

**KLASIFIKASI PENYAKIT TUBERKULOSIS BERDASARKAN CITRA
X-RAY MENGGUNAKAN METODE *ELMAN RECURRENT NEURAL
NETWORK***

SKRIPSI



**UIN SUNAN AMPEL
S U R A B A Y A**

Disusun Oleh
LAILY JUMHURIYAH
H72217052

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL
SURABAYA**

2021

PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : LAILY JUMHURIYAH

NIM : H72217052

Program Studi : Matematika

Angkatan : 2017

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul " KLASIFIKASI PENYAKIT TUBERKULOSIS BERDASARKAN CITRA X-RAY MENGGUNAKAN METODE *ELMAN RECURRENT NEURAL NETWORK* ". Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 24 Januari 2021

Yang menyatakan,


LAILY JUMHURIYAH
NIM. H72217052

LEMBAR PERSETUJUAN PEMBIMBING

Skripsi oleh

Nama : LAILY JUMHURIYAH

NIM : H72217052

Judul Skripsi : KLASIFIKASI PENYAKIT TUBERKULOSIS
BERDASARKAN CITRA X-RAY MENGGUNAKAN
METODE *ELMAN RECURRENT NEURAL NETWORK*

telah diperiksa dan disetujui untuk diujikan.

Surabaya, 24 Januari 2021

Pembimbing I



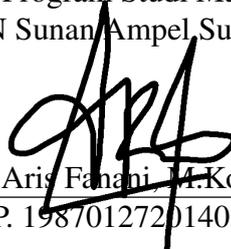
Dian Candra Rini Novitasari, M.Kom
NIP. 198511242014032001

Pembimbing II



Lutfi Hakim, M.Ag
NIP. 197312252006041001

Mengetahui,
Ketua Program Studi Matematika
UIN Sunan Ampel Surabaya



Aris Fahani, M.Kom
NIP. 198701272014031002

PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

Nama : LAILY JUMHURIYAH
NIM : H72217052
Judul Skripsi : **KLASIFIKASI PENYAKIT TUBERKULOSIS
BERDASARKAN CITRA X-RAY MENGGUNAKAN
METODE *ELMAN RECURRENT NEURAL NETWORK***

Telah dipertahankan di depan Tim Penguji
pada tanggal 27 Januari 2021

Mengesahkan,
Tim Penguji

Penguji I



Aris Fanani, M.Kom
NIP. 198701272014031002

Penguji II



Patroue Kuemala Intan, M.Si
NIP. 198805282018012001

Penguji III



Dian C. Rini Novitasari, M.Kom
NIP. 198511242014032001

Penguji IV



Lutfi Hakim, M.Ag
NIP. 197312252006041001

Mengetahui,
Dekan Fakultas Sains dan Teknologi
Sunan Ampel Surabaya



D. H. Fatmatur Rusydiyah, M.Ag
NIP. 197312272005012003



KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
PERPUSTAKAAN

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300
E-Mail: perpus@uinsby.ac.id

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : LAILY JUMHURIYAH
NIM : H72217052
Fakultas/Jurusan : SAINTEK / MATEMATIKA
E-mail address : LAILYJUMHURIYAH@EMAIL.COM

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

Sekripsi Tesis Desertasi Lain-lain (.....)
yang berjudul :

KLASIFIKASI PENYAKIT TUBERKULOSIS BERDASARKAN CITRA X-RAY
MENGGUNAKAN METODE ELMAN RECURRENT NEURAL NETWORK

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya,

Penulis

(LAILY JUMHURIYAH)
nama terang dan tanda tangan

2.6.2.	<i>Long Runs Emphasis (LRE)</i>	23
2.6.3.	<i>Gray Level Non-uniformity (GLN)</i>	23
2.6.4.	<i>Run Length Non-uniformity (RLN)</i>	23
2.6.5.	<i>Run Percentage (RP)</i>	23
2.6.6.	<i>Low Gray Level Run Emphasis (LGRE)</i>	24
2.6.7.	<i>High Gray Level Run Emphasis (HGRE)</i>	24
2.6.8.	<i>Short Run Low Gray Level Emphasis (SRLGE)</i>	24
2.6.9.	<i>Short Run High Gray Level Emphasis (SRHGE)</i>	25
2.6.10.	<i>Long Run Low Gray Level Emphasis (LRLGE)</i>	25
2.6.11.	<i>Long Run High Gray Level Emphasis (LRHGE)</i>	25
2.7.	Jaringan Saraf Tiruan (JST)	26
2.8.	<i>Elman Recurrent Neural Network</i>	30
2.9.	Evaluasi	36
2.10.	Penyakit dalam Perspektif Islam	37
2.10.1.	Allah Menciptakan Penyakit untuk Manusia	37
2.10.2.	Macam-macam Penyakit	38
2.10.3.	Kewajiban Orang yang Sakit	40
2.10.4.	Balasan Bagi Orang yang Sabar dalam Menghadapi Musibah	42
III	METODE PENELITIAN	44
3.1.	Jenis Penelitian	44
3.2.	Jenis dan Sumber Data	44
3.3.	Rancangan Penelitian	45
IV	HASIL DAN PEMBAHASAN	48
4.1.	<i>Preprocessing</i> Citra	48
4.2.	Ekstraksi Fitur	51
4.3.	Klasifikasi	59
4.3.1.	<i>Training</i>	59
4.3.2.	<i>Testing</i>	76
4.4.	Integrasi Keislaman	83
V	PENUTUP	85

disebabkan oleh *mycobacterium tuberculosis* yang dapat menular melalui udara (Amrin et al., 2019). Hal ini dapat menular karena penderita tuberkulosis sedang batuk dan mengeluarkan percikan dahak atau *droplet* yang dapat menyebarkan bakteri (Siregar et al., 2018). Penyakit tuberkulosis banyak dialami oleh masyarakat, terdapat 10 juta kasus tuberkulosis dan 1.5 juta mengalami kematian pada setiap tahunnya (WHO, 2020). Berdasarkan data World Health Organization (WHO) tahun 2019, Indonesia berada pada urutan ketiga sebagai negara dengan total kasus penderita tuberkulosis terbanyak yaitu 842.000 atau 46% dari total kasus yang ada (Nurdiansyah et al., 2020).

