

Ekstraksi Fitur Berdasarkan Fuzzy Restricted Boltzmann Machine Pada Klasifikasi Fashion-MNIST Dengan Dan Tanpa Noise.

Muhammad Ribhan Hadiyan, Firdaniza Firdaniza, Herlina Napitupulu

Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Padjadjaran
Email: muhammad20009@mail.unpad.ac.id; firdaniza@unpad.ac.id; herlina@unpad.ac.id.

Diterima:
19 Juni 2024

Diterima Setelah Revisi:
24 Juli 2024

Dipublikasikan:
16 Agustus 2024

Abstrak

Mixed accelerated learning method based on a Fuzzy Restricted Boltzmann Machine (MAFRBM) merupakan metode ekstraksi fitur pada gambar yang relatif baru dan belum banyak diimplementasikan. MAFRBm memiliki kelebihan dalam melakukan ekstraksi fitur pada gambar yang memiliki *noise*. Pada umumnya keberadaan *noise* pada gambar dapat mempengaruhi hasil ekstraksi fitur secara signifikan. Pada penelitian ini dilakukan ekstraksi fitur menggunakan MAFRBm pada dataset Fashion-MNIST dengan dan tanpa penambahan *noise*. Jenis *noise* yang ditambahkan pada gambar yaitu *gaussian*, *salt & pepper*, dan *poisson*. Hasil ekstraksi fitur MAFRBm kemudian diklasifikasikan menggunakan *Support Vector Machine* (SVM). Hasil klasifikasi menunjukkan akurasi tertinggi sebesar 88,2%. Selain itu, perbandingan hasil akurasi dari klasifikasi fashion-MNIST dengan *noise* tidak berbeda jauh dengan gambar tanpa *noise*.

Kata Kunci: Ekstraksi fitur, MAFRBm, *noise*, SVM.

Abstract

Mixed Accelerated Learning Method based on a Fuzzy Restricted Boltzmann Machine (MAFRBM) was a relatively new feature extraction method on images that had not been widely implemented. MAFRBm had advantages in extracting features from noisy images. Generally, the presence of noise in images could significantly affect the outcome of feature extraction. In this study, feature extraction was performed using MAFRBm on the Fashion-MNIST dataset with and without added noise. The types of noise added to the images were Gaussian, salt & pepper, and Poisson. The features extracted by MAFRBm were then classified using a Support Vector Machine (SVM). The classification results showed the highest accuracy at 88%. Moreover, the comparison of accuracy results from the classification of Fashion-MNIST with noise did not differ significantly from the images without noise.

Keywords: Feature Extraction, MAFRBm, *noise*, SVM

1 PENDAHULUAN

Ekstraksi fitur merupakan langkah penting sebelum melakukan klasifikasi gambar (Puspitasari *et al.*, 2023). Tujuan ekstraksi fitur pada gambar adalah mengambil fitur yang paling representatif pada sebuah gambar, sehingga algoritma pengklasifikasian seperti *Support Vector Machine* (SVM) dapat bekerja dengan optimal (Diantarakita *et al.*, 2019).

Menurut Lü et al. (2022), saat ini ekstraksi fitur berbasis *deep learning* banyak digunakan dalam pengklasifikasian gambar karena memiliki kekuatan komputasi yang besar dan kemampuan otomatis dalam mempelajari fitur-fitur penting dari data. Selain itu kemampuan dari ekstraksi fitur berbasis *deep learning* dapat memanfaatkan seluruh dataset sehingga menghasilkan fitur yang lebih komprehensif.

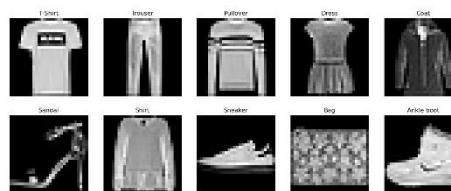
Lü et al. (2022) memperkenalkan metode ekstraksi fitur berbasis *deep learning* bernama *Mixed Accelerated learning method based on a Fuzzy Restricted Boltzmann Machine*. Metode tersebut merupakan pengembangan dari *Fuzzy Restricted Boltzmann Machine* yaitu sebuah model berdasarkan energi dan peluang yang menerapkan aturan *fuzzy* untuk mengontrol parameter-parameternya. Tujuan dari penerapan aturan *fuzzy* untuk memperbaiki kelemahan dari *Restricted Boltzmann Machine* yaitu dari segi kecepatan dan keterbatasan dalam representasi (Feng & Chen, 2018). Aspek yang ditingkatkan pada MAFRBM yaitu sparsitas distribusi data, penghilangan unit tersembunyi yang berlebihan, laju pembelajaran adaptif, dan penghentian iterasi berdasarkan konvergensi jaringan.

