

## BAB II

### TINJAUAN PUSTAKA DAN LANDASAN TEORI

#### 2.1 Tinjauan Pustaka

Peranan radiografi di dunia kedokteran sangat penting. Terbentuknya gambar pada film radiografi berawal dengan tahap pembangkitan (*developer*), yaitu perubahan butiran perak halida dalam lapisan emulsi film setelah diradiasi dengan sinar-x menjadi logam perak. Perubahan butiran perak halida tersebut ditampakan dengan warna hitam pada film. Tingkat kehitaman pada film bersesuaian dengan intensitas sinar-x yang diterima, sedangkan yang tidak memperoleh penyinaran tetap bening. Teknik pembuatan film radiografi dikelompokkan menjadi dua yaitu otomatis dan manual. Proses film manual adalah proses pencucian yang dilakukan manual oleh operator. Sedangkan otomatis proses pencucian film yang dilakukan otomatis oleh mesin (Afani, et al., 2018). Radiografi citra digital pada umumnya memperhatikan tiga aspek, yaitu resolusi spasial, *noise*, *signal ratio noise* (SRN) (Louk, et al., 2014).

*Computer vision* adalah salah satu bidang pembelajaran yang berpengaruh terhadap sistem kecerdasan buatan. *Computer vision* merupakan sebuah bidang pembelajaran yang telah mengalami perluasan. Mulai dari merekam data mentah ke ekstraksi pola gambar dan interpretasi informasi. Hal ini memiliki kombinasi konsep, teknik, dan ide dari pemrosesan gambar digital, pengenalan pola, kecerdasan buatan dan grafik komputer. *Computer Vision* memiliki fungsi dalam hal pengkombinasian dari pemrosesan gambar dan pengenalan pola. Pengembangan bidang ini diadaptasi dari proses penglihatan manusia dalam mengambil informasi. Tujuan utama dari pembentukan *Computer Vision* adalah membuat model dan ekstrak data serta informasi dari gambar (Wiley, et al., 2018).

Salah satu metode yang dapat di pakai dalam segmentasi deep learning adalah metode *Convolutional Neural Network* (CNN). CNN merupakan metode yang paling umum dilakukan dalam pengimplementasian deep learning. CNN sendiri adalah sebuah jaringan saraf tiruan, yang kerjanya seperti otak manusia.

CNN telah diterapkan pada berbagai pengklasifikasian gambar atau citra medis. kekuatan yang dimiliki CNN adalah sebuah pengekstraksian fitur tingkat yang berbeda dengan gambar atau citra (Ma'aitah, et al., 2018).

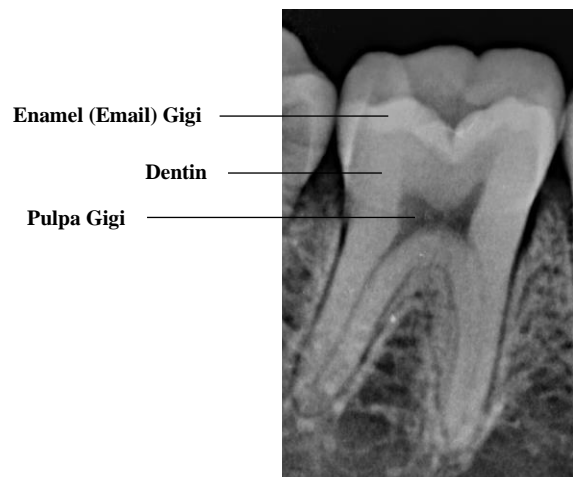
Selain itu ada metode lainnya seperti *Fully Convolutional Network* (FCN) yang memungkinkan jaringan untuk memiliki prediksi *pixel-wise*. Untuk mencapai kinerja pelokalan yang lebih baik, peta aktivasi resolusi tinggi digabungkan dengan keluaran sampel dan diteruskan ke lapisan konvolusi untuk mengumpulkan keluaran yang lebih akurat. Peningkatan ini memungkinkan FCN untuk memiliki prediksi *pixel-wise* dari gambar berukuran penuh pada prediksi *patch-wise* dan juga mampu melakukan prediksi untuk seluruh gambar hanya dalam satu *forward pass*. Metode *Convolutional Residual Networks* (CRNs) yang memperkenalkan *residual network* yang awalnya dikembangkan untuk segmentasi gambar alami pada gambar 2D. Dalam model ini, alih-alih secara berurutan memberi *feeding stack layers* dengan peta fitur, desain ini membantu jaringan untuk menikmati akurasi yang didapat dari desain yang lebih dalam. Metode *Recurrent Neural Networks* (RNNs) yang diberdayakan dengan koneksi berulang yang memungkinkan jaringan untuk menghafal bentuk pola terakhir input. Dan metode U-Net yang salah satu struktur paling terkenal untuk citra medis segmentasi (Hesamian, et al., 2019).

