

Klasifikasi Jenis Kulit Wajah menggunakan *Backpropagation Neural Networks* Berbasis GLCM

M. ARY HERYANTO, DENY JUANANTA, AGATA SADANARESWARI, SARI AYU
WULANDARI

Program Studi Teknik Elektro, Universitas Dian Nuswantoro
Email: m.aryheryanto@dsn.dinus.ac.id

Received 30 Mei 2023 | *Revised* 19 Juni 2023 | *Accepted* 22 Juni 2023

ABSTRAK

Kulit wajah sangat sensitif dibandingkan dengan bagian tubuh lainnya. Ada beberapa jenis kulit wajah, yaitu normal, berminyak, dan kering. Namun, terkadang mengidentifikasi jenis kulit wajah seseorang dengan benar bisa menjadi masalah karena terdapat lima jenis kulit wajah yang berbeda. Untuk mengatasi kesulitan dalam mengidentifikasi jenis kulit wajah, pada penelitian ini diterapkan metode klasifikasi Backpropagation Neural Network berbasis GLCM. Penelitian ini menggunakan tiga jenis kulit wajah, yaitu: kering, berminyak, dan normal. Sedangkan untuk mencari model arsitektur yang tepat dilakukan dengan cara variasi jumlah hidden layer dan jumlah neuron per hidden layer. Setelah dilakukan beberapa pengujian didapatkan hasil akurasi 96.70% untuk model sembilan lapisan tersembunyi dengan enam neuron pada tiap lapisan tersembunyi.

Kata kunci: kulit wajah, klasifikasi, backpropagation neural network, GLCM.

ABSTRACT

Facial skin is very sensitive compared to other body parts. There are several facial skin types: normal, oily, and dry. However, sometimes correctly identifying a person's facial skin type can be problematic because there are five different skin types. To overcome difficulties in identifying facial skin types, this study applied the GLCM-based Backpropagation Neural Networks classification method. This study used three types of facial skin, namely: dry, oily, and normal. Meanwhile, finding the right architectural model is done by varying the number of hidden layers and the number of neurons per hidden layer. After several tests, the results obtained an accuracy of 96.70% for the nine hidden layers model with six neurons for each hidden layer.

Keywords: facial skin, classification, backpropagation neural network, GLCM.

1. PENDAHULUAN

Kulit merupakan bagian terluar tubuh yang melapisi dan melindungi tubuh terutama dari paparan sinar Ultra Violet (UV) matahari. Akibat paparan UV mengakibatkan kerusakan jaringan kulit, di antaranya keriput, bercak hitam, jerawat, kanker kulit dan lain sebagainya. Selain memiliki nilai estetika, kulit wajah juga merupakan bagian kulit yang paling sensitif sehingga sebagian orang sangat memperhatikan dan menjaga kesehatan kulit wajah **(Sulastri & Chaerunisaa, 2016)**. Untuk menjaga kesehatan kulit wajah dari sinar UV matahari atau polusi perlu dilakukan perawatan teratur di antaranya dengan menggunakan kosmetik. Adapun pemilihan kosmetik perlu memperhatikan kondisi maupun jenis kulit wajah. Usia, gaya hidup, konsumsi makanan, keseimbangan hormonal maupun jenis kulit kering, normal dan berminyak menjadi salah satu dasar dalam pemilihan kosmetik sebagai perawatan kulit. Untuk mengatasi kondisi tersebut baik wanita maupun pria selalu mencari produk kosmetik yang tepat untuk dirinya **(Maryani & Fachrurrazi, 2017) (Fadila, dkk, 2022)**.