Deteksi tuberkulosis dapat dilakukan dengan *rontgen* dada berupa *chest x-ray* (Santony et al., 2015). *Chest x-ray* sangat membantu dalam melakukan diagnosis karena rendah biaya, rendah dosis, dan dapat melakukan deteksi secara akurat (Rahman et al., 2020). Pemeriksaan *chest x-ray* dilakukan dengan melihat gambar permukaan dalam dada yang digunakan sebagai bahan pertimbangan oleh para ahli apakah seorang pasien terdeteksi penyakit tuberkulosis atau tidak. Namun, pemeriksaan tersebut sangat rentan mengalami kesalahan dan terjadinya *human error* (Hamid, 2019).

Kasus *human error* telah terjadi di Rumah Sakit Padang, dimana pada rumah sakit tersebut hanya memiliki 1 ahli radiologi dalam melakukan diagnosis dan deteksi. Sementara itu setiap harinya selalu ada pasien yang mengambil hasil diagnosis dan rumah sakit hanya beroperasi pada jam kerja, sehingga mengakibatkan ahli radiologi bekerja lembur dan membawa pekerjaannya pulang. Hal ini mengakibatkan pekerjaan ahli radiologi tidak maksimal sehingga terjadinya *human error* (Hesti, 2020). Untuk memperkecil terjadinya *human error* pada daerah lain maka dibutuhkannya suatu sistem yaitu *Computer Aided Diagnosis*

(CAD) *system* yang dapat digunakan untuk mendeteksi penyakit dengan hasil yang lebih akurat (Xie et al., 2020). Dalam deteksi tuberkulosis dengan CAD *system* dibutuhkan beberapa tahap yaitu *preprocessing*, ekstraksi fitur, dan klasifikasi.

Preprocessing dilakukan untuk memperbaiki kualitas pada citra. Citra *x-ray* terkadang masih terdapat *noise* atau gangguan pada gambar yang akan mempengaruhi kualitas suatu citra. Untuk memperbaiki kualitas citra dapat dilakukan dengan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) dan *median filter* (Matondang, 2017). Metode CLAHE merupakan metode untuk meningkatkan perbedaan kontras citra berdasarkan area ketetanggaan piksel, sehingga dapat mengatasi *noise* yang berlebihan (Li et al., 2020; Haleot et al., 2020). *Median filter* merupakan salah satu *filtering* yang dapat memberikan hasil lebih baik apabila dibandingkan dengan *mean filter*, hal ini disebabkan karena *median filter* tidak mengganti nilai piksel dengan rata-rata tetanggaanya tetapi mengurutkan semua nilai piksel dan mengambil nilai tengahnya (Umamaheswari and Geetha, 2020). Sehingga *median filter* menjadi metode *filter* yang paling luas karena mempertahankan tepinya (Leavline and Antony, 2013). Citra yang memiliki kualitas yang baik akan dilakukan ekstraksi fitur. Ekstraksi fitur bertujuan untuk mendapatkan informasi yang terdapat didalam citra (Naufal, 2017).

Metode ekstraksi fitur pada pengenalan pola terdapat beberapa macam, yaitu transformasi wavelet, deteksi tepi, dan metode statistik (Reja and Santoso, 2013). Metode ekstraksi fitur statistik yang sering digunakan yaitu *Gray Level Co-occurrence Matrix* (GLCM) dan *Gray Level Run Length Matrix* (GLRLM) (Nagarajan et al., 2019). GLCM adalah metode ekstraksi fitur orde dua yang terkenal dengan memanfaatkan matriks *co-occurrence* (Faustina, 2019). Kemudian

muncul metode ekstraksi fitur yang lebih baik yaitu GLRLM yang dapat membedakan citra halus dan citra kasar dengan memanfaatkan matriks *run length* (Purwandari et al., 2018). Dalam penelitian yang dilakukan oleh (Xu et al., 2019) tentang klasifikasi penyakit liver menggunakan SVM berdasarkan ekstraksi fitur GLCM dan GLRLM menunjukkan bahwa metode GLRLM memiliki performa lebih tinggi dari GLCM yaitu sebesar 87.125% . Setelah dilakukannya ekstraksi fitur, pada CAD system biasanya diikuti dengan klasifikasi. Baru-baru ini klasifikasi dapat diselesaikan dengan *Artificial Intelligence* (AI) atau kecerdasan buatan (Xie et al., 2020).

Jaringan saraf tiruan adalah salah satu penemuan terbesar pada AI yang memiliki kelebihan yaitu toleransi yang tinggi terhadap data *outlier*, mampu mengenali pola, dan hasil yang didapatkan akurat (Wibawa et al., 2018). Terdapat banyak peneliti yang melakukan klasifikasi penyakit tuberkulosis. Seperti yang dilakukan oleh (Depinta and Abdullah, 2017), telah mengimplementasikan jaringan saraf tiruan *backpropagation* pada deteksi tuberkulosis berdasarkan *ronteg* dada. Pengenalan pola yang dilakukan jaringan saraf tiruan berupa pola sebaran warna hitam dan putih. Dengan melakukan deteksi tubekulosis menggunakan *backpropagation* diperoleh akurasi sebesar 79.41%. Selain itu dalam jaringan saraf tiruan banyak metode yang digunakan untuk klasifikasi, seperti metode *Elman Recurrent Neural Network* (RNN). Seperti (Abdullah et al., 2019) melakukan pengenalan wajah pada siswa menggunakan *Elman* RNN. Dari penelitiannya *Elman* RNN dapat mengenali pola wajah siswa dengan baik sehingga akurasi yang diperoleh sebesar 94%. Kemudian (Nurtiyasari, 2014) menggunakan *Elman* RNN, dalam penelitiannya *Elman* RNN mampu melakukan klasifikasi dengan menghasilkan akurasi yang baik antara 87.5% hingga 99.47%. Selain itu (Permana

and Prijodiprodo, 2014) menerapkan *Elman* RNN untuk mengevaluasi kelayakan mahasiswa magang ke luar negeri, dalam penelitiannya tersebut memberikan informasi yang akurat dalam menentukan keputusan. Jaringan *Elman* RNN memiliki perbedaan dengan jaringan *Backpropagation* yaitu *Elman* RNN memiliki *feedback* yang dapat melakukan proses iterasi lebih cepat, sehingga kecepatan pada *update* parameternya menjadi lebih cepat. Selain itu *Elman* RNN juga bisa digunakan dalam prediksi yang dapat menghasilkan hasil yang akurat dan efisien (Rifaldi, 2019).