Pada eksperimen yang dilakukan Lü et al. (2022), ekstraksi fitur menggunakan MAFRBM dengan klasifikasi SVM telah dilakukan pada beberapa data seperti pada MNIST *handwritten database*, YELU *faces data set*, Weld *images data set*, dan ImageNet *image experiment*. Hasil eksperimennya menunjukkan bahwa MAFRBM memberikan efek akselerasi dan akurasi yang lebih baik dibandingkan model energi lainnya. Selain itu, MAFRBM terbukti *robust* terhadap *noise* dalam mengekstrak fitur pada gambar. Namun metode ini masih perlu banyak diimplementasikan pada dataset lain untuk menguji keunggulannya dalam melakukan ekstraksi fitur. Oleh karena itu, pada penelitian ini MAFRBM+SVM diimplementasikan untuk klasifikasi pada dataset MNIST-Fashion dengan menambahkan 3 macam *noise* yaitu *gaussian*, *salt & pepper*, dan *poisson*. Setelah itu, dievaluasi hasil ekstraksi fitur MAFRBM dari berbagai macam *noise* terhadap akurasi pada pengklasifikasian dengan menggunakan SVM.

2 KAJIAN PUSTAKA

2.1 Dataset *Fashion-MNIST*

Fashion-MNIST merupakan dataset gambar yang berasal dari sebuah perusahaan *e-commerce* yang bergerak dibidang *fashion* (Priyowidodo, 2019). Motivasi pembuatan dataset ini dikarenakan MNIST *handwritten database* dianggap terlalu mudah, sehingga kurang memberikan kesempatan untuk melakukan testing performa berbagai model klasifikasi modern. Dataset ini terdiri dari 10 kelas yaitu *T-shirt*, *Trouser*, *Pullover*, *Dress*, *Coat*, *Sandal*, *Shirt*, *Sneaker*, *Bag*, dan *Ankle boot*. Setiap gambar memiliki ukuran 28×28 piksel dengan jumlah gambar tiap kelas nya sebesar 6000 untuk data latih dan 1000 untuk data uji. Sampel gambar dari *fashion-MNIST* dapat dilihat pada Gambar 1.



Gambar 1. Sampel *Fashion-MNIST*

2.2 *Noise*

Piksel yang tidak diinginkan dan mengganggu kualitas sebuah citra akibat penyimpanan data digital yang diterima oleh alat penerima data gambar disebut dengan *noise* (Prayogi & Nababan,

2021). Beberapa jenis *noise* yang umum yaitu *gaussian*, *salt & pepper* dan *poisson* (Alamsyah & Pratama, 2019).

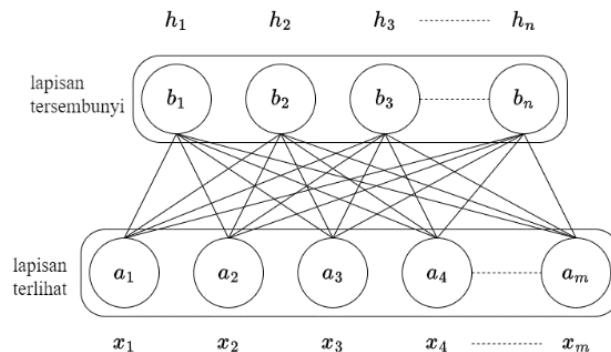
2.3 Machine Learning

Cabang ilmu dari *Artificial Intelligent* (AI) yang mempelajari bagaimana membuat sebuah sistem yang dapat belajar sendiri disebut dengan *machine learning* (Taye, 2023). Secara umum *machine learning* terbagi menjadi tiga tipe yaitu *supervised learning*, *unsupervised learning* dan *reinforcement learning*. *Supervised learning* merupakan metode *machine learning* yang menggunakan data latih berlabel, sedangkan *unsupervised learning* merupakan metode *machine learning* yang mempelajari pola dari data yang tidak berlabel. Sementara itu, *reinforcement learning* merupakan metode *machine learning* yang menerapkan prinsip *reward* dan *punishment* sehingga mendapatkan hasil tertinggi (Taye, 2023).

Menurut Wang et al. (2021) metode pembelajaran *machine learning* yang umum digunakan dalam klasifikasi gambar adalah *supervised learning* atau *unsupervised learning*. Metode *supervised learning* yang dapat digunakan untuk klasifikasi gambar adalah *Support Vector Machine* (SVM).