Perkembangan penelitian untuk identifikasi jenis kulit wajah telah banyak dilakukan. Metode dalam klasifikasi jenis kulit wajah yang telah digunakan di antaranya *Naive Bayes* **(Wahyuningtyas, dkk, 2015)**, *Haar Wavelet* **(Farhan, dkk, 2019)**, *certainty factor* **(Santi & Andari, 2019)**, *Gray Level Co-Occurance Matrix* (GLCM) dengan *Support Vector Machine* (SVM) **(Nusantara, dkk, 2018)**, dan *Discrete Wavelet Transform Dan Backpropagation* **(Amelia, dkk, 2019)**, *Convolution Neural Network* **(Saidah, dkk, 2021) (Chang, dkk, 2018)**, *K-Nearest Neighbor* **(Khodijah, dkk, 2022) (Priandana & Sukarman, 2014)**, dan *Fuzzy C-Means* **(Wulandari, dkk, 2019)**. Sedangkan akurasi dalam klasifikasi capaian tertinggi dengan metode *Naive Bayes*, namun pada penelitian tersebut meskipun keakuratannya mencapai 100% metode yang digunakan dengan pertanyaan-pertanyaan tentang ciri kulit wajah pada jenis kulit tertentu yang dijawab oleh individu berdasarkan ciri kulit wajah mereka sendiri. Akurasi yang lain yaitu sebesar 95% didapat dari penelitian menggunakan metode *Discrete Wavelet Transform* dan *Backpropagation*.

Dalam penelitian ini dikembangkan metode identifikasi jenis kulit wajah menggunakan *Backpropagation Neural Networks* (BNN) berbasis *Gray Level Co-Occurrence Matrix* (GLCM). Penggunaan GLCM sebagai ekstraksi fitur dalam *preprocessing* dipilih karena berbasis citra abu-abu sehingga tidak menjadi beban dalam komputasi dan menunjukkan tingkat keberhasilan klasifikasi yang tinggi berdasarkan nilai *contras*, *correlation*, *energy*, dan *homogeneity*. Selain itu, saat ini GLCM telah banyak digunakan dalam permasalahan klasifikasi menggunakan citra **(Mall, dkk, 2019) (Indriani, dkk, 2017)**. BNN saat ini juga menjadi salah satu metode klasifikasi yang banyak digunakan karena tingkat keberhasilan yang tinggi dan kemudahan dalam pembuatan model arsitekturnya.

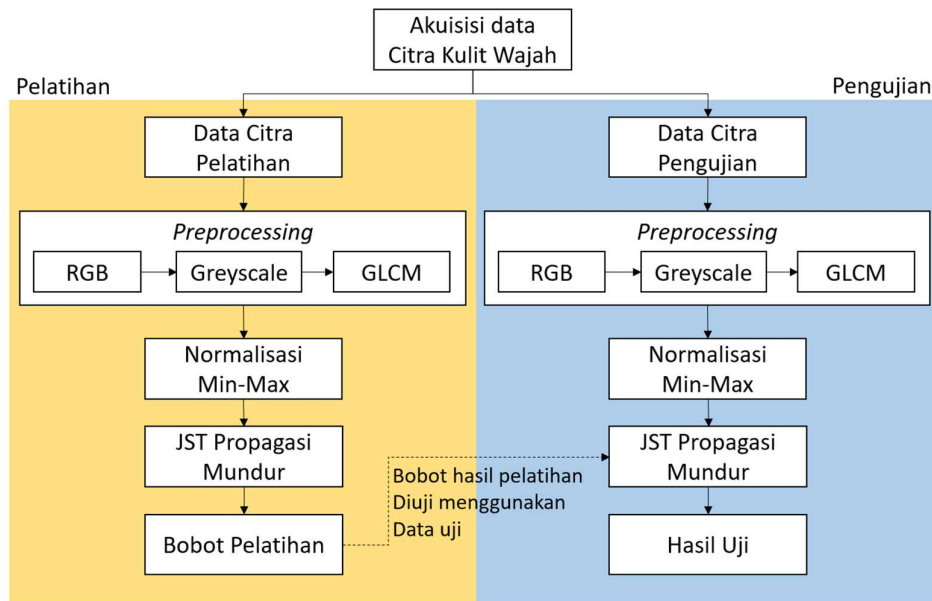
Dengan menggunakan hasil ekstraksi ciri dari GLCM dan hasil klasifikasi jenis kulit kering, berminyak, dan normal, penelitian ini diuji dengan menggunakan beberapa model arsitektur baik dari lapisan tersembunyi maupun dari jumlah neruon. Pelatihan model arsitektur yang dibuat, dilakukan sepuluh kali dengan dipilih salah satu hasil uji yang terbaik dari tiap model arsitektur. Sedangkan pengambilan data citra kulit wajah diambil pada bagian *T-Zone* karena pada bagian ini merupakan bagian kulit wajah yang paling banyak menghasilkan minyak.