U-net adalah solusi pembelajaran dalam generik untuk tugas-tugas kuantifikasi yang sering terjadi seperti pendeteksian selaput dan perincian penataan dalam pengaturan gambar. Plugin ini dilengkapi dengan model pra=terlatih untuk segmentasi sel tunggal dan memungkinkan adaptasi U-net untuk tugas-tugas berdasarkan beberapa sampel yang dianotasikan. U-net berlaku untuk tugas kalsifikasi piksel umum dalam gambar datar atau tumpukan gambar volumetrik dengan satu atau beberapa saluran. Tugas tersebut meliputi deteksi dan penghitungan sel. Prediksi titik referensi tunggal per sel dan segmentasi. U-net dioptimalkan untuk kegunaan dalam ilmu kehidupan. Integrasi perangkat lunak dalam imageJ dan tutorial langkah demi langkah membuat *deep learning* tersedia bagi para ilmuwan tanpa latar belakang komputer (Falk, et al., 2019).

## 2.2 Landasan Teori

### 2.2.1 Bagian gigi

Gigi membantu dalam mengunyah makanan agar dapat mudah dicerna. Gigi memiliki bentuk yang mempunyai perbedaan sedikit. Gigi memiliki beberapa bagian jaringan yang mempunyai fungsi yang berbeda. Gambar 2.2 adalah contoh bagian gigi.



Gambar 2. 1 Bagian-bagian gigi

#### a. Enamel (email) Gigi

Enamel adalah satu bagian gigi luar yang peling keras dan berwarna putih. Enamel ini yang melindungi jaringan vital dalam gigi. Unsur yang terdapat pada enamel gigi sebagian besar terdiri dari kalsium dan fosfat. Jika email ini rusak maka tidak dapat digantikan atau dibentuk kembali.

#### b. Pulpa Gigi

Pulpa adalah salah satu dari bagian gigi yang mendasar. Pulpa gigi merupakan bagian yang dapat menunjukkan tekanan cairan jaringan interstitial normal yang relatif tinggi. Hal ini berarti ada tekanan gradien di tubulus dentinal dalam kondisi normal (Mjör, 2009). Pulpa merupakan sebuah penyakit yang terjadi pada bagian gigi. Penyakit pada pulpa ini terjadi karena karies gigi atau gigi berlubang. Apabila kerusakan gigi berlubang tidak segera dilakukan perawatan maka akan berlanjut pada email, dinti hingga ke pulpa. Namun, selain gigi

berlubang ada hal lain yang menjadi penyebab terjadinya kelainan pada bagian pulpa gigi. Hal tersebut adalah trauma, panas, dan bahan kimia (Larasati, et al., 2014).

### **c. Dentin**

Dentin adalah salah satu bagian gigi yang sangat rentan mengalami kerusakan. Dentin berada di bawah enamel gigi, enamel gigi merupakan bagian gigi yang awal atau berada di mahkota gigi. Dentin sendiri merupakan permasalahan yang sering terjadi pada seseorang. Permasalahan pada dentin biasanya ditandai dengan rasa nyeri yang berlebihan. Dentin yang mengalami kerusakan akan rentan terhadap rangsangan yang masuk pada bagian tersebut (Garoushi, et al., 2015).

## **2.2.2 Deep learning**

*Deep learning* memungkinkan model komputasi yang terdiri dari beberapa *layer* pemrosesan untuk mempelajari representasi data dengan berbagai tingkat abstraksi. Metode-metode ini telah secara dramatis meningkatkan *state-of-the-art* dalam pengenalan suara, pengenalan objek visual, deteksi objek dan banyak domain lain seperti penemuan obat dan genomik. *Deep learning* menemukan struktur rumit dalam kumpulan data besar dengan menggunakan algoritma *backpropagation* untuk menunjukkan bagaimana mesin harus mengubah parameter internal yang digunakan untuk menghitung representasi di setiap layer dari representasi di *layer* sebelumnya. (LeCun, et al., 2015)