2.4 Mixed Accelerated learning method based on a Fuzzy Restricted Boltzmann Machine

Pada dasarnya MAFRBM sama seperti *Restricted Boltzmann Machine* (RBM) yang merupakan model berdasarkan energi dan peluang yang terdiri dari dua lapisan yaitu unit terlihat (x) dan unit tersembunyi (h). Setiap unit saling terhubung antara *visible layer* dengan unit tersembunyi. Parameter-parameter MAFRBM dinotasikan dengan $\tilde{\theta} = \{\tilde{\mathbf{a}}, \tilde{\mathbf{b}}, \tilde{\mathbf{w}}\}$ yang merepresentasikan himpunan bilangan *fuzzy* kurva segitiga simetris. Hubungan antara unit terlihat dengan unit tersembunyi digambarkan pada Gambar 2.



Gambar 2. Visualisasi MAFRBM (Lü et al., 2022)

Menurut Lü et al. (2022), fungsi energi MAFRBM dirumuskan dengan persamaan (1).

$$\tilde{E}(\mathbf{x}, \mathbf{h} | \tilde{\theta}) = - \sum_{i=1}^m \tilde{a}_i x_i - \sum_{j=1}^{c_1} \tilde{b}_j h_j - \sum_{i=1}^m \sum_{j=1}^{c_1} x_i \tilde{w}_{ij} h_j + \sum_{j=1}^{c_1} \lambda h_j^T h_j - \sum_{r=1}^{c_2} \tilde{b}_r h_r - \sum_{i=1}^m \sum_{j=1}^{c_2} x_i \tilde{w}_{ij} h_j + \sum_{r=1}^{c_2} \lambda h_r^T h_r \quad (1)$$

dengan m merupakan jumlah *visible unit*, n jumlah unit tersembunyi, c_1 jumlah unit tersembunyi yang tidak berlebihan, c_2 jumlah unit tersembunyi yang berlebihan, dan λ merupakan konstanta regularisasi. Ekstraksi fitur MAFRBM dilakukan dengan mengikuti *pseudo code* sebagai berikut

Tabel 1. *Pseudo Code* MAFRBM

Input:
Data latih $\mathbf{X}^{(0)}$
Laju pembelajaran η
Konstanta regularisasi λ
Jumlah unit tersembunyi n
Jumlah iterasi K
Batas kiri bobot (\mathbf{w}^L) dan batas kanan bobot \mathbf{w}^R
Batas kiri biar (\mathbf{a}^L) dan batas kanan bias \mathbf{a}^R pada <i>hidden unit</i>
Batas kiri biar (\mathbf{b}^L) dan batas kanan bias \mathbf{b}^R pada <i>visible unit</i>
Ekstraksi fitur MAFRBM
$k = 1$
while ($k \leq K$ or $ e_{t+1} - e_t \leq T$) do
Mulai fase Positif:
for all $x^{(0)} \in \mathbf{X}^{(0)}$ do
for all hidden units $j = 1, 2, \dots, n$ do
Hitung $P_L(h_j^{L(0)} = 1 \mathbf{x}^{(0)})$ dan $P_R(h_j^{R(0)} = 1 \mathbf{x}^{(0)})$
Hitung $P(h_j^{(0)} = 1 \mathbf{x}^{(0)}) = \frac{P_L(h_j^{L(0)} = 1 \mathbf{x}^{(0)}) + P_R(h_j^{R(0)} = 1 \mathbf{x}^{(0)})}{2}$
$h_j^{(0)} \in \{0, 1\} \sim P(h_j^{(0)} = 1 \mathbf{x}^{(0)})$
Sampel $h_j^{L(0)} \in \{0, 1\} \sim P_L(h_j^{L(0)} = 1 \mathbf{x}^{(0)})$
$h_j^{R(0)} \in \{0, 1\} \sim P_R(h_j^{R(0)} = 1 \mathbf{x}^{(0)})$
end for
end for
Hapus unit tersembunyi yang berlebihan:
for $t, l = 1, 2, \dots, n$ ($t \neq l$) do
if $\{h_t^p = h_l^p 1 \leq p \leq m, \forall p \in ns, h \in \{0, 1\}\}$
then $h_l^p = []$, Perbaharui $\mathbf{w}^L, \mathbf{w}^R, \mathbf{b}^L$ dan \mathbf{b}^R
end if
end for
Mulai fase Negatif:
for all $\mathbf{h}^{(0)} \in \mathbf{H}^{(0)}, \mathbf{h}^{L(0)} \in \mathbf{H}^{R(0)}, \mathbf{h}^{R(0)} \in \mathbf{H}^{R(0)}$ do
for all visible units $i = 1, 2, \dots, m$ do
Hitung $P_L(x_i^{L(1)} = 1 \mathbf{h}^{L(0)})$ dan $P_R(x_i^{R(1)} = 1 \mathbf{h}^{R(0)})$
Hitung $P(x_i^{(1)} = 1 \mathbf{h}^{(0)}) = \frac{P_L(x_i^{L(1)} = 1 \mathbf{h}^{L(0)}) + P_R(x_i^{R(1)} = 1 \mathbf{h}^{R(0)})}{2}$
$x_i^{(1)} \in \{0, 1\} \sim P(x_i^{(1)} = 1 \mathbf{h}^{(0)})$
Sampel $x_i^{L(1)} \in \{0, 1\} \sim P_L(x_i^{L(1)} = 1 \mathbf{h}^{L(0)})$
$x_i^{R(1)} \in \{0, 1\} \sim P_R(x_i^{R(1)} = 1 \mathbf{h}^{R(0)})$
end for
end for
Mulai fase Positif:
for all $x^{(1)} \in \mathbf{X}^{(1)}, x^{L(1)} \in \mathbf{X}^{L(1)}, x^{R(1)} \in \mathbf{X}^{R(1)}$ do
for all hidden units $j = 1, 2, \dots, n$ do