Naskah ini selanjutnya dipaparkan sebagai berikut: bagian 2, memaparkan tentang metode pelaksanaan dari penelitian, dari perancangan model, pengambilan data, pelatihan hingga pengujian. Pada bagian 3 menjelaskan tentang hasil dan pembahasan untuk tiap model arsitektur, dan penentuan akurasi model. Terakhir, yaitu bagian 4 merupakan kesimpulan dari hasil penelitian.

2. METODE

Metode yang digunakan dalam penelitian ini sesuai alur pada Gambar 1. Tahap awal adalah dilakukan akuisisi data yaitu untuk mendapatkan data citra kulit yang terbagi menjadi kulit berminyak, kulit normal, dan kulit kering. Kemudian untuk proses klasifikasi menggunakan *Neural Networks* (NN) memerlukan data pelatihan dan data pengujian, sehingga dari hasil akuisisi data tersebut dibagi menjadi dua (**Utami, dkk, 2023**), yaitu 50% untuk data pelatihan dan 50% lainnya untuk data pengujian.


Pada proses pelatihan dilakukan *preprocessing*, yang terbagi menjadi dua tahapan yaitu tahap konversi citra RGB ke *Greyscale*, dan tahap ekstrasi ciri menggunakan GCLM. Dari hasil ekstrasi ciri GLCM ini kemudian dinormalisasi yang kemudian digunakan untuk pelatihan model JST propagasi mundur. Untuk mendapatkan hasil yang optimal, penelitian ini menggunakan variasi jumlah *hidden layer* dan jumlah neuron. Hasil bobot pelatihan tiap variasi jumlah *hidden layer* dan neuron kemudian diuji menggunakan data uji.



Gambar 1. Blok Diagram

2.1 Akuisisi Data


Pada akuisisi data ini digunakan kamera mikroskop digital 5x-1200x dengan hasil penyimpanan menggunakan format RGB (*Red, Green, dan Blue*). Data yang didapatkan pada penelitian ini berupa citra kulit pada bagian *T-zone* dari 60 wanita dengan distribusi 20 citra kulit kering, 20 citra kulit normal, dan 20 citra kulit berminyak. Data citra kulit ini kemudian dibagi menjadi dua, sebagian data untuk data pelatihan dan sebagian lainnya untuk pengujian.



Gambar 2. Hasil Akuisisi Citra Kulit pada Bagian T-Zone

2.2 Konversi RGB menjadi *Greyscale*

Data citra kulit wajah dengan format RGB kemudian dikonversi menjadi citra format *greyscale*. Hasil konversi dapat dilihat pada Gambar 3. Citra RGB tersebut terdiri dari 24 bit, di mana setiap piksel terdiri dari nilai Red 8 bit, Green 8 bit dan Blue 8 bit sehingga dengan konversi menjadi *greyscale* 8 bit dapat mempermudah dalam komputasi dan penyesuaian pada tahap ekstraksi fitur menggunakan *Grey Level Co-occurrence Matrix* (GLCM)



Gambar 3. Hasil konversi greyscale dari citra kulit kering

2.3 Ekstraksi Fitur GLCM

Dari data citra kulit yang telah dikonversi menjadi *greyscale*, tahap selanjutnya adalah ekstraksi fitur menggunakan GLCM. Ekstraksi ciri ini melalui tekstur dengan menghitung *contrast*, *correlation*, *energy*, dan *homogeneity* (CCrEH). Tabel 1 merupakan hasil ekstraksi fitur menggunakan GLCM.