Berdasarkan pemaparan dari permasalahan diatas, GLRLM memberikan hasil yang baik dalam melakukan ekstraksi fitur dan *Elman* RNN menghasilkan akurasi yang tinggi, maka penelitian ini akan menerapkan *Gray Level Run Length Matrix* (GLRLM) dan *Elman* RNN untuk klasifikasi citra *x-ray* tuberkulosis dengan judul Klasifikasi Penyakit Tuberkulosis berdasarkan Citra *X-ray* Menggunakan *Elman Recurrent Neural Network*. Dengan adanya penelitian ini diharapkan dapat membentuk sistem klasifikasi untuk mendeteksi adanya penyakit tuberkulosis.

1.2. Rumusan Masalah

Berdasarkan paparan dari latar belakang, dapat diambil beberapa permasalahan yang dapat dikaji, antara lain:

1. Bagaimana hasil ekstraksi fitur tekstur pada citra *x-ray* tuberkulosis dengan menggunakan GLRLM?
2. Bagaimana arsitektur jaringan yang optimal dari hasil klasifikasi citra *x-ray* tuberkulosis menggunakan *Elman* RNN?

2.7. Jaringan Saraf Tiruan (JST)

Jaringan Saraf Tiruan (JST) atau *Artificial Neural Network* (ANN) merupakan salah satu metode pemroses informasi, dimana cara kerjanya menyerupai kerja jaringan saraf pada manusia yang terdiri atas sel-sel yang disebut *neuron*. Didalam *neuron* terdapat tiga komponen utama dimana fungsinya dapat dianalogikan dengan *neural network* yaitu *dendrit*, *soma*, dan *akson*. Pada JST istilah *neuron* sering disebut dengan unit atau *node*. Setiap *node* akan berhubungan dengan *node-node* lainnya melalui suatu *layer* dengan bobot tertentu. Bobot ini akan menyampaikan informasi-informasi yang dapat menyelesaikan permasalahan, dalam jaringan manusia proses ini terjadi pada *synaptic gap* terdapat pada proses kimia. Apabila suatu *node* berada pada sebuah *layer* yang sama dengan *node* lainnya biasanya memiliki sifat yang serupa. Pada setiap *node* memiliki fungsi aktivasi yang diterima dari *input* (Sudarsono, 2016).

JST merupakan suatu pemahaman model matematika yang dikembangkan untuk mendapatkan informasi yang sesuai dengan keinginan (Andriyani and Sitohang, 2018). Adapun bagian-bagian dari JST antara lain:

1. Komponen Jaringan Saraf Tiruan

JST awalnya hanya memiliki dua lapisan yaitu *input* dan *output layer*. Seiring berkembangnya waktu dan teknologi kini jaringan saraf tiruan ada tambahan 1 lapisan yaitu *hidden layer* yang terletak diantara *input layer* dan *output layer*. Berikut adalah penjelasan disetiap lapisannya (Lesnussa et al., 2015):

a *Input Layer*

Lapisan ini terdiri dari unit-unit masukan. *Input layer* menerima pola data untuk menggambarkan suatu permasalahan.

$$\begin{aligned}
LRE_0 &= \frac{1}{n_0} \sum_{i=0}^m \sum_{j=0}^n p(i;j) j^2 \\
&= \frac{1}{55757} \left[(2 \times 1^2) + (3 \times 2^2) + (0 \times 3^2) + \dots + (0 \times 244) + \right. \\
&\quad \left. (2 \times 1^2) + (5 \times 2^2) + (2 \times 3^2) + \dots + (0 \times 244) + \dots + \left((67 \times 1^2) + (32 \times 2^2) + \right. \right. \\
&\quad \left. \left. (8 \times 3^2) + \dots + (0 \times 244) \right) \right] \\
&= 2:3958 \\
GLN_0 &= \frac{1}{n_0} \sum_{i=0}^m \left(\sum_{j=0}^n p(i;j) \right)^2 \\
&= \frac{1}{55757} \left[(2 + 3 + 0 + \dots + 0)^2 + (2 + 5 + 2 + \dots + 0)^2 + \dots + (26 + 4 + 0 + \right. \\
&\quad \left. \dots + 0)^2 + (67 + 32 + 8 + \dots + 0 + 0 + 0)^2 \right] \\
&= 2852572 \\
RLN_0 &= \frac{1}{n_0} \sum_{j=0}^n \left(\sum_{i=0}^m p(i;j) \right) \\
&= \frac{1}{55757} \left[(\dots + 2 + 2 + 4 + \dots + 26 + 67 + \dots)^2 + (\dots + 2 + 3 + 9 + \dots + 4 + 32 + \dots)^2 \right. \\
&\quad \left. + \dots + (\dots + 0 + 0 + 0 + \dots + 0 + 0 + 0 + \dots)^2 \right] \\
&= 3:5780 + 04 \\
RP_0 &= \frac{n_0}{\sum_{i=0}^m \left(\sum_{j=0}^n p(i;j) \times j^2 \right)} \\
&= \frac{55757}{\left[\begin{aligned} &(2 \times 1) + (3 \times 2) + (0 \times 3) + \dots + (0 \times 256) + \\ &\dots + \left((67 \times 1) + (32 \times 2) + (8 \times 3) + \dots + (0 \times 256) \right) \end{aligned} \right]} \\
&= 0:7882 \\
LGRE_0 &= \frac{1}{n_0} \sum_{i=0}^m \left(\sum_{j=0}^n \frac{p(i;j)}{i^2} \right) \\
&= \frac{1}{55757} \left[\left(\frac{2}{11^2} + \frac{3}{11^2} + \frac{0}{11^2} + \dots + \frac{0}{256} \right) + \right. \\
&\quad \left. \left(\frac{2}{11^2} + \frac{5}{11^2} + \frac{2}{11^2} + \dots + \frac{0}{256} \right) + \left(\frac{67}{11^2} + \frac{32}{11^2} + \frac{8}{11^2} + \dots + \frac{0}{256} \right) \right] \\
&= 3:32238 - 04
\end{aligned}$$