Hitung $P_L(h_j^{L(1)} = 1 | \mathbf{x}^{L(1)})$ dan $P_R(h_j^{R(1)} = 1 | \mathbf{x}^{R(1)})$
 Hitung $P(h_j^{(1)} = 1 | \mathbf{x}^{(1)}) = \frac{P_L(h_j^{L(1)} = 1 | \mathbf{x}^{L(1)}) + P_R(h_j^{R(1)} = 1 | \mathbf{x}^{R(1)})}{2}$
 $h_j^{(1)} \in \{0,1\} \sim P(h_j^{(1)} = 1 | \mathbf{x}^{(1)})$
 Sampel $h_j^{L(1)} \in \{0,1\} \sim P_L(h_j^{L(1)} = 1 | \mathbf{x}^{L(1)})$
 $h_j^{R(1)} \in \{0,1\} \sim P_R(h_j^{R(1)} = 1 | \mathbf{x}^{R(1)})$

end for**end for****Mulai error Rekonstruksi Jaringan**

$$\text{Hitung } e_k = \sqrt{\frac{\sum_{j=1}^N \sum_{i=1}^m (x_{ij}^{(0)} - P(x_{ij}^{(1)} = 1 | \mathbf{h}^{(0)}))^2}{m}}$$

Perbaharui laju pembelajaran

$$\eta_k = \begin{cases} 1,05\eta_{k-1}; & e_k < e_{k-1} \\ 0,7\eta_{k-1}; & e_k > 1,04e_{k-1} \\ \eta_{k-1}; & \text{lainnya} \end{cases}$$

Mulai fase perbaharuan:Hitung $\Delta\mathbf{w}^L, \Delta\mathbf{w}^R, \Delta\mathbf{a}^L, \Delta\mathbf{a}^R, \Delta\mathbf{b}^L, \Delta\mathbf{b}^R$ dengan

$$\left. \begin{aligned} \Delta w_{ij}^L &\approx \frac{1}{2} \left(P(h_j^{L(0)} = 1 | \mathbf{x}^{(0)}) x_i^{(0)} - P(h_j^{L(1)} = 1 | \mathbf{x}^{L(1)}) x_i^{L(1)} \right) \\ \Delta w_{ij}^R &\approx \frac{1}{2} \left(P(h_j^{R(0)} = 1 | \mathbf{x}^{(0)}) x_i^{(0)} - P(h_j^{R(1)} = 1 | \mathbf{x}^{R(1)}) x_i^{R(1)} \right) \\ \Delta a_i^L &\approx \frac{1}{2} (x_i^{L(0)} - x_i^{L(1)}) \\ \Delta a_i^R &\approx \frac{1}{2} (x_i^{R(0)} - x_i^{R(1)}) \\ \Delta b_i^L &\approx \frac{1}{2} \left(P(h_j^{L(0)} = 1 | \mathbf{x}^{(0)}) - P(h_j^{L(1)} = 1 | \mathbf{x}^{L(1)}) \right) \\ \Delta b_i^R &\approx \frac{1}{2} \left(P(h_j^{R(0)} = 1 | \mathbf{x}^{(0)}) - P(h_j^{R(1)} = 1 | \mathbf{x}^{R(1)}) \right) \end{aligned} \right\}$$