2.4 Normalisasi Min-Max

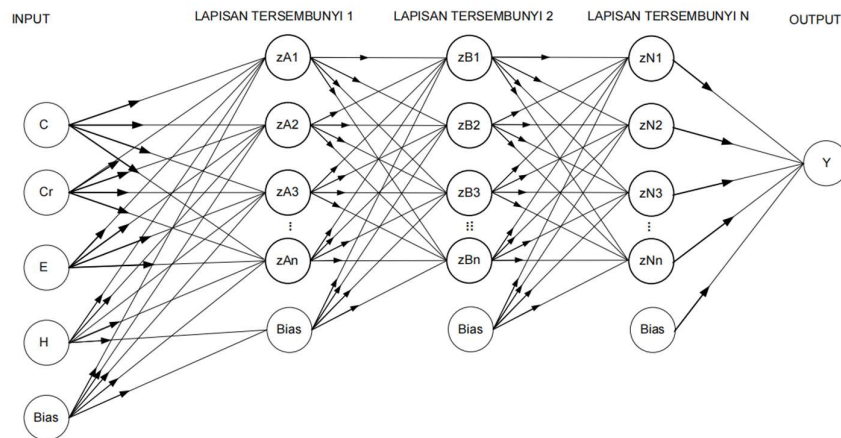
Dari tahap ekstraksi ciri dapat dilihat bahwa perbedaan orde pada sebaran data tiap ciri sangat jauh, sehingga diperlukan normalisasi untuk mempermudah dalam klasifikasi. Tahap normalisasi menggunakan metode min-max sehingga tiap ciri pada GLCM dinormalisasi pada skala -1 hingga 1.

Tabel 1. Hasil Ekstraksi Fitur untuk Data Pelatihan dan Data Pengujian

Jenis Kulit	DATA PELATIHAN				DATA PENGUJIAN			
	Contras	Correlation	Energy	Homogeneity	Contras	Correlation	Energy	Homogeneity
Kering	144797.8	-0.00045	1.36E-06	0.01222625	144546.9	-4.48E-05	1.35E-06	0.012179
	145231.8	-4.30E-06	1.36E-06	0.01219659	144100.7	0.000262	1.36E-06	0.012197
	144941.1	-4.48E-04	1.36E-06	0.012223624	144860.6	0.000768	1.36E-06	0.012252
	144652.3	0.000803	1.36E-06	0.012244818	144978	-0.0004	1.36E-06	0.012196
	144453.7	0.000899	1.36E-06	0.012284389	144698.9	-1.01E-05	1.36E-06	0.012288
	145224.5	-0.00081	1.36E-06	0.01220976	144849	0.000279	1.36E-06	0.012216
	145201.5	-0.0003	1.36E-06	0.0122083	143580.7	-6.31E-05	1.36E-06	0.01216
	143913.6	0.002155	1.36E-06	0.012225937	143023.9	-0.00055	1.36E-06	0.012271
	144419.2	0.000905	1.36E-06	0.01226867	142835.6	5.71E-05	1.36E-06	0.012217
	145531	-0.00012	1.36E-06	0.012191927	143125.6	-0.0008	1.36E-06	0.012284
Berminyak	130843.8	0.000719	1.49E-06	0.012648845	132270.4	4.81E-04	1.50E-06	0.012688
	131721.8	8.53E-05	1.50E-06	0.012590225	132803.1	-5.19E-04	1.50E-06	0.01262
	133988	-0.00033	1.51E-06	0.012625447	132479.1	0.00054	1.51E-06	0.012703
	134511.1	-0.00074	1.52E-06	0.012544492	131939.9	-4.72E-04	1.51E-06	0.01266
	133146.3	-0.001	1.52E-06	0.012662113	129690.4	0.000749	1.51E-06	0.012772
	133572.2	0.001443	1.51E-06	0.012639791	133685	0.000753	1.52E-06	0.012691
	133179.3	0.000358	1.51E-06	0.01269933	133897.1	-0.00031	1.52E-06	0.012624
	133461.1	-0.00055	1.51E-06	0.012712512	134085.4	0.001034	1.52E-06	0.012608
	133247.7	1.08E-03	1.51E-06	0.012607946	132072.4	-0.00107	1.51E-06	0.012594
	132006.9	0.000321	1.50E-06	0.012728102	132029.6	-0.00111	1.50E-06	0.012605
Normal	127604.3	0.002007	1.53E-06	0.012858809	127829.3	-5.51E-04	1.54E-06	0.012828
	129531.4	-0.00129	1.53E-06	0.012820743	129501	-6.79E-04	1.53E-06	0.012843
	129099.4	2.41E-03	1.53E-06	0.012808501	131106.3	-0.00089	1.53E-06	0.012844
	128663	0.002258	1.53E-06	0.012829083	131167.9	-7.38E-04	1.54E-06	0.012802
	130392.7	0.001292	1.54E-06	0.012809924	129200	5.90E-05	1.53E-06	0.012951
	128924.7	-0.00265	1.53E-06	0.012684867	128184.1	0.000411	1.54E-06	0.012729
	128545.3	0.004553	1.54E-06	0.012789845	127678.4	-0.0044	1.54E-06	0.012868
	129406.6	-0.00313	1.54E-06	0.012786203	127442.9	0.004365	1.54E-06	0.012847
	130565.8	-0.00038	1.53E-06	0.012827831	128127	-3.56E-06	1.54E-06	0.012865
	127204.4	0.000122	1.53E-06	0.012827526	128953.3	-0.00098	1.54E-06	0.01279