$$\begin{aligned}
\text{HGRE}_0 &= \frac{1}{n_0} \sum_{i=0}^m \sum_{j=0}^n p(i;j) i^2 \\
&= \frac{1}{5575} \left[\left((\dots + (2 \times 11^2) + (3 \times 12^2) + (0 \times 13^2) + \dots + (0 \times 256)) \right) + \right. \\
&\quad \left((\dots + (2 \times 11^2) + (5 \times 12^2) + (2 \times 13^2) + \dots + (0 \times 256)) \right) + \dots \\
&\quad \left. + \left((\dots + (67 \times 11^2) + (32 \times 12^2) + (8 \times 13^2) + \dots + (0 \times 256)) \right) \right] \\
&= 1:451\bar{e}+04 \\
\text{SRLGE}_0 &= \frac{1}{n_0} \sum_{i=0}^m \sum_{j=0}^n \frac{p(i;j)}{i^2 j^2} \\
&= \frac{1}{5575} \left[\left(\dots + \frac{2}{11^2 \times 12^2} + \frac{3}{11^2 \times 2^2} + \frac{0}{11^2 \times 3^2} + \dots + \frac{0}{11^2 \times 256} \right) + \right. \\
&\quad \left(\dots + \frac{2}{11^2 \times 12^2} + \frac{5}{11^2 \times 2^2} + \frac{2}{11^2 \times 3^2} + \dots + \frac{0}{11^2 \times 256} \right) + \\
&\quad \dots + \left(\dots + \frac{67}{11^2 \times 12^2} + \frac{32}{11^2 \times 2^2} + \frac{8}{11^2 \times 3^2} + \dots + \frac{0}{11^2 \times 244} \right) \right] \\
&= 2:846\bar{e}-04 \\
\text{SRHGE}_0 &= \frac{1}{n_0} \sum_{i=0}^m \sum_{j=0}^n \frac{p(i;j) i^2}{j^2} \\
&= \frac{1}{5575} \left[\left(\frac{2 \times 11^2}{1^2} + \frac{3 \times 11^2}{2^2} + \frac{0 \times 11^2}{3^2} + \dots + \frac{0 \times 11^2}{256} \right) \right. \\
&\quad + \left(\frac{2 \times 12^2}{1^2} + \frac{5 \times 12^2}{2^2} + \frac{2 \times 12^2}{3^2} + \dots + \frac{0 \times 12^2}{256} \right) + \dots \\
&\quad \left. + \left(\frac{67 \times 246}{1^2} + \frac{32 \times 246}{2^2} + \frac{8 \times 246}{3^2} + \dots + \frac{0 \times 246}{256} \right) \right] \\
&= 1:229\bar{e}+04 \\
\text{LRLGE}_0 &= \frac{1}{n_0} \sum_{i=0}^m \sum_{j=0}^n \frac{p(i;j) j^2}{i^2} \\
&= \frac{1}{5575} \left[\left(\frac{2 \times 1^2}{11^2} + \frac{3 \times 2^2}{11^2} + \frac{0 \times 3^2}{11^2} + \dots + \frac{0 \times 256}{11^2} \right) + \right. \\
&\quad \left(\frac{2 \times 1^2}{12^2} + \frac{5 \times 2^2}{12^2} + \frac{2 \times 3^2}{12^2} + \dots + \frac{0 \times 256}{12^2} \right) + \dots + \\
&\quad \left. \left(\frac{67 \times 1^2}{246} + \frac{3 \times 2^2}{246} + \frac{8 \times 3^2}{246} + \dots + \frac{0 \times 256}{246} \right) \right] \\
&= 6:273\bar{e}-04
\end{aligned}$$

Tabel 4.3 Hasil Ekstraksi Fitur Tuberkulosis pada Sudut Orientasi 90

Fitur	Citra ke-					
	1	2	3	4	5	6
SRE	0.8201	0.8103	0.8208	0.8198	0.8433	0.8509
LRE	3.0023	2.8040	2.2726	3.0524	2.2979	2.2587
GLN	267.3941	233.3999	238.7066	209.8261	231.5257	227.9809
RLN	3.0430e+04	2.9093e+04	3.1103e+04	2.9691e+04	3.3751e+04	3.4860e+04
RP	0.7447	0.7261	0.7556	0.7224	0.7729	0.7829
LGRE	3.2909e-04	3.4341e-04	3.3189e-04	3.3136e-04	3.1171e-04	3.1177e-04
HGRE	1.4727e+04	1.6877e+04	1.7638e+04	2.2957e+04	2.4060e+04	2.2484e+04
SRLGE	2.7082e-04	2.8705e-04	2.6997e-04	2.5003e-04	2.4992e-04	2.4922e-04
SRHGE	1.2019e+04	1.3373e+04	1.4333e+04	1.8945e+04	2.0042e+04	1.8977e+04
LRLGE	7.9718e-04	7.2445e-04	8.2819e-04	0.0019	0.0011	0.0010
LRHGE	8.1725e+04	7.0401e+04	4.0661e+04	5.1735e+04	5.1289e+04	4.4809e+04
Kelas	Normal	Normal	Normal	TB	TB	TB

Tabel 4.3 adalah hasil ekstraksi fitur dengan sudut orientasi 90°. Berdasarkan tabel tersebut tekstur citra TB ke 5 dan 6 memiliki nilai SRE lebih tinggi apabila dibandingkan dengan citra yang lain sehingga dapat diketahui bahwa citra TB ke 5 dan 6 memiliki tekstur yang lebih halus dari citra lainnya. Disamping itu bila melihat nilai dari fitur LRE, citra akan bertekstur kasar apabila memiliki nilai LRE tinggi. Nilai LRE berbanding lurus dengan nilai *run*, sehingga nilai *run* lebih panjang daripada citra bertekstur halus. Berdasarkan tabel diatas dapat diketahui bahwa nilai citra ke 4 memiliki LRE lebih tinggi bila dibandingkan dengan lainnya. Sehingga pada sudut ini citra ke 4 memiliki tekstur yang sangat kasar.

