.5)$$

$$\begin{aligned} \frac{\partial L}{\partial B1_{0,0}} &= \frac{\partial L}{\partial FB1_{0,0}} \cdot RA1_{0,0} + \frac{\partial L}{\partial FB1_{0,1}} \cdot RA1_{0,1} + \frac{\partial L}{\partial FB1_{0,2}} \cdot RA1_{0,2} + \dots + \frac{\partial L}{\partial FB1_{3,3}} \cdot RA3_{3,3} \\ &= (0 * -0,243406979 + 0 * 0,104700796 + 0 * -0,049793602 + \dots + 0 * 0) \\ &= 0 \end{aligned}$$

Visualisasi proses tersebut dapat dilihat pada Gambar 3.15 Visualisasi 1 Operasi Konvolusi Matriks Gradien $\frac{\partial L}{\partial B1}$.




Gambar 3.15 Visualisasi 1 Operasi Konvolusi Matriks Gradien $\frac{\partial L}{\partial B1}$

Setelah itu geser filter ke kanan dan lakukan kembali operasi konvolusi.

$$\begin{aligned}
 \frac{\partial L}{\partial B1_{0,1}} &= \frac{\partial L}{\partial FB1_{0,0}} \cdot RA1_{0,1} + \frac{\partial L}{\partial FB1_{0,1}} \cdot RA1_{0,2} + \frac{\partial L}{\partial FB1_{0,2}} \cdot RA1_{0,3} + \dots + \frac{\partial L}{\partial FB1_{3,3}} \cdot RA3_{3,4} \\
 &= (0 * -0,243406979 + 0 * 0,104700796 + 0 * -0,049793602 + \dots + 0 * 0) \\
 &= 0
 \end{aligned}$$

Visualisasi proses tersebut dapat dilihat pada Gambar 3.16 Visualisasi 2 Operasi Konvolusi Matriks Gradien $\frac{\partial L}{\partial B1}$.



Gambar 3.16 Visualisasi 2 Operasi Konvolusi Matriks Gradien $\frac{\partial L}{\partial B1}$

Proses tersebut terus diulang hingga seluruh permukaan matriks. Hasil proses

keseluruhan dapat dilihat pada Tabel 3.44 Matriks Gradien $\frac{\partial L}{\partial B1}$.

Tabel 3.44 Matriks Gradien $\frac{\partial L}{\partial B1}$

i, j	0	1	2	3	4	5	6
0	0	0	0	0	89,99614465	126,5953722	94,31455392
1	0	0	0	0	66,99695605	43,67291692	41,00092767
2	0	0	0	0	-21,4365484	-58,88677676	-37,22692419
3	0	0	0	0	-15,90056092	-40,54568056	-26,54532403
4	0	0	0	0	54,78026196	206,0781283	157,8193261
5	0	0	0	0	14,18454171	176,3359688	133,2975943
6	0	0	0	0	-19,9350316	104,6981979	103,5314743

Setelah melakukan perhitungan gradien $\frac{\partial L}{\partial B1}$, selanjutnya akan dilakukan perhitungan nilai bobot filter B1 baru. Perhitungan bobot baru akan menggunakan Adam Optimizer. Hitung dahulu m_I menggunakan persamaan (2.17).

$$\mathbf{m}_t = \boldsymbol{\beta}_1 * \mathbf{m}_{t-1} + (1 - \boldsymbol{\beta}_1) * \frac{\partial L}{\partial B1,0} \quad (2.17)$$

$$m_I = 0,9 * 0 + (1 - 0,9) * 0$$

$$m_I = 0$$

Selanjutnya, hitung nilai v_I menggunakan persamaan (2.18).

$$v_t = \beta_2 * v_{t-1} + (1 - \beta_2) * \frac{\partial L}{\partial B1_{0,0}}^2 \quad (2.18)$$

$$v_I = 0,999 * 0 + (1 - 0,999) * 0^2$$

$$v_I = 0$$

Lalu hitung nilai \hat{m}_I menggunakan persamaan (2.19).

$$\hat{m}_t = m_t / (1 - \beta_1^t) \quad (2.19)$$

$$\hat{m}_I = 0 / (1 - 0,9^1)$$

$$\hat{m}_I = 0$$

Setelah itu lakukan perhitungan nilai \hat{v}_I menggunakan persamaan (2.20).

$$\hat{v}_t = v_t / (1 - \beta_2^t) \quad (2.20)$$

$$\hat{v}_I = 0 / (1 - 0,999^1)$$

$$\hat{v}_I = 0$$

Terakhir, lakukan perhitungan bobot baru menggunakan persamaan (2.21).

$$B1'_{0,0} = B1_{0,0} - \alpha * \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon) \quad (2.21)$$

$$B1'_{0,0} = B1_{0,0} - \alpha * \hat{m}_I / (\sqrt{\hat{v}_I} + \epsilon)$$

$$B1'_{0,0} = 0,31 - 0,001 * 0 / (\sqrt{0} + 10^{-8})$$

$$B1'_{0,0} = 0,31$$

Nilai Hasilperhitungan bobot baru B1 keseluruhan dapat dilihat pada Tabel 3.45

Bobot Baru Filter B1.

Tabel 3.45 Bobot Baru Filter B1

x, y	0	1	2	3	4	5	6
0	0,31	-0,14	0,44	0,25	0,439	-0,361	0,049
1	-0,47	0,09	0,28	0,05	0,399	-0,061	0,089
2	-0,29	0,4	0,25	0,36	0,331	-0,199	0,361
3	-0,1	0,34	-0,1	-0,49	-0,369	-0,179	-0,189
4	-0,01	-0,01	0,21	-0,26	0,429	-0,451	-0,261
5	0,19	0,34	0,1	0,31	0,329	0,169	0,449
6	-0,43	0,06	-0,39	0,03	0,211	0,219	-0,021

Selanjutnya lakukan proses konvolusi antara $\frac{\partial L}{\partial FB2}$ dengan *feature map* RA1, RA2 dan RA3, hasil dari proses keseluruhan dapat dilihat pada Tabel 3.46 Matriks Gradien $\frac{\partial L}{\partial B2}$.

Tabel 3.46 Matriks Gradien $\frac{\partial L}{\partial B2}$

<i>i,j</i>	0	1	2	3	4	5	6
0	0	0	0	0	98,22612581	93,94504257	-5,252700878
1	0	0	0	0	54,0089661	-34,79339772	-152,1630478
2	0	0	0	0	-39,08898758	-145,6932577	-185,0260869
3	0	0	0	0	-6,525697647	-21,72488787	16,94503765
4	0	0	0	0	54,59379483	254,2678203	270,5033375
5	0	0	0	0	-0,736414776	182,5645252	261,0261129
6	16,43828388	2,725451852	0	0	-30,95093603	89,30504269	213,4717783

Setelah melakukan perhitungan gradien $\frac{\partial L}{\partial B2}$, selanjutnya akan dilakukan perhitungan nilai bobot filter B2 baru menggunakan Adam Optimizer, hasilnya dapat dilihat pada Tabel 3.47 Bobot Baru Filter B2.

Tabel 3.47 Bobot Baru Filter B2

<i>x,y</i>	0	1	2	3	4	5	6
0	-0,39	0,41	-0,16	-0,18	0,399	0,409	0,061
1	0,33	0,21	0,12	0,34	-0,001	0,071	0,131
2	0,46	-0,04	0,4	-0,2	-0,439	0,361	-0,119
3	-0,34	-0,08	-0,11	-0,16	0,101	-0,139	0,399
4	-0,39	0,26	-0,22	0,1	-0,051	-0,171	-0,391
5	0,14	-0,16	-0,22	0,26	0,401	0,419	-0,131
6	-0,261	-0,431	0,12	0,4	0,011	0,219	0,329

Terakhir lakukan proses konvolusi antara $\frac{\partial L}{\partial FB3}$ dengan feature map RA1, RA2 dan RA3, hasil keseluruhan dapat dilihat pada Tabel 3.48 Matriks Gradien $\frac{\partial L}{\partial B3}$.