2.5 Pelatihan dan Pengujian JST Propagasi Mundur

Pada penelitian ini dilakukan beberapa variasi jumlah lapisan tersembunyi (*hidden layer*) dan juga variasi jumlah neuron pada tiap lapisan tersembunyi. Untuk *input* jaringan digunakan fitur GLCM yaitu *contras*, *correlation*, *energy*, dan *homogeneity* (CCrEH). Sedangkan *output* hanya satu dengan label kelas klasifikasi adalah kering bernilai -1, berminyak bernilai 0, dan normal bernilai 1. Untuk lebih jelasnya dapat dilihat pada model JST pada Gambar 4.



Gambar 4. Arsitektur JST Klasifikasi Jenis Kulit Wajah

Pada proses pelatihan menggunakan 50% data yang dilatih yang berulang dengan variasi 1, 2, 4, dan 7 lapisan tersembunyi, untuk jumlah neuron menggunakan variasi 4, 6, 8, dan 10 neuron dilakukan berulang tiap jumlah lapisan tersembunyi. Dalam pelatihan dicari bobot terbaik dengan parameter *learning rate*: 0.1, maksimum epoch: 10000, dan kinerja tujuan menggunakan metode *mean square error* (MSE): 1×10^{-5} . Hasil bobot tiap pelatihan disimpan untuk dilakukan pengujian. Pada proses pengujian dilakukan menggunakan 50% data lainnya untuk tiap variasi jumlah Lapisan Tersembunyi (LT) dan variasi jumlah neuron.

3. HASIL DAN PEMBAHASAN

Tahap pengujian dilakukan untuk menguji validasi model yang didapat dengan memasukan data pengujian. Hasil pengujian dapat dilihat pada Tabel 2 sampai dengan Tabel 5.

Tabel 2. Hasil Pengujian menggunakan 4 Neuron

LAPISAN TERSEMBUNYI	t (s)	EPOCH	MSE PELATIHAN	MSE UJI
1	6.14	10000	3.00E-03	0.352
3	1.04	568	6.94E-05	0.149
5	4.43	5111	5.96E-05	0.129
7	1.4	886	9.79E-05	0.061
9	1.47	873	6.17E-05	0.181

Tabel 3. Hasil Pengujian menggunakan 6 Neuron

LAPISAN TERSEMBUNYI	t (s)	EPOCH	MSE PELATIHAN	MSE UJI
1	5.9	10000	9.23E-04	1.767
3	2.6	2902	6.39E-05	1.044
5	1.41	352	8.31E-05	0.480
7	0.95	297	5.24E-05	0.100
9	0.89	280	9.26E-05	0.055

Tabel 4. Hasil Pengujian menggunakan 8 Neuron

LAPISAN TERSEMBUNYI	t (s)	EPOCH	MSE PELATIHAN	MSE UJI
1	5.79	10000	6.79E-04	0.219
3	1.04	673	6.83E-05	0.225
5	1.17	780	6.55E-05	0.351
7	0.71	143	7.23E-05	0.096
9	0.71	74	3.93E-05	0.130