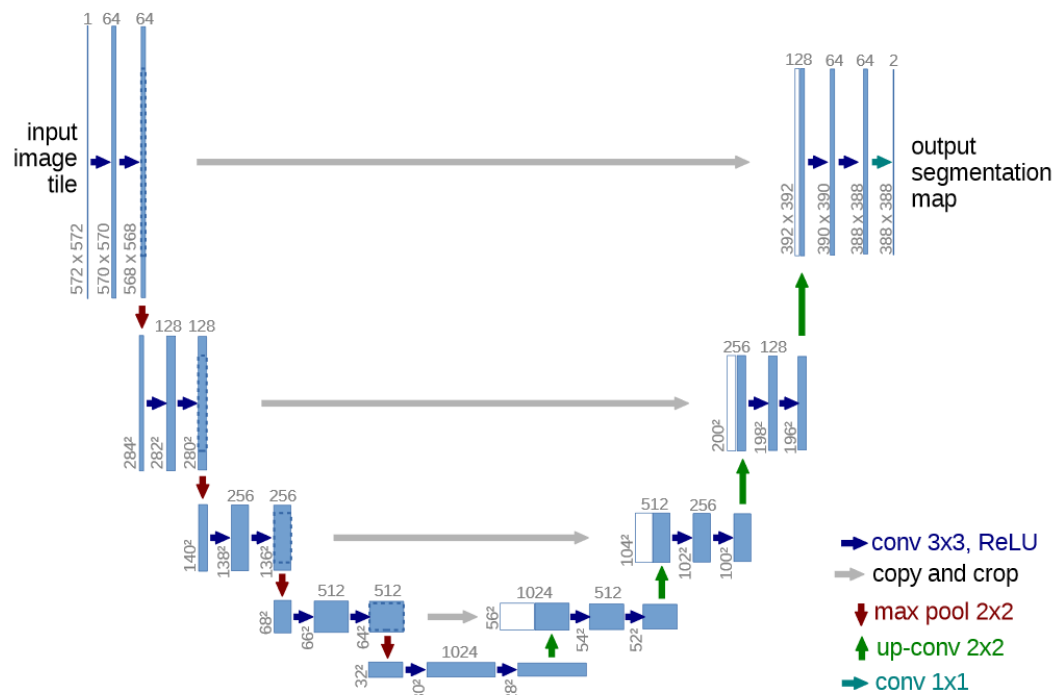
*Deep learning* mengacu pada *class* yang cukup luas dari teknik dan arsitektur mesin *learning*, dengan ciri menggunakan banyak *layer* pemrosesan informasi non-linier yang bersifat *hierarki*. Tergantung pada bagaimana arsitektur dan teknik dimaksudkan untuk digunakan misalnya sintesis, *generation* atau *recognition*, klasifikasi. (Yu, et al., 2013)

## **2.2.3 AI (Artificial Intelligence)**

Secara khusus, ada empat utama dalam model AI yang dapat dijelaskan: (1) mengapa – pertanyaan itu kontras; (2) penjelasan dipilih (dengan cara yang bias);

(3) penjelasan bersifat sosial; dan (4) probabilitas tidak penting hubungan sebab akibat. AI bekerja erat dengan peneliti dari filsafat, psikologi, ilmu kognitif, dan interaksi manusia-komputer (Miller, et al., 2018).

## 2.2.4 U-Net



Gambar 2. 2 Arsitektur U-net (Ronneberger, et al., 2015)

Arsitektur u-net di bagian upsampling memiliki sejumlah angka besar dari fitur channels yang memungkinkan jaringan untuk menyebarkan informasi konteks ke resolusi *layer* yang lebih tinggi. Bagian jalur ekspansif yang lebih atau kurang simetris dengan jalur *contract* dan menghasilkan jalur berbentuk u. Jaringan tidak memiliki lapisan yang terhubung sepenuhnya dan hanya menggunakan bagian yang valid dari setiap konvolusi yaitu peta segmentasi hanya berisi piksel, yang konteks lengkapnya tersedia di gambar input. Strategi ini memungkinkan segmentasi tanpa batas dari gambar besar yang berubah-ubah oleh strategi anoverlap-tile. Untuk memprediksi piksel di wilayah border gambar, konteks yang hilang diekstrapolasi dengan mencerminkan gambar input. Strategi ubin ini penting untuk menerapkan jaringan ke gambar besar, karena jika resolusi tidak dibatasi akan dibatasi oleh

memori GPU. Arsitektur u-net (contoh untuk 32 x 32 piksel dalam resolusi terendah). Setiap kotak biru sesuai dengan peta fitur multi-saluran. Jumlah saluran dilambangkan diatas kotak. Ukuran x-y disediakan di tepi kiri bawah. Kotak putih mewakili peta fitur yang disalin. Tanda panah menunjukkan perasi yang berbeda (Ronneberger, et al., 2015).

U-net adalah solusi pembelajaran dalam generik untuk tugas-tugas kuantifikasi yang sering terjadi seperti pendeteksian selaput dan perincian penataan dalam pengaturan gambar. Plugin ini dilengkapi dengan model pra=terlatih untuk segmentasi sel tunggal dan memungkinkan adaptasi U-net untuk tugas-tugas berdasarkan beberapa sampel yang dianotasikan. U-net berlaku untuk tugas kalsifikasi piksel umum dalam gambar datar atau tumpukan gambar volumetrik dengan satu atau beberapa saluran. Tugas tersebut meliputi deteksi dan penghitungan sel. Prediksi titik referensi tunggal per sel dan segmentasi. U-net dioptimalkan untuk kegunaan dalam ilmu kehidupan. Integrasi perangkat lunak dalam imageJ dan tutorial langkah demi langkah membuat *deep learning* tersedia bagi para ilmuwan tanpa latar belakang komputer (Falk, et al., 2019).

Segmentasi citra menggunakan metode U-net memiliki kemampuan yang bagus dibandingkan arsitektur lainnya. U-net dapat melakukan segmentasi lebih akurat. Metode segmentasi U-Net merupakan proses segmentasi yang belum banyak digunakan. Oleh karena itu, U-Net merupakan jenis arsitektur yang masih tergolong baru dalam dunia *deep learning* (Kolar'ík, et al., 2019).