Tabel 4.4 Hasil Ekstraksi Fitur Tuberkulosis pada Sudut Orientasi 135

Fitur	Citra ke-					
	1	2	3	4	5	6
SRE	0.8975	0.8899	0.9042	0.8849	0.9106	0.9099
LRE	1.7021	1.8215	1.5174	1.7833	1.5266	1.5675
GLN	303.6765	267.8362	272.7699	239.0476	257.9833	250.3469
RLN	4.2719e+04	4.1309e+04	4.4398e+04	4.0569e+04	4.5394e+04	4.5125e+04
RP	0.8508	0.8389	0.8698	0.8343	0.8743	0.8702
LGRE	3.2913e-04	3.3122e-04	3.3661e-04	3.5984e-04	3.3784e-04	3.4126e-04
HGRE	1.4949e+04	1.7178e+04	1.7661e+04	2.2519e+04	2.4251e+04	2.2600e+04
SRLGE	2.9533e-04	2.9821e-04	3.0140e-04	2.9431e-04	3.0164e-04	3.0640e-04
SRHGE	1.3227e+04	1.4950e+04	1.5854e+04	2.0221e+04	2.2085e+04	2.0638e+04
LRLGE	5.1167e-04	5.1015e-04	5.2716e-04	8.4959e-04	5.8674e-04	5.9312e-04
LRHGE	3.4447e+04	4.4063e+04	2.7304e+04	3.5064e+04	3.5054e+04	3.2658
Kelas	Normal	Normal	Normal	TB	TB	TB

Tabel 4.4 adalah hasil ekstraksi fitur dengan sudut orientasi 90°. Berdasarkan tabel tersebut tekstur citra TB ke 5 memiliki nilai SRE lebih tinggi apabila dibandingkan dengan citra yang lain sehingga citra TB ke 5 memiliki tekstur yang lebih halus dari citra lainnya. Disamping itu bila melihat nilai dari fitur LRE, citra akan bertekstur kasar apabila memiliki nilai LRE tinggi. Nilai LRE berbanding lurus dengan nilai *run*, sehingga nilai *run* lebih panjang daripada citra bertekstur halus. Berdasarkan tabel diatas dapat diketahui bahwa nilai citra ke 2 memiliki LRE lebih tinggi bila dibandingkan dengan lainnya. Hal ini menunjukkan bahwa citra ke 2 memiliki tekstur yang lebih kasar.

4.3. Klasifikasi

Klasifikasi penyakit tuberkulosis pada penelitian ini menggunakan metode *Elman* RNN. Pada klasifikasi ini terdapat dua proses yaitu proses *training* dan proses *testing*. Proses *training* dilakukan untuk membangun model terbaik pada sistem klasifikasi, sedangkan proses *testing* dilakukan untuk menguji keakuratan model yang telah dibentuk. Data yang digunakan pada proses *training* sejumlah 463 dan data yang digunakan pada proses *testing* sejumlah 199. Penelitian ini menggunakan parameter yang telah diperoleh dari proses ekstraksi fitur menggunakan GLRLM yaitu sebanyak 11 fitur yang meliputi SRE, LRE, GLN, RLN, RP, LGRE, HGRE, SRLGE, SRHGE, LRLGE, dan LRHGE. Dengan menggunakan parameter ini akan dilakukan klasifikasi kedalam dua kelas yaitu kelas normal dan terdeteksi tuberkulosis. Berikut adalah tahapan yang dilakukan pada proses *training* dan *testing*:

4.3.1. Training

Proses *training* dilakukan dengan jumlah data sebanyak 463, dimana data ini terdiri dari 228 data normal dan 235 data tuberkulosis. Pada penelitian ini dilakukan beberapa percobaan pada setiap sudut orientasi GLRLM dengan 2 *hidden layer* yang memiliki jumlah *node* yang bervariasi. Uji coba yang dilakukan pada penelitian ini seperti yang telah dijelaskan pada BAB III Subbab 3.3. Berikut adalah contoh perhitungan manual dari proses klasifikasi menggunakan *Elman* RNN dengan *node* pada *hidden layer* satu sebanyak 20 dan *node* pada *hidden layer* dua sebanyak 50.

- a. Tahap awal yang dilakukan pada *Elman* RNN yaitu menentukan nilai parameter tambahan seperti bobot awal dari *input layer* ke *hidden layer*,

Tabel 4.11 Hasil Proses net_j

Persamaan	Hasil
$net1$	1.3630e-11
$net2$	1.9910e-11
$net3$	1.5450e-11
$net4$	6.7830e-12
$net5$	1.3345e-11
$net6$	4.9190e-12
\vdots	\vdots
$net50$	2.1743e-12

Selanjutnya menghitung δ kesalahan dengan fungsi sigmoid dengan menggunakan persamaan 2.24.

$$\begin{aligned}\delta_1 &= \delta_{net1} f'(net_1) \\ &= (1.3630e - 11) \times 1 \\ &= 1.3630e - 11\end{aligned}$$

Untuk hasil perhitungan setiap nilai δ_j ditunjukkan pada Tabel 4.12.