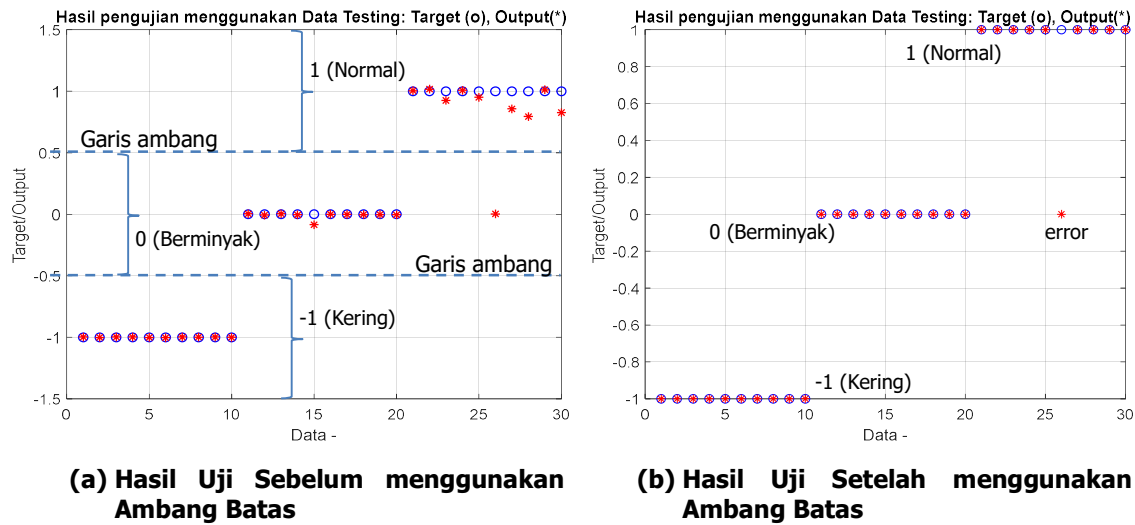
Tabel 5. Hasil Pengujian menggunakan 10 Neuron

LAPISAN TERSEMBUNYI	t (s)	EPOCH	MSE PELATIHAN	MSE UJI
1	5.38	10000	1.76E-04	0.548
3	1.23	1115	5.51E-05	0.249
5	0.69	167	6.38E-05	0.153
7	0.75	135	6.69E-05	0.125
9	0.77	145	6.85E-05	0.093

Dari hasil pengujian menggunakan empat neuron pada Tabel 2, untuk masing-masing variasi *layer* tersembunyi didapat MSE terkecil pada tujuh *layer* tersembunyi sebesar 0.061 dengan iterasi pelatihan 886 *epoch* dan MSE 9.79E-05. Meskipun nilai MSE pelatihan lebih besar dari pengujian dengan lima *layer* tersembunyi namun hasil uji model menggunakan data uji menunjukkan kinerja yang lebih baik, hal ini dapat berarti bahwa pada pelatihan didapatkan model *overfitting* karena model JST terlalu mendekati model dari data pelatihan. Dari data uji pada Tabel 2 sampai dengan Tabel 5 diambil tiap MSE terkecil, yaitu model arsitektur BNN (1) 4 neuron pada 7 LT, (2) 6 neuron pada 9 LT, (3) 8 neuron pada 7 LT, dan (4) 10 neuron pada 9 LT. Tiap luaran (y) hasil uji dengan MSE terkecil ini kemudian diberikan ambang batas untuk klasifikasi menggunakan Persamaan (1).

$$f_o(y) = \begin{cases} -1, & y \leq -0.5 \\ 0, & -0.5 < y < 0.5 \\ 1, & y \geq 0.5 \end{cases} \quad (1)$$

Pada Gambar 5.a. adalah hasil uji sebelum diberikan ambang batas dan Gambar 5.b. merupakan hasil uji setelah diberikan ambang batas. Setelah dilakukan penyesuaian menggunakan ambang batas kemudian dilakukan akurasi dari tiap model arsitekturnya. *Confusion Matrix* biasanya digunakan untuk mengevaluasi atau memvisualisasikan perilaku model arsitektur dari *machine learning* pada klasifikasi yang terawasi. *Confusion Matrix* ini merupakan matriks persegi di mana baris mewakili kelas aktual dan kolom mewakili kelas yang diprediksi (Rahmad, dkk, 2020).