Tabel 3.48 Matriks Gradien $\frac{\partial L}{\partial B3}$

<i>i,j</i>	0	1	2	3	4	5	6
0	0	0	0	0	77,60537111	97,67764513	-0,426885856
1	0	0	0	0	55,96279609	-6,022692778	-5,69930922
2	0	0	0	0	-18,95379721	-58,53128304	8,751567541
3	0	0	0	0	-13,05269926	-15,05249406	10,36718136
4	0	0	0	0	40,4330505	148,0371365	113,4733998
5	0	0	0	0	10,46954269	124,2237841	48,9295297
6	0	0	0	0	-14,71395189	57,9774235	-21,81681747

Setelah gradien $\frac{\partial L}{\partial B3}$ didapat, lakukan perhitungan nilai bobot filter B3 baru menggunakan Adam Optimizer, hasilnya dapat dilihat pada Tabel 3.49 Bobot Baru Filter B3.

Tabel 3.49 Bobot Baru Filter B3

x, y	0	1	2	3	4	5	6
0	0,36	-0,32	0,39	-0,26	-0,311	-0,001	-0,189
1	0,03	0,25	0,08	0,26	0,169	0,101	-0,409
2	-0,37	-0,16	-0,37	0,07	0,061	0,411	-0,401
3	-0,29	0,15	0,04	0,32	-0,199	-0,149	-0,301
4	0,13	0,21	0,37	-0,17	-0,491	-0,441	0,339
5	0,49	-0,48	-0,11	-0,03	0,409	0,289	-0,431
6	0,46	-0,24	0,03	0,29	0,401	0,429	-0,479

5. Perhitungan Gradien Terhadap Bobot Filter A


Terakhir akan dilakukan perhitungan gradien terhadap bobot pada filter A menggunakan rumus *chain rule* yang dapat dilihat pada persamaan (2.16).

$$\frac{\partial L}{\partial A_i} = \sum_{j=1}^n \frac{\partial L}{\partial R_{Ai}} \frac{\partial R_{Ai}}{\partial F_{Ai}} \frac{\partial F_{Ai}}{\partial A_i} \quad (2.16)$$

Sebelum melakukan perhitungan terhadap gradien filter A, perlu dilakukan perhitungan dari $\frac{\partial L}{\partial R_{Ai}}$ dengan melakukan operasi *cross-correlation* antara $\frac{\partial L}{\partial F_{Bi}}$ dengan Filter Bi yang dapat dilihat pada Tabel 3.15 Bobot *Convolutional Filter* B1 [14] menggunakan persamaan (2.6).

$$\begin{aligned} \frac{\partial L}{\partial R_{A1_{i,j}}} &= \sum_{m=0}^{-3} \sum_{n=0}^{-3} B_1 \mathbf{1}_{i+m, j+n} \frac{\partial L}{\partial F_{B1_{-m,-n}}} \\ \frac{\partial L}{\partial R_{A1_{0,0}}} &= \sum_{m=0}^{-3} \sum_{n=0}^{-3} B_1 \mathbf{1}_{0+m, 0+n} \frac{\partial L}{\partial F_{B1_{-m,-n}}} \\ \frac{\partial L}{\partial R_{A1_{0,0}}} &= (B_1_{0,0} * \frac{\partial L}{\partial F_{B1_{0,0}}} + 0 * \frac{\partial L}{\partial F_{B1_{0,1}}} + 0 * \frac{\partial L}{\partial F_{B1_{0,2}}} + \dots + 0 * \frac{\partial L}{\partial F_{B1_{3,3}}}) \\ &= (0,31 * -0,243406979 + 0 * 0,104700796 + 0 * -0,049793602 + \dots + 0 * 0) \\ &= -0,075456164 \end{aligned} \quad (2.6)$$

Visualisasi proses tersebut dapat dilihat pada Gambar 3.17 Visualisasi 1 Operasi Cross-Correlation Matriks Gradien $\frac{\partial L}{\partial R_{A1}}$.




Gambar 3.17 Visualisasi 1 Operasi Cross-Correlation Matriks Gradien $\frac{\partial L}{\partial RA1}$

Setelah itu geser filter ke kanan dan lakukan kembali operasi konvolusi.

$$\begin{aligned} \frac{\partial L}{\partial RA1_{0,1}} &= (B1_{0,1} * \frac{\partial L}{\partial FB1_{0,0}} + B1_{0,0} * \frac{\partial L}{\partial FB1_{0,1}} + 0 * \frac{\partial L}{\partial FB1_{0,2}} + \dots + 0 * \frac{\partial L}{\partial FB1_{3,3}}) \\ &= (-0,243406979 * 0,31 + 0,104700796 * -0,14 + 0 * -0,049793602 + \dots + 0 * 0) \\ &= 0,066534224 \end{aligned}$$

Visualisasi dari proses tersebut dapat dilihat pada Gambar 3.18 Visualisasi 2

Operasi Cross-Correlation Matriks Gradien $\frac{\partial L}{\partial RA1}$.



Gambar 3.18 Visualisasi 2 Operasi Cross-Correlation Matriks Gradien $\frac{\partial L}{\partial RA1}$

Proses tersebut terus diulang hingga seluruh permukaan matriks. Hasil dari proses tersebut dapat dilihat pada Tabel 3.50 Matriks Gradien $\frac{\partial L}{\partial RA1}$.

Tabel 3.50 Matriks Gradien $\frac{\partial L}{\partial RA_1}$

<i>i,j</i>	0	1	2	3	9
0	-0,075456164	0,066534224	-0,137193199	-0,036663176	-0,004653369
1	0,095874097	-0,013785605	-0,105850715	0,141476471	-0,005065013
2	0,219728491	-0,26200767	0,198291035	0,126215595	-0,014757187
3	-0,141856156	-0,127795056	0,243178785	-0,029265726	0,064539284
.....
9	0	0	0	0	0	0

Selanjutnya, lakukan proses yang sama antara antara $\frac{\partial L}{\partial FB_2}$ dengan Filter B2, hasil dari proses tersebut dapat dilihat pada Tabel 3.51 Matriks Gradien $\frac{\partial L}{\partial RA_2}$ dan antara $\frac{\partial L}{\partial FB_3}$ dengan Filter B3, hasil dari proses tersebut dapat dilihat pada Tabel 3.52 Matriks Gradien $\frac{\partial L}{\partial RA_3}$.

Tabel 3.51 Matriks Gradien $\frac{\partial L}{\partial RA_2}$

<i>i,j</i>	0	1	2	3	9
0	0,126488533	-0,233113958	0,118552239	0,170769044	-0,017365758
1	-0,056448303	-0,036550677	0,076827245	-0,061763882	-0,049610791
2	-0,130142195	0,038830061	-0,125757929	-0,118214102	0,023909239
3	-0,001720085	-0,089469323	-0,088697171	0,008845875	-0,042534219
.....
9	0	0	-0,012082139	-0,091278256	0,090491402

Tabel 3.52 Matriks Gradien $\frac{\partial L}{\partial RA_3}$

<i>i,j</i>	0	1	2	3	9
0	-0,039717269	0,035304239	-0,043027041	0,028684694	0
1	-0,135554932	0,089969816	-0,152091649	0,066825699	0
2	0,123708657	-0,157659073	0,113166987	-0,171056044	0
3	0,175738816	0,107441042	0,152374175	0,006804273	0
.....
9	0	0	0	0	0	0

Setelah mendapat matriks $\frac{\partial L}{\partial RA_1}$, $\frac{\partial L}{\partial RA_2}$ dan $\frac{\partial L}{\partial RA_3}$. Selanjutnya melakukan perhitungan untuk mencari nilai $\frac{\partial L}{\partial FA_i}$.

$$\frac{\partial L}{\partial FA_i} = \sum_{j=1}^3 \frac{\partial L}{\partial RA_j} \frac{\partial RA_j}{\partial FA_i}$$

$$\frac{\partial L}{\partial FA_{1,0}} = \frac{\partial L}{\partial RA_{1,0}} * \frac{\partial RA_{1,0}}{\partial FA_{1,0}} + \frac{\partial L}{\partial RA_{2,0}} * \frac{\partial RA_{2,0}}{\partial FA_{1,0}} + \frac{\partial L}{\partial RA_{3,0}} * \frac{\partial RA_{3,0}}{\partial FA_{1,0}}$$

$$\begin{aligned}
&= \frac{\partial L}{\partial RA_{1,0}} * \begin{cases} 1 & FA1_{0,0} \geq 0 \\ 0 & FA1_{0,0} < 0 \end{cases} + \frac{\partial L}{\partial RA_{2,0}} * \begin{cases} 1 & FA1_{0,0} \geq 0 \\ 0 & FA1_{0,0} < 0 \end{cases} + \frac{\partial L}{\partial RA_{3,0}} * \\
&\quad \begin{cases} 1 & FA1_{0,0} \geq 0 \\ 0 & FA1_{0,0} < 0 \end{cases} \\
&= (-0,075456164 * 1) + (0,126488533 * 1) + (-0,039717269 * 1) \\
&= 0,011315101
\end{aligned}$$

Nilai hasil keseluruhan perhitungan keseluruhan dari matriks $\frac{\partial L}{\partial FA_1}$ dapat dilihat pada Tabel 3.53 Matriks $\frac{\partial L}{\partial FA_1}$.