Tabel 4.12 Hasil Proses net_j

Persamaan	Hasil
1	1.3630e-11
2	1.9910e-11
3	1.5450e-11
4	6.7830e-12
5	1.3340e-11
6	4.9190e-12
\vdots	\vdots
50	2.1740e-12

Tabel 4.17 Hasil *Training* pada Sudut Orientasi 0

<i>Hidden Layer 1</i>	<i>Hidden Layer 2</i>	<i>Learning Rate</i>	<i>Waktu Training</i>	<i>Accuracy (%)</i>
20	50	0.1	0:00:03	96.5293
		0.2	0:00:01	70.4989
		0.3	0:00:01	65.9436
		0.4	0:00:04	98.6985
		0.5	0:00:05	96.3124
50	100	0.1	0:00:10	99.4920
		0.2	0:00:13	95.0108
		0.3	0:00:03	69.6312
		0.4	0:00:03	66.3774
		0.5	0:00:16	98.2646
80	150	0.1	0:00:29	99.1323
		0.2	0:00:42	94.0594
		0.3	0:00:07	57.4837
		0.4	0:00:28	89.1089
		0.5	0:00:45	90.0990

Berdasarkan Tabel 4.17 hasil *training* terbaik pada sudut orientasi 0° diperoleh sebesar 99.3492% pada *node hidden layer 1* sebanyak 50 dan *node hidden layer 2* sebanyak 100 dengan *learning rate* 0.1. Untuk hasil *training* pada sudut orientasi 45° ditunjukkan pada Tabel 4.18.

Tabel 4.18 Hasil *Training* pada sudut Orientasi 45

<i>Hidden Layer 1</i>	<i>Hidden Layer 2</i>	<i>Learning Rate</i>	Waktu <i>Training</i>	Accuracy (%)
20	50	0.1	0:00:25	86.5510
		0.2	0:00:44	91.1063
		0.3	0:01:16	96.9631
		0.4	0:00:01	73.5358
		0.5	0:00:05	96.3124
50	100	0.1	0:00:03	65.2928
		0.2	0:00:12	94.3601
		0.3	0:00:04	68.2928
		0.4	0:00:03	94.5770
		0.5	0:00:11	92.8416
80	150	0.1	0:00:28	87.1287
		0.2	0:00:38	98.0477
		0.3	0:00:43	98.6985
		0.4	0:00:41	97.1800
		0.5	0:00:47	93.9262

Berdasarkan Tabel 4.18 hasil *training* terbaik pada sudut orientasi 45° diperoleh sebesar 98.6985% pada *node hidden layer 1* sebanyak 80 dan *node hidden layer 2* sebanyak 150 dengan *learning rate* 0.3. Untuk hasil *training* pada sudut orientasi 90° ditunjukkan pada Tabel 4.19.

Tabel 4.19 Hasil *Training* pada Sudut Orientasi 90

<i>Hidden Layer 1</i>	<i>Hidden Layer 2</i>	<i>Learning Rate</i>	<i>Waktu Training</i>	<i>Accuracy (%)</i>
20	50	0.1	0:00:41	97.8308
		0.2	0:00:05	98.4816
		0.3	0:00:39	87.6356
		0.4	0:00:39	96.7462
		0.5	0:00:04	93.7093
50	100	0.1	0:00:54	98.0477
		0.2	0:00:03	54.8807
		0.3	0:00:11	94.7939
		0.4	0:00:54	96.7462
		0.5	0:00:08	94.7093
80	150	0.1	0:00:15	99.1323
		0.2	0:00:43	93.2755
		0.3	0:00:34	88.5033
		0.4	0:00:31	92.8416
		0.5	0:00:43	93.4924

Berdasarkan Tabel 4.19 hasil *training* terbaik pada sudut orientasi 90° diperoleh sebesar 99.1323% pada *node hidden layer 1* sebanyak 80 dan *node hidden layer 2* sebanyak 150 dengan *learning rate* 0.1. Untuk hasil *training* pada sudut orientasi 135° ditunjukkan pada Tabel 4.20.

Tabel 4.20 Hasil *Training* pada Sudut Orientasi 135

<i>Hidden Layer 1</i>	<i>Hidden Layer 2</i>	<i>Learning Rate</i>	<i>Waktu Training</i>	<i>Accuracy (%)</i>
20	50	0.1	0:00:41	97.1800
		0.2	0:00:11	55.9653
		0.3	0:00:27	98.4816
		0.4	0:01:24	99.3492
		0.5	0:00:10	57.0499
50	100	0.1	0:00:17	98.9154
		0.2	0:00:06	77.6573
		0.3	0:00:15	94.7939
		0.4	0:00:06	73.9696
		0.5	0:00:18	98.2646
80	150	0.1	0:00:26	86.3341
		0.2	0:00:33	91.5401
		0.3	0:00:12	63.9913
		0.4	0:00:20	89.5879
		0.5	0:00:44	96.5293

Berdasarkan Tabel 4.20 hasil terbaik diperoleh sebesar 99.3492% pada *node hidden layer 1* sebanyak 20 dan *node hidden layer 2* sebanyak 50 dengan *learning rate* 0.4. Dari proses *training* ini menghasilkan bobot yang optimum yang akan digunakan pada proses *testing*. Tabel 4.21 adalah hasil bobot *input layer* ke *hidden layer 1*.

Tabel 4.21 Bobot Optimum *Input Layer* ke *Hidden Layer 1*

	w_1	w_2	w_3	w_4	...	w_{20}
b	1.4964	1.3404	-1.1761	-1.0154	...	-1.4917
x_1	-0.1313	-0.0916	0.2957	0.1486	...	0.2077
x_2	-0.0198	-0.3002	-0.2745	-0.3192	...	0.3012
\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots
x_{11}	-0.0996	-0.2288	0.0105	-0.1732	...	0.1557