Gambar 5. Hasil Uji Arsitektur BNN 6 Neuron 9 Lapisan Tersembunyi

Pada penelitian ini karena target klasifikasi ada tiga, yaitu: kering, berminyak, dan normal maka untuk mendapatkan nilai akurasi menggunakan:

$$akurasi\ keseluruhan = \frac{\sum TP}{ju\ data} \times 100\% \quad (2)$$

Pada model arsitektur BNN 6 neuron 9 lapisan tersembunyi pada Gambar 5.b. didapat nilai akurasi keseluruhan adalah sebagai berikut:

$$akurasi\ keseluruhan = \frac{10 + 10 + 9}{30} \times 100\%$$

$$akurasi\ keseluruhan = 96.70\%$$

Sehingga visualisasi *Confusion Matrix* dari model arsitektur BNN 6 neuron pada 9 lapisan tersembunyi dapat dilihat pada Gambar 6. Dengan cara yang sama maka didapatkan nilai akurasi untuk tiap percobaan dengan nilai MSE yang terendah seperti pada Tabel 6.

Confusion Matrix

Output Class	-1 (Kering)	10 33.3%	0 0.0%	0 0.0%	100% 0.0%
	0 (Berminyak)	0 0.0%	10 33.3%	1 3.3%	90.9% 9.1%
	1 (Normal)	0 0.0%	0 0.0%	9 30.0%	100% 0.0%
		100% 0.0%	100% 0.0%	90.0% 10.0%	96.7% 3.3%
		Target Class			
		-1 (Kering)	0 (Berminyak)	1 (Normal)	

Gambar 6. Confusion Matrix Arsitektur BNN 6 Neuron pada 9 Lapisan Tersembunyi

Tabel 6. Hasil Akurasi Tiap Model Arsitektur dengan MSE Terendah

MODEL ARSITEKTUR		t (s)	EPOCH	MSE PELATIHAN	MSE UJI	AKURASI
LAPISAN TERSEMBUNYI	JUMLAH NEURON					
7	4	1.399	886	9.79E-05	0.0608	93.3%
9	6	0.886	280	9.26E-05	0.0551	96.7%
7	8	0.708	143	7.23E-05	0.0955	93.3%
9	10	0.771	145	6.85E-05	0.0925	93.3%

Pada Tabel 6 dapat dilihat hasil akurasi 96.70% pada model arsitektur 9 lapisan tersembunyi dengan 6 neuron pada tiap lapisan tersembunyi. Performa ini sangat baik karena dari 30 data uji hanya satu data yang salah prediksi, yaitu pada data kulit Normal yang diprediksi sebagai data kulit berminyak. Dalam pelatihan tercapai pada *epoch* ke 280 dengan waktu 0.886 detik, sedangkan MSE pelatihan meskipun lebih besar dari pada model arsitektur 7 LT 8 neuron atau 9 LT 10 neuron tetapi menunjukkan akurasi pengujian yang lebih tinggi. Hal ini disebabkan model yang lain *overfitting* pada data pelatihan.

4. KESIMPULAN

Setelah dilakukan pengujian dan analisis terhadap model JST propagasi mundur untuk klasifikasi jenis kulit wajah didapatkan hasil akurasi sebesar 96.70% dengan model arsitektur BNN 9 lapisan tersembunyi dengan 6 neuron pada tiap lapisan tersembunyi. Pada penelitian ini juga terjadi *overfitting* pada tiap pengujian, hal ini terjadi karena model JST yang dibuat tidak dapat menggeneralisasi dari data pengujian dan terlalu cocok dengan data pelatihan. Kejadian *overfitting* pada penelitian ini dapat terjadi karena data pelatihan terlalu kecil atau kurang variasi data sehingga sampel data tidak cukup untuk mewakili seluruh kemungkinan variasi data *input* secara tepat. Penelitian ini masih dilanjutkan dengan menambah variasi data pelatihan baik dari sisi umur maupun jenis kelamin serta penggunaan kamera non mikroskopis.

DAFTAR RUJUKAN

- Amelia, R. D., Tritasmoro, I. I., & Ibrahim, N. (2019). Klasifikasi Jenis Kulit Wajah Menggunakan Metode Discrete Wavelet Transform Dan Backpropagation. *EProceedings of Engineering*, 6(2).
- Chang, C.-C., Hsing, S.-T., Chuang, Y.-C., Wu, C.-T., Fang, T.-J., Chen, K.-F., & Choi, B. (2018). Robust skin type classification using convolutional neural networks. *2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, (pp. 2011–2014). <https://doi.org/10.1109/ICIEA.2018.8398040>
- Fadila, I., Minerva, P., & Astuti, M. (2022). Hubungan pengetahuan kosmetika dengan pemilihan kosmetik perawatan kulit wajah siswa Kelas XI Jurusan Tata Kecantikan SMK Negeri 7 Padang. *Jurnal Tata Rias Dan Kecantikan*, 2(1), 19–26.