Tabel 3.53 Matriks $\frac{\partial L}{\partial FA_1}$

<i>i,j</i>	0	1	2	3	9
0	0,011315101	-0,131275495	-0,061668002	0,162790562	-0,022019127
1	-0,096129138	0,039633534	-0,181115119	0,146538288	-0,054675804
2	0,213294954	-0,380836682	0,185700093	-0,163054551	0,009152051
3	0,032162576	-0,109823337	0,30685579	-0,013615578	0,022005065
.....
9	0	0	-0,012082139	-0,091278256	0,090491402

Lakukan proses yang sama untuk matriks $\frac{\partial L}{\partial RA_2}$ yang menghasilkan $\frac{\partial L}{\partial FA_2}$, hasilnya dapat dilihat pada Tabel 3.54 Matriks $\frac{\partial L}{\partial FA_2}$ dan matriks $\frac{\partial L}{\partial RA_3}$ yang menghasilkan $\frac{\partial L}{\partial FA_3}$, hasilnya dapat dilihat pada Tabel 3.55 Matriks $\frac{\partial L}{\partial FA_3}$.

Tabel 3.54 Matriks $\frac{\partial L}{\partial FA_2}$

<i>i,j</i>	0	1	2	3	9
0	0,011315101	-0,131275495	-0,061668002	0,162790562	0
1	-0,096129138	0,039633534	-0,181115119	0,146538288	0
2	0,213294954	-0,380836682	0,185700093	-0,163054551	0
3	0,032162576	-0,109823337	0,30685579	-0,013615578	0
.....
9	0	0	0	0	0


Tabel 3.55 Matriks $\frac{\partial L}{\partial FA_3}$

<i>i,j</i>	0	1	2	3	9
0	0,011315101	-0,131275495	-0,061668002	0,162790562	-0,022019127
1	-0,096129138	0,039633534	-0,181115119	0,146538288	-0,054675804
2	0,213294954	-0,380836682	0,185700093	-0,163054551	0,009152051
3	0,032162576	-0,109823337	0,30685579	-0,013615578	0
.....
9	0	0	-0,012082139	0	0

Setelah nilai dari $\frac{\partial L}{\partial FA1}$, $\frac{\partial L}{\partial FA2}$ dan $\frac{\partial L}{\partial FA3}$ diketahui, lakukan proses konvolusi antara $\frac{\partial L}{\partial FA1}$ dengan citra input yang dapat dilihat pada Tabel 3.5 Nilai Pixel Citra Masukan C (*Current State*) untuk menghasilkan gradien $\frac{\partial L}{\partial A1}$. Karena filter pada A1 bernilai *stride* 3 maka pixel-pixel pada matriks $\frac{\partial L}{\partial FA1}$ akan dilakukan pelebaran (*dilatation*) sejumlah *stride*-1 sehingga besar lebaran adalah 2 pixel diantara dua pixel bersebelahan dan diisi 0. Berikut perhitungannya.

$$\begin{aligned}\frac{\partial L}{\partial A1_{i,j}} &= \sum_{m=0}^{27} \sum_{n=0}^{27} \frac{\partial L}{\partial FA1_{m,n}} \cdot C_{i*1+m, j*1+n} \quad (2.5) \\ \frac{\partial L}{\partial A1_{0,0}} &= \frac{\partial L}{\partial FA1_{0,0}} \cdot C_{0,0} + \frac{\partial L}{\partial FA1_{0,1}} \cdot C_{0,1} + \frac{\partial L}{\partial FA1_{0,2}} \cdot C_{0,2} + \frac{\partial L}{\partial FA1_{0,3}} \cdot C_{0,3} + \dots + \\ &\quad \frac{\partial L}{\partial FA1_{27,27}} \cdot C_{27,27} \\ &= (0,011315101*0 + 0*0 + 0*0 + -0,131275495*0 + \dots + 0,090491402*255) \\ &= 22,30971661\end{aligned}$$

Visualisasi dari proses tersebut dapat dilihat pada Gambar 3.19 Visualisasi 1 Operasi Konvolusi Matriks Gradien $\frac{\partial L}{\partial A1}$



Gambar 3.19 Visualisasi 1 Operasi Konvolusi Matriks Gradien $\frac{\partial L}{\partial A1}$


Setelah itu geser filter ke kanan dan lakukan kembali operasi konvolusi.

$$\begin{aligned}\frac{\partial L}{\partial A1_{0,1}} &= \frac{\partial L}{\partial FA1_{0,0}} \cdot C_{0,1} + \frac{\partial L}{\partial FA1_{0,1}} \cdot C_{0,2} + \frac{\partial L}{\partial FA1_{0,2}} \cdot C_{0,3} + \dots + \frac{\partial L}{\partial FA1_{27,26}} \cdot C_{27,26} + \\ &\quad \frac{\partial L}{\partial FA1_{27,27}} \cdot C_{27,27}\end{aligned}$$

$$\begin{aligned}
 &= (0,011315101*0 + 0*0 + 0*0 + \dots + 0*255 + 0,090491402*255) \\
 &= 54,68556143
 \end{aligned}$$

Visualisasi dari proses tersebut dapat dilihat pada Gambar 3.20 Visualisasi 2

Operasi Konvolusi Matriks Gradien $\frac{\partial L}{\partial A1}$.



Gambar 3.20 Visualisasi 2 Operasi Konvolusi Matriks Gradien $\frac{\partial L}{\partial A1}$

Proses tersebut terus diulang hingga seluruh permukaan matriks dan menghasilkan

gradien $\frac{\partial L}{\partial A1}$ dapat dilihat pada Tabel 3.56 Matriks Gradien $\frac{\partial L}{\partial A1}$.

Tabel 3.56 Matriks Gradien $\frac{\partial L}{\partial A1}$

i, j	0	1	2	3	4
0	22,30971661	54,68556143	54,90446472	54,90446472	158,4784809
1	-1,12890853	41,02879994	41,24770323	41,24770323	168,2603446
2	-6,740200047	3,041663597	3,260566883	3,260566883	10,00076693
3	-33,097101	-38,8469389	0,179621311	0,179621311	122,6692937
4	-30,48933208	-158,552644	-116,4451382	-113,3641926	72,20678904

Setelah melakukan perhitungan gradien $\frac{\partial L}{\partial A1}$, lalu lakukan perhitungan bobot baru filter A1 menggunakan Adam Optimizer, diawali menghitung m_I .

$$m_t = \beta_1 * m_{t-1} + (1 - \beta_1) * \frac{\partial L}{\partial A1_{0,0}} \quad (2.17)$$

$$m_I = 0,9 * 0 + (1 - 0,9) * 22,30971661$$

$$m_I = 2,230971661$$

Selanjutnya, hitung nilai v_I menggunakan persamaan (2.18).

$$\nu_t = \beta_2 * \nu_{t-1} + (1 - \beta_2) * \frac{\partial L}{\partial A1_{0,0}}^2 \quad (2.18)$$

$$\nu_1 = 0,999 * 0 + (1 - 0,999) * 22,30971661^2$$

$$\nu_1 = 0,497723455$$

Lalu hitung nilai \hat{m}_I menggunakan persamaan (2.19).

$$\hat{m}_t = m_t / (1 - \beta_1^t) \quad (2.19)$$

$$\hat{m}_I = 2,230971661 / (1 - 0,9^1)$$

$$\hat{m}_I = 22,30971661$$

Setelah itu lakukan perhitungan nilai $\hat{\nu}_I$ menggunakan persamaan (2.20).

$$\hat{\nu}_t = \nu_t / (1 - \beta_2^t) \quad (2.20)$$

$$\hat{\nu}_1 = 0,497723455 / (1 - 0,999^1)$$

$$\hat{\nu}_1 = 497,723455$$

Terakhir, lakukan perhitungan bobot baru menggunakan persamaan (2.21).

$$A1'_{0,0} = A1_{0,0} - \alpha * \hat{m}_t / (\sqrt{\hat{\nu}_t} + \epsilon) \quad (2.21)$$

$$AI'_{0,0} = AI_{0,0} - \alpha * \hat{m}_I / (\sqrt{\hat{\nu}_1} + \epsilon)$$

$$AI'_{0,0} = 0,05 - 0,001 * 22,30971661 / (\sqrt{497,723455} + 10^{-8})$$

$$AI'_{0,0} = 0,049$$

Nilai hasil perhitungan bobot baru A1 keseluruhan dapat dilihat pada Tabel 3.57 Bobot Baru Filter A1.