- Darsyah, M. Y. (2014). Klasifikasi Tuberkulosis dengan Pendekatan Metode Supports Vector Machine (Svm). *Statistika*, 2(2):0–4.
- Depinta, L. and Abdullah, Z. (2017). Penyakit Tuberculosis (TB) Paru dari Citra Rontgen. 6(1):61–66.
- Dewi, I. R., Magdalena, I. R., and Nur, R. Y. (2019). Klasifikasi Retinopati Diabetik pada Citra Mata Digital Menggunakan 3d GLCM dengan Learning Vector Quantization. *e-Proceeding Eng.*, 6(2):4186–4193.
- Fajrin, H. R. (2016). Perbandingan Metode untuk Perbaikan Kualitas Citra Mammogram. *J. SIMETRIS*, 7(2):657–664.
- Faqih, K. M., Husna, H. S., Febriani, E., Erfandi, M., Bachtiar, N. R., and Karmila, E. D. (2014). *Buku Pintar Penanggulangan Tuberkulosis: Kupas Para Kyai*.
- Fatta, H. A. (2007). Konversi Format Citra Rgb Ke Format Grayscale Menggunakan Visual Basic. *Semin. Nas. Teknol. 2007*, pages 1–6.
- Faustina, F. D. E. A. (2019). Identifikasi Pola Kerapuhan Tulang Berdasarkan Fitur Tekstur Citra Dental Panoramic Radiograph (Dpr) Menggunakan Gray Level Run Length Matrix (GLRLM) Dan Support Vector Machine (SVM). *Skripsi, Univ. Islam Negeri Sunan Ampel Surabaya*.
- Hadi, S. (2018). Konsep Sabar dalam Al-Qur'an. *J. Madani*, 1(2):473–488.
- Hakim, H. (2018). Epidemi Dalam Alquran (Suatu Kajian Tafsir Maudhu'i dengan Corak Ilmi). *KORDINAT*, 17(1):114–128.
- Haleot, R. A., Abood, Z. M., and Karam, G. S. (2020). Thermal Image Enhancement Algorithm Based on Adaptive Fusion Technique of Multi Color Space. *Int. J. Eng. Res. Adv. Technol.*, 6(9):10–15.

- Hamid, A. (2019). Klasifikasi Penyakit Tuberculosis dan Pneumonia pada Paru-paru Manusia Berdasarkan Citra Chest X-ray menggunakan Convolutional Neural Network. *Skripsi, UIN Syarif Hidayatullah Jakarta*.
- Herdyanti, D. K. K. R. M. (2018). Identifikasi Jamur pada Pasien Penderita Tuberculosis Paru Di Rsup H. Adam Malik. *Karya Tulis Ilm.*
- Hesti, G. (2020). Pemanfaatan Image Mining Untuk Klasifikasi Kanker Paru-Paru Menggunakan Jaringan Saraf Tiruan (Studi Kasus: Semen Padang Hospital Dan Rsup M Djamil Padang. *Thesis, Univ. Andalas*, pages 1–5.
- Kaur, K. and Mittal, S. K. (2020). Materials Today : Proceedings Classification of mammography image with CNN-RNN based semantic features and extra tree classifier approach using LSTM. *Mater. Today Proc.*, (xxxx).
- Kurniadi, W. and Maliki, I. (2016). Speech Recognition Menggunakan Elman Recurrent Neural Network untuk Kata dalam Bahasa Indonesia. *Tek. Inform. - Univ. Komput. Indones.*, pages 1–10.
- Kusuma, R. (2017). Pemahaman Mahasiswa Ilmu Al- Qur'an dan Tafsir Atas Ayat-Ayat Musibah. *Skripsi, Univ. Islam Negeri Syarif Hidayatullah Jakarta*.
- Leavline, J. and Antony, A. (2013). Salt and Pepper Noise Detection and Removal in Gray Scale Images: An Experimental Analysis. *Int. J. Signal Process. Image Process. Pattern Recognit.*, 3(10):1–16.
- Lesnussa, Y. A., Latuconsina, S., and Persulesy, E. R. (2015). Aplikasi Jaringan Saraf Tiruan Backpropagation untuk Memprediksi Prestasi Siswa SMA (Studi kasus : Prediksi Prestasi Siswa SMAN 4 Ambon). *J. Mat. Integr.*, 11(2):149–160.

- Li, C., Guo, C., Ren, W., Cong, R., and Hou, J. (2019). An Underwater Image Enhancement Benchmark Dataset and Beyond. *IEEE Trans. Image Process.*, 29:4376–4389.
- Li, C., Tang, S., Yan, J., and Zhou, T. (2020). Low-Light Image Enhancement Based on Quasi-Symmetric Correction Functions by Fusion. *Symmetry (Basel)*, 12:1–18.
- Matondang, Z. A. (2017). Penerapan Metode Contrast Limited Adaptive Histogram Equalization (Clahe) Pada Citra Digital Untuk Memperbaiki Gambar X-Ray. *STMIK Kristen Neumann Indones.*, pages 24–29.
- Mustafa, A. A. and Tahir, A. A. K. (2020). Improving the Performance of Finger-Vein Recognition System Using A New Scheme of Modified Preprocessing Methods. *Acad. J. Nawroz Univ.*, 9(3):397–409.
- Nagarajan, V., Caroline, E., and Murugan, S. (2019). Feature extraction based on empirical mode decomposition for automatic mass classification of mammogram images. *Med. Nov. Technol. Devices*, 1:1–14.
- Naufal, M. A. (2017). Implementasi Metode Klasifikasi K-Nearest Neighbor (K-Nn) untuk Pengenalan Pola Batik Motif Lampung. *Skripsi, Univ. Lampung*.
- Nurdiansyah, V. V., Cholissodin, I., and Adikara, P. P. (2020). Klasifikasi Penyakit Tuberkulosis (TB) menggunakan Metode Extreme Learning Machine (ELM). *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, 4(5):1387–1393.
- Nurtiyasari, D. (2014). Aplikasi Model Recurrent Neural Network Dan Model Recurrent Neuro Fuzzy Untuk Klasifikasi Nodul Kanker Paru Dari Citra Foto Paru. *Skripsi, Univ. Negeri Yogyakarta*.