- Farhan, M. R., Widodo, A. W., & Rahman, M. A. (2019). Ekstraksi Ciri Pada Klasifikasi Tipe Kulit Wajah Menggunakan Metode Haar Wavelet. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*.
- Indriani, O. R., Kusuma, E. J., Sari, C. A., & Rachmawanto, E. H. (2017). Tomatoes classification using K-NN based on GLCM and HSV color space. *2017 International Conference on Innovative and Creative Information Technology (ICITech)*, (pp. 1–6).
- Khodijah, L., Latifah, R., & Adharani, Y. (2022). Identifikasi Jenis Kulit Wajah Menggunakan K-Nearest Neighbor. *Seminar Nasional Teknik Elektro, Informatika Dan Sistem Informasi*, 1(1).
- Mall, P. K., Singh, P. K., & Yadav, D. (2019). Glcm based feature extraction and medical x-ray image classification using machine learning techniques. *2019 IEEE Conference on Information and Communication Technology*, (pp. 1–6).
- Maryani, M., & Fachrurrazi, S. (2017). Sistem Pendukung Keputusan Pemilihan Kosmetik Produk Latulipe Yang Sesuai Dengan Jenis Kulit Wajah Perempuan Indonesia Menggunakan Metode Promethee. *Sisfo: Jurnal Ilmiah Sistem Informasi*, 1(2).
- Nusantara, T. F. B., Atmaja, R. D., & Azizah, A. (2018). Klasifikasi Jenis Kulit Wajah Pria Berdasarkan Tekstur Menggunakan Metode Gray Level Co-occurrence Matrix (glcm) Dan Support Vector Machine (svm). *EProceedings of Engineering*, 5(2).
- Priandana, K., & Sukarman, S. (2014). Mobile munsell soil color chart berbasis android menggunakan histogram ruang citra HVC dengan klasifikasi KNN. *Jurnal Ilmu Komputer Dan AgroInformatika*, 3(2), 245421.
- Rahmad, F., Suryanto, Y., & Ramli, K. (2020). Performance comparison of anti-spam technology using confusion matrix classification. *IOP Conference Series: Materials Science and Engineering*, 879(1), 012076.
- Saidah, S., Fuadah, Y. N., Alia, F., Ibrahim, N., Magdalena, R., & Rizal, S. (2021). Facial Skin Type Classification Based on Microscopic Images Using Convolutional Neural Network (CNN). *Proceedings of the 1st International Conference on Electronics, Biomedical Engineering, and Health Informatics: ICEBEHI 2020, 8-9 October, Surabaya, Indonesia*, (pp. 75–83).
- Santi, I. H., & Andari, B. (2019). Sistem pakar untuk mengidentifikasi jenis kulit wajah dengan metode certainty factor. *INTENSIF: Jurnal Ilmiah Penelitian Dan Penerapan Teknologi Sistem Informasi*, 3(2), 159–177.
- Sulastris, A., & Chaerunisaa, A. Y. (2016). Formulasi masker gel peel off untuk perawatan kulit wajah. *Farmaka*, 14(3), 17–26.

- Utami, F. M., Magladena, R., & Saidah, S. (2023). Deteksi Jenis Kulit Wajah Menggunakan Convolutional Neural Network Arsitektur Mobilenet. *EProceedings of Engineering*, 9(6).
- Wahyuningtyas, R. S., Pratiwi, H. S., Informatika, T., Teknik, F., & Tanjungpura, U. (2015). Sistem pakar penentuan jenis kulit wajah wanita menggunakan metode naïve bayes. *Jurnal Sistem Dan Teknologi Informasi (JUSTIN)*, 1(1), 1.
- Wulandari, S. A., Prasetyanto, W. A., & Kurniatie, M. D. (2019). Classification of Normal, Oily and Dry Skin Types Using a 4-Connectivity and 8-Connectivity Region Properties Based on Average Characteristics of Bound. *J. Transform*, 17(01), 78–87.