Tabel 3.57 Bobot Baru Filter A1

<i>x, y</i>	0	1	2	3	4
0	0,049	0,339	0,379	0,109	0,289
1	0,211	0,269	-0,451	0,239	-0,171
2	0,411	0,219	0,359	-0,181	-0,141
3	0,231	-0,239	-0,451	-0,071	-0,031
4	0,011	-0,139	0,461	0,351	0,219

Selanjutnya, lakukan proses yang sama antara $\frac{\partial L}{\partial FA_2}$ dengan citra input yang dapat dilihat pada Tabel 3.5 Nilai Pixel Citra Masukan C (*Current Sate*). Hasil dari proses tersebut adalah gradien $\frac{\partial L}{\partial A_2}$ dapat dilihat pada Tabel 3.58 Matriks Gradien $\frac{\partial L}{\partial A_2}$.

Tabel 3.58 Matriks Gradien $\frac{\partial L}{\partial A2}$

i, j	0	1	2	3	4
0	0	0	0	0	0
1	0	0	0	0	0
2	0	0	0	0	0
3	0	0	0	0	112,6685268
4	-23,74913203	-116,6247595	-116,6247595	-116,6247595	62,20602211

Lalu lakukan perhitungan nilai bobot baru A2 menggunakan Adam Optimizer, hasil perhitungan bobot baru A2 dapat dilihat pada Tabel 3.59 Bobot Baru Filter A2.

Tabel 3.59 Bobot Baru Filter A2

x, y	0	1	2	3	4
0	0,07	0,21	0,34	-0,31	-0,43
1	-0,35	0,14	-0,48	-0,27	-0,25
2	0,05	0,15	-0,11	0,05	0,16
3	-0,18	0,13	-0,45	-0,23	0,349
4	-0,269	0,291	0,391	0,221	0,149

Terakhir, lakukan proses yang sama antara $\frac{\partial L}{\partial FA3}$ dengan citra inputan. Hasil proses tersebut adalah gradien $\frac{\partial L}{\partial A3}$ yang dapat dilihat pada Tabel 3.60 Matriks Gradien $\frac{\partial L}{\partial A3}$.

Tabel 3.60 Matriks Gradien $\frac{\partial L}{\partial A3}$

i, j	0	1	2	3	4
0	16,69842509	49,07426992	49,2931732	49,2931732	158,4784809
1	-6,740200047	35,41750843	35,63641171	35,63641171	168,2603446
2	-6,740200047	3,041663597	3,260566883	3,260566883	10,00076693
3	-9,821145619	-38,8469389	0,179621311	0,179621311	122,6692937
4	-30,48933208	-158,552644	-116,4451382	-113,3641926	72,20678904

Lalu lakukan perhitungan nilai bobot baru filter A3 menggunakan Adam Optimizer. Hasil perhitungan keseluruhan dapat dilihat pada Tabel 3.61 Bobot Baru Filter A3.

Tabel 3.61 Bobot Baru Filter A3

x, y	0	1	2	3	4
0	0,219	-0,221	0,239	-0,031	0,189
1	-0,259	-0,041	-0,411	0,249	0,359
2	-0,169	0,479	-0,311	0,299	-0,441
3	-0,459	-0,189	-0,211	0,459	0,219
4	0,361	0,391	0,341	0,021	0,469

Setelah bobot-bobot baru didapatkan, selanjutnya bobot tersebut akan digunakan untuk perhitungan *Q-value* untuk setiap *action* di suatu *state*. Detail proses pemilihan *action* akan dijelaskan pada bagian Analisis Pemilihan Action.

3.7.2. Analisis Pemilihan Action


Setelah proses pelatihan CNN dan menghasilkan bobot baru, selanjutnya bobot baru tersebut dipergunakan pada tahap eksplorasi untuk menghitung *Q-value* dari setiap action yang bisa dilakukan *agent* dengan *inputan current state* dari permainan *flappy bird*. Gambaran proses pemilihan action dengan CNN dapat dilihat pada Gambar 3.21 Tahapan Proses Memilih Action dengan CNN.



Gambar 3.21 Tahapan Proses Memilih Action dengan CNN

Proses dimulai dengan *feedforward* pada CNN dengan *input current state*, *output* dari feedforward adalah nilai *Q-value* untuk setiap *action* (0 dan 1). Selanjutnya *agent* akan memutuskan *action* yang akan diambil dengan membandingkan nilai *Q-value* dari seluruh *action*, *action* dengan nilai *Q-value* terbesar akan menjadi *action* yang dipilih dan selanjutnya dieksekusi di permainan *flappy bird*.

Sebagai contoh, dilakukan pemilihan action terhadap state C yang sudah *dipreprocessing*, untuk state C dapat dilihat pada Gambar 3.22 State C. Gambar 3.22 State tersebut memiliki ukuran 32 x 32 dengan nilai disetiap *pixel*-nya dapat dilihat pada Tabel 3.62 Nilai Pixel State C.



Gambar 3.22 State C

Tabel 3.62 Nilai Pixel State C

x, y	0	1	2	3	4	5	6	30	31
0	0	0	0	0	0	0	0	255	255
1	0	0	0	0	0	0	0	255	255
2	0	0	0	0	0	0	0	255	255
3	0	0	0	0	0	0	0	255	255
4	0	0	0	0	0	0	0	255	255
5	0	0	0	0	0	0	0	255	255
6	0	0	0	0	0	0	0	255	255
.....
30	0	0	0	0	0	0	0	255	255
31	0	0	0	0	0	0	0	255	255

Pertama-tama Tabel 3.62 Nilai Pixel State C akan memasuki layer pertama yaitu *convolution layer A*.

1. Convolution Layer A

Pada *convolution layer A* akan dilakukan konvolusi antara matriks citra masukan Tabel 3.62 Nilai Pixel State C dengan matriks-matrik pada filter A. Pada layer ini terdapat 3 filter dengan ukuran 3x3 dengan *stride* 3. Proses pertama akan dilakukan konvolusi antara filter A1 yang dapat dilihat pada Tabel 3.63 *Convolution Filter A1* dan biasnya 0.

Tabel 3.63 Convolution Filter A1

x, y	0	1	2	3	4
0	0,049	0,339	0,379	0,109	0,289
1	0,211	0,269	-0,451	0,239	-0,171
2	0,411	0,219	0,359	-0,181	-0,141
3	0,231	-0,239	-0,451	-0,071	-0,031
4	0,011	-0,139	0,461	0,351	0,219

Berikut adalah operasi konvolusi menggunakan persamaan (2.5) antara citra *state C* dengan filter A1 yang akan menghasilkan *feature map FA1*.

$$FA1_{i,j} = \sum_{m=0}^4 \sum_{n=0}^4 A1_{m,n} \cdot C_{i*3+m, j*3+n} + b \quad (2.5)$$

$$\begin{aligned} FA1_{0,0} &= (A1_{0,0} \cdot C_{0,0} + A1_{0,1} \cdot C_{0,1} + A1_{0,2} \cdot C_{0,2} + \dots + A1_{4,4} \cdot C_{4,4}) + bA_0 \\ &= (0,049*0 + 0,339*0 + 0,379*0 + \dots + 0,219*0) + 0 \\ &= 0 \end{aligned}$$

$$FA1_{0,1} = (A1_{0,0} \cdot C_{0,3} + A1_{0,1} \cdot C_{0,4} + A1_{0,2} \cdot C_{0,5} + \dots + A1_{4,4} \cdot C_{4,7}) + bA_0$$

$$= (0,049*0 + 0,339*0 + 0,379*0 + \dots + 0,219*0) + 0 \\ = 0$$

Operasi tersebut akan terus diulang hingga seluruh permukaan citra *state* C. Hasil keseluruhan proses pada filter A1 dapat dilihat pada Tabel 3.64 *Feature Map* FA1.