- Parui, K. and Tripathy, B. K. (2019). Diabetic Retinopathy Detection & Segmentation Using Color Image Processing. *Comput. Rev. J.*, 4:90–103.
- Permana, A. A. J. and Prijodiprodjo, W. (2014). Sistem Evaluasi Kelayakan Mahasiswa Magang Menggunakan Elman Recurrent Neural Network. *IJCCS*, 8(1):37–48.
- Permana, I. S. and Sumaryana, Y. (2018). Sistem Pakar untuk Mendiagnosa Penyakit Kulit dengan Metode Forward Chaining. *Jumantaka*, 1(1):361–370.
- Pertiwi, J. I., Putri, A. R., and Lestari, R. (2020). Analisis Perilaku Model Sir Tanpa dan dengan Vaksinasi. *J. Ilmu Mat. dan Terap.*, 14(2):223–232.
- Praditya, R. (2020). Penerapan Jaringan Syaraf Tiruan Elman Recurrent Neural Network (Ernn) untuk Prediksi Produksi Tandan Buah Kelapa Sawit. Technical report.
- Purwandari, E. P., Hasibuan, R. U., and Andreswari, D. (2018). Identifikasi Jenis Bambu Berdasarkan Tekstur Daun dengan Metode Gray Level Co-Occurrence Matrix dan Gray Level Run Length Matrix Identification of Bamboo Species Based on Leaf Texture using Gray Level Co-Occurrence Matrix and Gray Level Run Length Matrix. *J. Teknol. dan Sist. Komput.*, 6(4):146–151.
- Puspitasari, W. T. R. I. (2019). Sistem Klasifikasi Leukemia berdasarkan Citra Peripheral Blood Microscopic menggunakan Extreme Learning Machine. *Skripsi, UIN Sunan Ampel Surabaya*.
- Qassim, H. M., Basheer, N. M., and Farhan, M. N. (2019). Brightness Preserving Enhancement for Dental Digital X-ray Images Based on Entropy and Histogram Analysis. *J. Appl. Sci. Eng.*, 22(1):187–194.

- R, D. S. M. and D, A. (2019). Comparison of Gaussian and Median Filters to Remove Noise in Dental images. *Inst. Sch.*, pages 1430–1436.
- Rafflesia, U. (2014). Model Penyebaran Penyakit Tuberkulosis (TBC). *J. Gradien*, 10(2):983–986.
- Rahman, T., Khandakar, A., Kadir, M. A., Islam, K. R., Islam, K. F., Mazhar, R., Hamid, T., Islam, M. T., Mahbub, Z. B., Ayari, M. A., and Chowdhury, M. E. H. (2020). Reliable Tuberculosis Detection using Chest X-ray with Deep Learning , Segmentation and Visualization. *IEEE Access*, XX:1–15.
- Reja, I. D. and Santoso, A. J. (2013). Pengenalan Motif Sarung (Utan Maumere) Menggunakan Deteksi Tepi. *Semin. Nas. Teknol. Inf. Komun. Terap. 2013 (SEMANTIK 2013)*, (November):161–168.
- Rifaldi, M. I. (2019). Implementasi Jaringan Syaraf Tiruan Elman Recurrent Neural Network (ERNN) Untuk Peramalan Penjualan Kerupuk Mirasa. *Tugas akhir, Univ. Islam Negeri Sultan Syarif Kasim Riau*.
- S, A. (2019). Tuberculosis Chest X-ray Image Dataset.
- Santony, J., Harlan, J., Madenda, S., and M, C. (2015). Segmentasi Citra X-Ray Thorax Untuk Mengidentifikasi Objek Infiltrat Dengan Proses Morfologi Matematika. *Pros. Semin. Ilm. Nas. Teknol. Komput. (SENATKOM 2015)*, 1:528–534.
- Sembiring, A. (2016). Perbandingan Algoritma Mean Filter , Median Filter dan Wiener Filter pada Aplikasi Restorasi Citra RGB Terdegradasi Impulse Noise Menggunakan The Peak Signal To Noise Ratio (PSNR). pages 1–8.

- Setiawan, I. K. D., Rasmana, S. T., and Wibowo, M. C. (2015). Analisis Fitur Citra Prasasti Logam Menggunakan Metode Gray Level Run Length Matriks. *J. Control Netw. Syst.*, 4(1):22–30.
- Sinaga, A. S. R. (2017). Implementasi Teknik Thresholding pada Segmentasi Citra. *J. Mantik Penusa*, 1(2):48–51.
- Siregar, P. A., Gurning, F. P., Eliska, and Pratama, M. Y. (2018). Analisis Faktor yang Berhubungan dengan Kejadian Tuberkulosis Paru Anak di Rsud Sibuhuan. *J. Berk. Epidemiol.*, 6:268–275.
- Sudarsono, A. (2016). Jaringan Syaraf Tiruan Untuk Memprediksi Laju Pertumbuhan Penduduk Menggunakan Metode. *Media Infotama*, 12(1):61–69.
- Sugeng, O. P. K., Magdalena, R., and Tsp, H. F. (2016). Sistem Deteksi Glaukoma Dengan Pengukuran Area Optik Disk Pada Citra Fundus Glaucoma. *e-Proceeding Eng.*, 3(3):4823–4830.
- Sukino (2018). Konsep Sabar dalam Al-Quran dan Kontekstualisasinya dalam Tujuan Hidup Manusia Melalui Pendidikan. *J. RUHAMA*, 1(1):63–77.
- Umamaheswari, D. and Geetha, S. (2020). Visual Quality and Illumination Enhancement Using Gamma Corrected Gaussian Filtering Framework for Covid-19 Images. *ICTACT J. Image Video Process.*, 11(01):2268–2274.
- Walangadi, O. D. (2020). Perancangan Buku Ilustrasi Dengan Teknik Digital Painting Sebagai Media Kampanye Sosial Pencegahan Penyakit Tuberkulosis Anak Usia 6-12 Tahun. *Tugas Akhir, Univ. Din.*
- WHO (2020). World Health Organization.

- Wibawa, A. P., Guntur, M., Purnama, A., Akbar, M. F., and Dwiyanto, F. A. (2018). Metode-metode Klasifikasi. *Pros. Semin. Ilmu Komput. dan Teknol. Inf.*, 3(1):134–138.
- Xie, Y., Wu, Z., Han, X., Wang, H., Wu, Y., Cui, L., Feng, J., Zhu, Z., and Chen, Z. (2020). Computer-Aided System for the Detection of Multicategory Pulmonary Tuberculosis in Radiographs. *J. Healthc. Eng.*, 2020:0–11.
- Xu, S. S.-d., Chang, C.-c., Su, C.-t., and Phu, P. Q. (2019). Classification of Liver Diseases Based on Ultrasound Image Texture Features. *Appl. Sci.*, 9:1–25.