Tabel 3.64 *Feature Map* FA1

Langkah selanjutnya adalah menjalankan fungsi aktivasi pada *feature map* FA menggunakan fungsi aktivasi ReLU dan menghasilkan *feature map* RA1. Berikut adalah persamaannya (2.7).

$$f(x) = \max(0, x) \quad (2.7)$$

$$\begin{aligned} \text{RA1}_{0,0} &= \max(0, \text{FA1}_{0,0}) \\ &= \max(0, 0) \\ &\equiv 0 \end{aligned}$$

$$\begin{aligned} \text{RA1}_{0,1} &= \max(0, \text{FA1}_{0,1}) \\ &= \max(0, 0) \\ &\equiv 0 \end{aligned}$$

Hasil dari fungsi aktivasi dapat dilihat pada Tabel 3.65 *Feature Map* RA1.

Tabel 3.65 Feature Map RA1

Setelah proses pada filter A1 selesai, lakukan proses konvolusi terhadap *state* C dengan filter A2. Bobot pada filter A2 dapat dilihat pada Tabel 3.66 *Convolution Filter A2*.

Tabel 3.66 Convolution Filter A2

x, y	0	1	2	3	4
0	0,07	0,21	0,34	-0,31	-0,43
1	-0,35	0,14	-0,48	-0,27	-0,25
2	0,05	0,15	-0,11	0,05	0,16
3	-0,18	0,13	-0,45	-0,23	0,349
4	-0,269	0,291	0,391	0,221	0,149

Proses ini akan menghasilkan *feature map* FA2. Hasil keseluruhan proses pada filter A2 dapat dilihat pada Tabel 3.67 *Feature Map* FA2.

Tabel 3.67 Feature Map FA2

x, y	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	0	-143,055
1	0	0	0	0	0	0	0	0	0	-143,055
2	0	0	0	0	0	0	0	0	0	-143,055
3	0	0	0	0	0	0	0	0	0	-321,3
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	56,355	87,465	-68,595	0	0	0	0	0	94,35
7	0	-28,05	-270,3	-89,25	0	0	0	0	0	45,645
8	0	0	0	0	0	0	0	0	0	-143,055
9	0	0	0	0	0	0	0	0	0	-143,055

Selanjutnya jalankan fungsi aktivasi ReLU pada *feature map* FA2 dan menghasilkan *feature map* RA2 dapat dilihat pada Tabel 3.68 *Feature Map* RA2.

Tabel 3.68 Feature Map RA2

x, y	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	56,355	87,465	0	0	0	0	0	0	94,35
7	0	0	0	0	0	0	0	0	0	45,645
8	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	0	0

Terakhir, lakukan proses konvolusi terhadap *state* C dengan filter A3. Bobot pada filter A3 dapat dilihat pada Tabel 3.69 *Convolution Filter* A3.

Tabel 3.69 Convolution Filter A3

<i>x, y</i>	0	1	2	3	4
0	0,219	-0,221	0,239	-0,031	0,189
1	-0,259	-0,041	-0,411	0,249	0,359
2	-0,169	0,479	-0,311	0,299	-0,441
3	-0,459	-0,189	-0,211	0,459	0,219
4	0,361	0,391	0,341	0,021	0,469

Proses ini akan menghasilkan *feature map* FA3. Hasil keseluruhan proses pada filter A2 dapat dilihat pada Tabel 3.70 *Feature Map* FA3.

Tabel 3.70 Feature Map FA3

<i>x, y</i>	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	0	456,96
1	0	0	0	0	0	0	0	0	0	456,96
2	0	0	0	0	0	0	0	0	0	456,96
3	0	0	0	0	0	0	0	0	0	195,33
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	5,355	184,365	92,055	0	0	0	0	0	124,95
7	0	-48,96	-64,515	-66,045	0	0	0	0	0	416,67
8	0	0	0	0	0	0	0	0	0	456,96
9	0	0	0	0	0	0	0	0	0	456,96

Lalu jalankan fungsi aktivasi ReLU pada *feature map* FA3 dan menghasilkan *feature map* RA3 yang dapat dilihat pada Tabel 3.71 *Feature Map* RA3.

Tabel 3.71 Feature Map RA3

<i>x, y</i>	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	0	456,96
1	0	0	0	0	0	0	0	0	0	456,96
2	0	0	0	0	0	0	0	0	0	456,96
3	0	0	0	0	0	0	0	0	0	195,33
4	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0
6	0	5,355	184,365	92,055	0	0	0	0	0	124,95
7	0	0	0	0	0	0	0	0	0	416,67
8	0	0	0	0	0	0	0	0	0	456,96
9	0	0	0	0	0	0	0	0	0	456,96

Hasil dari *convolutional layer* A, yaitu Feature Map RA1, RA2 dan RA3 akan digunakan pada layer selanjutnya, yaitu *convolutional layer* B.

2. Convolution Layer B

Pada convolutional layer B akan dilakukan proses yang sama seperti pada convolutional layer A hanya saja inputannya rangkap tiga, yaitu feature map RA1,

RA2 dan RA3. Pada convolutional layer B terdapat 3 filter berukuran 7x7 dengan stride 1. Pertama-tama lakukan proses konvolusi antara *feature map* RA1, RA2 dan RA3 dengan bobot pada filter B1. Bobot pada filter B1 dapat dilihat pada Tabel 3.72 *Convoluton Filter* B1 dan biasnya 0.

Tabel 3.72 Convoluton Filter B1

x, y	0	1	2	3	4	5	6
0	0,31	-0,14	0,44	0,25	0,439	-0,361	0,049
1	-0,47	0,09	0,28	0,05	0,399	-0,061	0,089
2	-0,29	0,4	0,25	0,36	0,331	-0,199	0,361
3	-0,1	0,34	-0,1	-0,49	-0,369	-0,179	-0,189
4	-0,01	-0,01	0,21	-0,26	0,429	-0,451	-0,261
5	0,19	0,34	0,1	0,31	0,329	0,169	0,449
6	-0,43	0,06	-0,39	0,03	0,211	0,219	-0,021

Berikut adalah operasi konvolusi menggunakan persamaan (2.5) antara *feature map* RA1, RA2 dan RA3 dengan filter B1 akan menghasilkan *feature map* FB1.

$$FB1_{i,j} = \sum_{c=1}^3 \sum_{m=0}^6 \sum_{n=0}^6 B1_{m,n} \cdot RA_c_{i+1+m, j+1+n} + b \quad (2.5)$$

$$\begin{aligned} FB1_{0,0} &= (B1_{0,0} \cdot RA1_{0,0} + B1_{0,1} \cdot RA1_{0,1} + B3_{0,2} \cdot RA1_{0,2} + \dots + B1_{6,6} \cdot RA3_{6,6}) + bB_0 \\ &= (0,31*0 + -0,14*0 + 0,44*0 + \dots + -0,021*0) + 0 \\ &= -175,37625 \end{aligned}$$

$$\begin{aligned} FB1_{0,1} &= (B1_{0,0} \cdot RA1_{0,1} + B1_{0,1} \cdot RA1_{0,2} + B3_{0,2} \cdot RA1_{0,3} + \dots + B1_{6,6} \cdot RA3_{6,7}) + bB_0 \\ &= (0,31*0 + -0,14*0 + 0,44*0 + \dots + -0,021*0) + 0 \\ &= -72,81015 \end{aligned}$$

Operasi tersebut akan terus diulang hingga seluruh permukaan *feature map* RA1, RA2 dan RA3. Hasil keseluruhan dapat dilihat pada Tabel 3.73 *Feature Map* FB1

Tabel 3.73 Feature Map FB1

x, y	0	1	2	3
0	-175,94235	-73,11615	-201,43725	198,07329
1	74,7201	179,0916	63,7347	345,769035
2	114,86985	73,746	40,4838	191,306865
3	-26,57865	148,7466	-17,9265	63,916515

Langkah selanjutnya adalah menjalankan fungsi aktivasi ReLU pada di *feature map* FB dan menghasilkan *feature map* RB1. Berikut adalah persamaannya (2.7).

$$f(x) = \max(0, x) \quad (2.7)$$

$$\begin{aligned} RB1_{0,0} &= \max(0, FB1_{0,0}) \\ &= \max(0, -175,37625) \\ &= 0 \\ RB1_{0,0} &= \max(0, FB1_{0,0}) \\ &= \max(0, -72,81015) \\ &= 0 \end{aligned}$$

Hasil dari fungsi aktivasi dapat dilihat pada Tabel 3.74 *Feature Map* RB1.

Tabel 3.74 Feature Map RB1

<i>x, y</i>	0	1	2	3
0	0	0	0	198,07329
1	74,7201	179,0916	63,7347	345,769035
2	114,86985	73,746	40,4838	191,306865
3	0	148,7466	0	63,916515

Setelah proses pada filter B1 selesai, lalu lakukan proses konvolusi antara *feature map* RA1, RA2 dan RA3 dengan bobot pada filter B2. Bobot pada filter B2 dapat dilihat pada Tabel 3.75 *Convoluton Filter* B2.

Tabel 3.75 Convoluton Filter B2

<i>x, y</i>	0	1	2	3	4	5	6
0	-0,39	0,41	-0,16	-0,18	0,399	0,409	0,061
1	0,33	0,21	0,12	0,34	-0,001	0,071	0,131
2	0,46	-0,04	0,4	-0,2	-0,439	0,361	-0,119
3	-0,34	-0,08	-0,11	-0,16	0,101	-0,139	0,399
4	-0,39	0,26	-0,22	0,1	-0,051	-0,171	-0,391
5	0,14	-0,16	-0,22	0,26	0,401	0,419	-0,131
6	-0,261	-0,431	0,12	0,4	0,011	0,219	0,329

Hasil dari proses tersebut akan menghasilkan *feature map* FB2 yang dapat dilihat pada Tabel 3.76 *Feature Map* FB2.

Tabel 3.76 Feature Map FB2

<i>x, y</i>	0	1	2	3
0	30,573735	-235,69446	-166,607055	265,31169
1	-77,09619	-140,251275	-9,33249	201,83811
2	-79,5498	13,51755	-151,20735	40,479975
3	-100,75305	-83,7114	-214,75845	30,698685

Lalu jalankan fungsi aktivasi ReLU pada *feature map* FB2 dan menghasilkan *feature map* RB2 yang dapat dilihat pada Tabel 3.77 *Feature Map* RB2.

Tabel 3.77 Feature Map RB2

<i>x, y</i>	0	1	2	3
0	30,573735	0	0	265,31169
1	0	0	0	201,83811
2	0	13,51755	0	40,479975
3	0	0	0	30,698685

Terakhirlakukan proses konvolusi antara *feature map* RA1, RA2 dan RA3 dengan bobot pada filter B3. Bobot pada filter B3 dapat dilihat pada Tabel 3.78 *Convolution Filter* B3.

Tabel 3.78 Convolution Filter B3

<i>x, y</i>	0	1	2	3	4	5	6
0	0,36	-0,32	0,39	-0,26	-0,311	-0,001	-0,189
1	0,03	0,25	0,08	0,26	0,169	0,101	-0,409
2	-0,37	-0,16	-0,37	0,07	0,061	0,411	-0,401
3	-0,29	0,15	0,04	0,32	-0,199	-0,149	-0,301
4	0,13	0,21	0,37	-0,17	-0,491	-0,441	0,339
5	0,49	-0,48	-0,11	-0,03	0,409	0,289	-0,431
6	0,46	-0,24	0,03	0,29	0,401	0,429	-0,479

Hasil dari proses tersebut akan menghasilkan *feature map* FB2 yang dapat dilihat pada Tabel 3.76 *Feature Map* FB2 Tabel 3.79 *Feature Map* FB3.

Tabel 3.79 Feature Map FB3

<i>x, y</i>	0	1	2	3
0	20,04045	-34,09095	102,9486	-577,99677
1	-62,28375	-110,36655	89,0103	-622,449645
2	97,88685	99,16695	54,66945	-498,087165
3	49,5873	26,5608	-65,02245	-388,731435

Lalu jalankan fungsi aktivasi ReLU pada *feature map* FB3 dan menghasilkan *feature map* RB3 yang dapat dilihat pada Tabel 3.80 *Feature Map* RB3.

Tabel 3.80 Feature Map RB3

<i>x, y</i>	0	1	2	3
0	20,04045	0	102,9486	0
1	0	0	89,0103	0
2	97,88685	99,16695	54,66945	0
3	49,5873	26,5608	0	0

Hasil proses dari *convolutional layer* B, yaitu *Feature Map* RB1, RB2 dan RB3 akan digunakan pada layer selanjutnya, yaitu *fully-connected layer*. *Fully-connected layer* adalah sebuah *neural network* yang memiliki *input layer*, *hidden layer* dan *output layer*. Berikut adalah operasi-operasi yang terjadi di masing-masing layer.

3. Input Layer (*Flatten*)

Pada input layer akan terjadi penggabungan dari matriks *feature map* RB1, RB2 dan RB3. Matriks akan diratakan menjadi sebuah vektor dengan panjang sejumlah keseluruhan pixel dari RB1, RB2 dan RB3. Total pixel dari ketiga *feature map* adalah 48, sehingga *input layer* X memiliki 48 node. Vector *input layer* X dapat dilihat pada Tabel 3.81 *Input Layer* X.

Tabel 3.81 Input Layer X

<i>i</i>	X	<i>i</i>	X	<i>i</i>	X
0	0	16	30,5737	32	20,0404
1	0	17	0	33	0
2	0	18	0	34	102,949
3	198,073	19	265,312	35	0
4	74,7201	20	0	36	0
5	179,092	21	0	37	0
6	63,7347	22	0	38	89,0103
7	345,769	23	201,838	39	0
8	114,87	24	0	40	97,8868
9	73,746	25	13,5176	41	99,1669
10	40,4838	26	0	42	54,6694
11	191,307	27	40,48	43	0
12	0	28	0	44	49,5873
13	148,747	29	0	45	26,5608
14	0	30	0	46	0
15	63,9165	31	30,6987	47	0

Selanjutnya nilai dari *input layer X* akan digunakan pada *hidden layer Z*.

4. Hidden Layer

Pada hidden layer, setiap node X_j akan dilakukan operasi menggunakan persamaan (2.9). Matriks nilai bobot V dapat dilihat pada Tabel 3.82 Bobot *Hidden Layer V* dan untuk nilai biasnya semua bernilai 0

Tabel 3.82 Bobot Hidden Layer V

x, y	0	1	2	3	4	5	6	7	8	9
0	-0,14	0,13	0,15	-0,33	0,35	-0,34	-0,41	0,35	0,19	-0,26
1	-0,479	0,249	-0,28	0,349	0,381	0,39	-0,299	-0,409	-0,35	-0,061
2	-0,299	-0,421	0,47	0,069	0,211	0,25	-0,279	0,161	0,09	0,349
3	0,041	0,359	-0,02	0,469	0,151	0,16	0,261	0,451	-0,42	-0,121
4	0,24	0,2	0,34	-0,12	0,37	0,44	0,04	-0,16	-0,21	0,18
5	-0,059	0,479	-0,19	0,489	-0,079	0,36	0,231	-0,189	0,19	-0,231
.....
44	0,24	0,21	-0,48	-0,17	-0,06	-0,41	0,3	0,3	-0,44	0,05
45	0,1	-0,19	-0,49	-0,42	0,27	-0,38	-0,08	0,14	0,01	-0,13
46	0,13	-0,31	-0,3	0,42	-0,08	-0,35	-0,1	0,29	0,19	-0,25
47	0,29	-0,08	0,12	-0,35	0,24	-0,15	0	0,49	-0,19	-0,42

Berikut adalah contoh perhitungannya menggunakan persamaan (2.9).

$$\begin{aligned}
 z_{in_i} &= \sum_{j=0}^{n=47} X_j * V_{j,i} + bV_i & (2.9) \\
 z_{ino} &= \sum_{j=0}^{n=47} X_j * V_{j,0} + bV_0 \\
 &= (0*-0,14 + 0*-0,479 + 0*-0,299 + \dots + 0*0,29) + 0 \\
 &= 141,6030275
 \end{aligned}$$

Hasil keseluruhan perhitungan Z_{in} dapat dilihat pada Tabel 3.83 Nilai Z_{in} .

Tabel 3.83 Nilai Z_{in}

i	z_{in}
0	141,6030275
1	505,9909181
2	-41,4783612
3	91,0151406
4	-12,71595495
5	115,2726684
6	269,8081356
7	407,033193
8	-199,6155759
9	18,3301038

Langkah selanjutnya adalah menjalankan fungsi aktivasi pada setiap nilai-nilai di z_{in} menggunakan fungsi aktivasi ReLU dan menghasilkan nilai Z. Berikut adalah contoh perhitungannya.

$$\begin{aligned} Z &= \max(0, z_{in}) \\ &= \max(0, 141,6030275) \\ &= 141,6030275 \end{aligned}$$

Proses tersebut menghasilkan nilai Z yang dapat dilihat pada Tabel 3.84 Nilai Z.

Tabel 3.84 Nilai Z

<i>i</i>	Z
0	141,6030275
1	505,9909181
2	0
3	91,0151406
4	0
5	115,2726684
6	269,8081356
7	407,033193
8	0
9	18,3301038

5. Output Layer

Selanjutnya, hasil perhitungan pada *hidden layer Z* akan digunakan untuk menghitung nilai *output Y*. Matriks bobot V dapat dilihat pada Tabel 3.85 Bobot *Output Layer W*.

Tabel 3.85 Bobot *Output Layer W*

<i>x, y</i>	0	1
0	0,211	0,27
1	-0,349	-0,09
2	-0,09	0,27
3	-0,149	-0,21
4	0,611	0,32
5	0,32	-0,19
6	0,111	0,37
7	0,361	-0,16
8	0,35	0,34
9	-0,429	0,04

Berikut adalah contoh perhitungannya

$$y_{in_i} = \sum_{j=0}^{n=9} Z_j * W_{j,i} + bV_i \quad (2.9)$$

$$\begin{aligned} y_{ino} &= Z_0*W_{0,0} + Z_1*W_{0,1} + Z_2*W_{0,2} + Z_3*W_{0,3} + \dots + Z_9*W_{0,9} \\ &= (141,6030275*0,211 + 505,9909181*-0,339 + 0*-0,09 + \dots + \\ &\quad 18,3301038*-0,429) + 0 \\ &= 45,63747753 \end{aligned}$$

Hasil perhitungan keseluruhan y_{in} dapat dilihat pada Tabel 3.86 Nilai y_{in} .

Tabel 3.86 Nilai y_{in}

i	y_{in}
0	45,63747753
1	-12,88444829

Selanjutnya, aktifkan fungsi aktifasi untuk setiap nilai dengan fungsi aktifasi linear dengan persamaan (2.7). berikut adalah contoh perhitungannya.

$$Y_0 = y_{ino}$$

$$Y_0 = 45,63747753$$

Hasil perhitungan Y dapat dilihat pada Tabel 3.87 Nilai Y.

Tabel 3.87 Nilai Y

i	Y
0	45,63747753
1	-12,88444829

Nilai Y merupakan nilai output pada CNN yang akan menjadi $Q\text{-value}$ untuk setiap *action*. Nilai Y_0 akan menjadi $Q\text{-value}$ dari *action* 0 dan Nilai Y_1 akan menjadi $Q\text{-value}$ dari *action* 1. Pengambilan *action* akan dilihat dari nilai $Q\text{-value}$, *action* dengan nilai $Q\text{-value}$ terbesar akan menjadi *action* yang dipilih, untuk state Gambar 3.22 *State C* nilai $Q\text{-value}$ terbesar adalah *action* 0 maka *action* 0 menjadi *action* yang dipilih oleh *agent*.

3.8 Analisis Kebutuhan Non-fungsional

Kebutuhan non-fungsional meliputi kebutuhan *hardware* dan kebutuhan *software* minimal agar implementasi algoritma pada penelitian ini dapat berjalan dengan baik.

3.8.1. Analisis Kebutuhan *Hardware*

Spesifikasi *Hardware* yang dibutuhkan pada penelitian ini dapat dilihat pada Tabel 3.88 Spesifikasi Kebutuhan *Hardware*.

Tabel 3.88 Spesifikasi Kebutuhan *Hardware*

Hardware	Spesifikasi
<i>Processor</i>	<i>Dual Core</i> atau lebih tinggi
<i>RAM</i>	4 GB atau lebih tinggi
<i>Display</i>	Resolusi 1024x768 atau lebih tinggi
<i>Keyboard</i> dan <i>Mouse</i>	<i>Standard</i>

3.8.2. Analisis Kebutuhan *Software*

Spesifikasi dari *software* yang dibutuhkan pada penelitian ini dapat dilihat pada Tabel 3.89 Spesifikasi Kebutuhan *Software*.

Tabel 3.89 Spesifikasi Kebutuhan *Software*


Software	Spesifikasi
<i>Operating System</i>	<i>Windows 8</i>
<i>Development Kit</i>	Python 3 keatas, TensorFlow 2 keatas, Keras 2.0 keatas, PyQt5, OpenCV 4 dan PyGame

3.9 Analisis Kebutuhan Fungsional

Analisis kebutuhan fungsional berisi analisis proses yang akan diterapkan di dalam sistem dan memberikan gambaran mengenai rencana desain dari sistem agar menggunakan UML (*Unified Modeling Language*) agar lebih mudah dipahami. Kebutuhan fungsional meliputi beberapa diagram UML, antara lain *use case diagram*, *activity diagram*, *class diagram* dan *sequence diagram*

3.9.1. Use Case Diagram

Use case diagram adalah diagram yang digunakan untuk menggambarkan unit fungsionalitas yang tersedia pada sistem. Adapun *use case diagram* pada sistem di penelitian ini dapat dilihat pada Gambar 3.23 *Use Case Diagram*.



Gambar 3.23 Use Case Diagram

3.9.1.1. Definisi Aktor

Definisi aktor berfungsi untuk memberi penjelasan mengenai aktor yang terdapat pada *use case diagram*. Adapun aktor yang terdapat pada *use case diagram* dapat dilihat pada Tabel 3.90 Definisi Aktor.

Tabel 3.90 Definisi Aktor

No	Aktor	Definisi
1	Pengguna	Pengguna yang dapat melakukan proses eksplorasi dan proses eksploitasi.

3.9.1.2. Definisi Use Case

Definisi *use case* berfungsi untuk memberikan penjelasan mengenai fungsi dari *use case* yang terdapat pada *use case diagram*. Adapun definisi *use case* yang terdapat pada *use case diagram* yang digunakan dapat dilihat pada Tabel 3.91 Definisi Use Case.

Tabel 3.91 Definisi Use Case

No	Use Case	Definisi
1	Eksplorasi	Fungsionalitas yang digunakan oleh pengguna untuk melakukan proses eksplorasi.
2	Eksloitasi	Fungsionalitas yang digunakan oleh pengguna untuk melakukan proses eksloitasi.

3.9.1.3. Skenario Use Case

Skenario *use case* adalah skenario dari setiap bagian pada *use case* yang menunjukkan proses apa saja yang terjadi pada setiap bagian di dalam *use case* tersebut. Adapun tabel-tabel yang menunjukkan skenario dari *use case*, antara lain: Skenario dari *use case* Eksplorasi dapat dilihat pada Tabel 3.92 Skenario Eksplorasi.

Tabel 3.92 Skenario Eksplorasi

Use Case Name	Eksplorasi	
Related Requirement	<i>None</i>	
Goal	Melakukan Proses Eksplorasi	
Precondition	<i>None</i>	
Success End Condition	Berhasil Melakukan Proses Eksplorasi	
Failed End Condition	Gagal Melakukan Proses Eksplorasi	
Primary Actor	Pengguna	
Main Flow	Step	Action
	1	Pengguna melakukan pengaturan parameter algoritma dan menekan tombol Eksplorasi.
	2	Sistem menampilkan permainan <i>flappy bird</i> .

	3	Sistem mendapat <i>current state</i> dari permainan.
	4	Sistem melakukan Pemotongan <i>current state</i>
	5	Sistem melakukan <i>Grayscaleing current state</i>
	6	Sistem melakukan <i>Resize current state</i>
	7	Sistem melakukan <i>Thresholding current state</i>
	8	Sistem memilih <i>action</i>
	9	Sistem mengeksekusi <i>action</i> di permainan
	10	Sistem mendapat <i>reward, next state</i> dan <i>terminal</i> dari permainan
	11	Sistem melakukan Pemotongan <i>next state</i>
	12	Sistem melakukan <i>Grayscaleing next state</i>
	13	Sistem melakukan <i>Resize next state</i>
	14	Sistem melakukan <i>Thresholding next state</i>
	15	Sistem menyimpan <i>current state, action, reward, next state</i> dan <i>terminal</i> ke <i>reply memory</i>
	16	Sistem mengambil data latih secara acak dari <i>reply memory</i>
	17	Sistem Melatih model CNN dengan data latih yang telah diambil
Extention	Step	Branching Action
	2.1	Sistem menampilkan pesan kesalahan proses eksplorasi gagal dilakukan


Skenario dari *use case* eksplotasi dapat dilihat pada Tabel 3.93 Skenario Eksplotasi.

Tabel 3.93 Skenario Eksplotasi

Use Case Name	Eksplotasi	
Related Requirement	<i>None</i>	
Goal	Melakukan Proses Eksplotasi	
Precondition	<i>None</i>	
Success End Condition	Berhasil Melakukan Proses Eksplotasi	
Failed End Condition	Gagal Melakukan Proses Eksplorasi	
Primary Actor	Pengguna	
Main Flow	Step	Action
	1	Pengguna melakukan pengaturan parameter algoritma dan menekan tombol Eksplorasi.
	2	Sistem menampilkan permainan <i>flappy bird</i> .
	3	Sistem mendapat <i>current state</i> dari permainan.
	4	Sistem melakukan Pemotongan <i>current state</i>
	5	Sistem melakukan <i>Grayscaleing current state</i>
	6	Sistem melakukan <i>Resize current state</i>
	7	Sistem melakukan <i>Thresholding current state</i>
	8	Sistem memilih action dengan CNN
	9	Sistem mengeksekusi <i>action</i> di permainan
Extention	Step	Branching Action
	2.1	Pengguna gagal melakukan proses eksplorasi


3.9.2. Activity Diagram

Activity diagram adalah diagram yang menunjukkan *flow control* dari satu atau lebih objek dalam memproses suatu kegiatan. Berikut adalah *activity diagram* untuk setiap *use case* pada *use case diagram*. Adapun *activity diagram* dari *use case* eksplorasi dapat dilihat Gambar 3.24 *Activity Diagram Eksplorasi*.



Gambar 3.24 *Activity Diagram Eksplorasi*


Sedangkan *activity diagram* yang menunjukkan *use case* eksplorasi dapat dilihat pada Gambar 3.25 *Activity Diagram* Eksplorasi.



Gambar 3.25 Activity Diagram Eksplorasi

3.9.3. Class Diagram


Class diagram menunjukkan suatu hubungan antara satu entitas dengan entitas lainnya. Berikut adalah *class digaram* pada sistem di penelitian ini dapat dilihat pada Gambar 3.26 *Class Diagr.*



Gambar 3.26 *Class Diagram*


3.9.4. Sequence Diagram

Sequence diagram memberi aliran rinci antar objek untuk *use case* tertentu atau hanya bagian dari *use case* tertentu. *Sequence diagram* untuk *use case* eksplorasi dapat dilihat pada Gambar 3.27 *Sequence Diagram* Eksplorasi.



Gambar 3.27 *Sequence Diagram* Eksplorasi

Sedangkan untuk *Sequence diagram* yang menunjukkan *use case* eksplorasi dapat dilihat pada Gambar 3.28 *Sequence Diagram* Eksplorasi.




Gambar 3.28 Sequence Diagram Eksplorasi

3.10 Perancangan Sistem

Perancangan sistem memberikan gambaran mengenai sistem yang akan dibangun. Dalam perancangan sistem ini, terdiri dari struktur menu, perancangan antar muka dan jaringan

3.10.1. Struktur Menu

Perancangan Struktur menu adalah gambaran alur sistem yang akan dibangun, juga dapat berfungsi sebagai navigasi halaman yang ada dalam sistem. Perancangan struktur menu pada sistem yang akan dibangun dapat dilihat pada Gambar 3.29 Struktur Menu.



Gambar 3.29 Struktur Menu

3.10.2. Perancangan Antarmuka


Perancangan antarmuka menggambarkan rencana tampilan dari sistem yang akan dibangun. Rancangan antarmuka dari sistem yang akan dibangun untuk tampilan utama dapat dilihat pada Gambar 3.30 Tampilan Utama.

F01

PARAMETER ALGORITMA		LOG PERMAINAN
Learning Rate	<input type="text"/>	<input type="button" value="Refresh"/>
Discount Rate	<input type="text"/>	
Batch	<input type="text"/>	
Gamma	<input type="text"/>	
<input type="button" value="Eksplorasi"/>	<input type="button" value="Eksloitasi"/>	
<input type="button" value="STOP"/>		
<input type="button" value="cutting"/>	<input type="button" value="grey"/>	<input type="button" value="resize"/> <input type="button" value="thresholding"/>
Keterangan Nama Form : F01 Resolusi : 600 x 650 pixel Deskripsi : Tampilan Utama		

Gambar 3.30 Tampilan Utama

Sedangkan untuk tampilan antramuka permainan *flappy bird* dapat dilihat pada Gambar 3.31 Tampilan Permainan Flappy Bird.



Gambar 3.31 Tampilan Permainan Flappy Bird

3.10.3. Perancangan Pesan

Perancangan pesan merupakan pesan yang muncul guna memberi peringatan atau pemberitahuan kepada user. Pada sistem yang akan dibangun, perancangan


pesan digunakan untuk memvalidasi inputan nilai *learning rate* dan *batch*. Adapun perancangan pesan tersebut dapat dilihat pada Tabel 3.94 Perancangan Pesan.

Tabel 3.94 Perancangan Pesan

NO	Kode	Keterangan
1	P01	Nilai Learning Rate Tidak Boleh Kurang Dari 0
2	P02	Nilai Discount Rate Tidak Boleh Kurang Dari 0
3	P03	Nilai Discount Rate Tidak Boleh Lebih Dari 1
4	P04	Nilai Batch Tidak Boleh Kurang Dari 0
5	P05	Nilai Kondisi Henti Tidak Boleh Kurang Dari 0
6	P06	Nilai Kondisi Henti Tidak Boleh Lebih Dari 1000
7	P07	Kolom Inputan Tidak Boleh Kosong dan Harus Berupa Angka

3.10.4. Jaringan Semantik

Jaringan Semantik memeberikan gambaran mengenai keterhubungan dari satu antar muka ke antar muka lainnya. Jaringan semantik yang terbentuk dari sistem ini dapat dilihat pada Gambar 3.32 Jaringan Semantik.




Gambar 3.32 Jaringan Semantik

3.10.5. Perancangan Method

Perancangan method adalah kumpulan metode yang terdapat pada system yang akan dirancang. Berikut adalah perancangan method yang terdapat pada sistem:

1. Proses Eksplorasi


Adapun perancangan method eksplorasi, yaitu method onClickedExploration() dapat dilihat pada Gambar 3.33 Ui_MainWindow.onClickedExploration().



Gambar 3.33 Ui_MainWindow.onClickedExploration()

2. Proses Eksplorasi


Adapun perancangan method eksplorasi, yaitu onClickedExploitation() dapat dilihat pada Gambar 3.34 Ui_MainWindow.onClickedExploitation().



Gambar 3.34 Ui_MainWindow.onClickedExploitation()

3. Preprocessing


Adapun perancangan method *predefined* preprocessing dapat dilihat pada Gambar 3.35 *Predefined Preprocessing*.



Gambar 3.35 Predefined Preprocessing

4. Memilih action


Adapun perancangan method *predefined* memilih action, yaitu `getAction()` dapat dilihat pada Gambar 3.36 *Predefined agent.getAction()*.



Gambar 3.36 Predefined agent.getAction()

5. Melatih CNN

Adapun perancangan method *predefined* melatih model CNN, yaitu train() dapat dilihat pada Gambar 3.37 *Predefined networks.train()*.



Gambar 3.37 *Predefined networks.train()*