Perbaharui bobot dan bias

$$\left. \begin{aligned} \mathbf{w}_{k+1}^L &= \mathbf{w}_k^L + \eta_{k+1} \Delta \mathbf{w}_k^L, \quad \mathbf{w}_{k+1}^R = \mathbf{w}_k^R + \eta_{k+1} \Delta \mathbf{w}_k^R \\ \mathbf{a}_{k+1}^L &= \mathbf{a}_k^L + \eta_{k+1} \Delta \mathbf{a}_k^L, \quad \mathbf{a}_{k+1}^R = \mathbf{a}_k^R + \eta_{k+1} \Delta \mathbf{a}_k^R \\ \mathbf{b}_{k+1}^L &= \mathbf{b}_k^L + \eta_{k+1} \Delta \mathbf{b}_k^L, \quad \mathbf{b}_{k+1}^R = \mathbf{b}_k^R + \eta_{k+1} \Delta \mathbf{b}_k^R \end{aligned} \right\}$$

 $k := k + 1$ **end while****Refactoring Data**

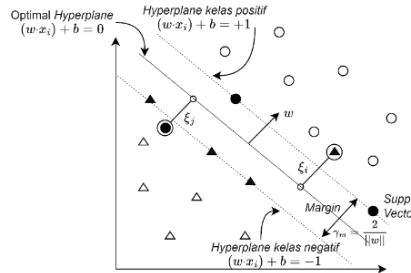
Hitung

$$\mathbf{T} = \sigma(\mathbf{b}^L + \mathbf{w}_k^L \mathbf{X}^{(0)}) + \sigma(\mathbf{b}^R + \mathbf{w}_k^R \mathbf{X}^{(0)})$$

2.5 Support Vector Machine

Support Vector Machine (SVM) merupakan metode klasifikasi yang bertujuan membuat sebuah *hyperplane* yang optimal antara kelas satu dengan yang lainnya (Reddy *et al.*, 2021). *Hyperplane* optimal ditentukan dengan memaksimumkan jarak dari *hyperplane* dengan titik data terdekat (*support vector*) dari masing-masing kelas. Jarak tersebut dikenal dengan istilah margin.

Pada masalah klasifikasi yang tidak dapat dipisahkan secara linear, dibutuhkan variabel *slack* untuk mengizinkan beberapa data yang dapat melanggar fungsi kendala (Deng *et al.*, 2012). Komponen SVM dengan adanya variabel *slack* diilustrasikan pada Gambar 3.



Gambar 3. Visualisasi Komponen SVM

Penerapan metode SVM menghasilkan nilai α dan b , dan dapat dibentuk fungsi *sign* seperti pada persamaan (2).

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^{N_s} \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \right)$$

$$= \begin{cases} +1, & \sum_{i=1}^{N_s} \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \geq 0 \\ -1, & \sum_{i=1}^{N_s} \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b < 0. \end{cases} \quad (2)$$

dengan N_s merupakan jumlah *support vector* dan $K(\mathbf{x}_i, \mathbf{x})$ merupakan fungsi kernel. Salah satu fungsi kernel yang umum digunakan yaitu *Gaussian Radial Basic Function* (RBF) yang dihitung menggunakan persamaan (3).

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}\|^2) \quad (3)$$

dengan γ merupakan *hyperparameter* kernel RBF.

2.6 Performance metrics

Kinerja model klasifikasi dapat dievaluasi dengan membentuk *confusion matrix* yang memiliki komponen terdiri dari *True Positives* (TP), *True Negatives* (TN), *False Positives* (FP), dan *False Negatives* (FN). *Confusion Matrix* dapat disajikan seperti pada Tabel 2 (Purbolaksono *et al.*, 2021).

Tabel 2. *Confusion Matrix*

		Data Aktual	
		Positif	Negatif
Data Prediksi	Positif	TP	FP
	Negatif	FN	TN

Komponen-komponen *Confusion Matrix* dapat dijelaskan sebagai berikut:

1. *True Positive* (TP) yaitu jumlah data kelas positif yang diklasifikasikan dengan benar oleh model.
2. *True Negative* (TN) yaitu jumlah data kelas negatif yang diklasifikasikan dengan benar oleh model.
3. *False Positive* (FP) yaitu jumlah data kelas negatif yang diklasifikasikan dengan salah oleh model.
4. *False Negative* (FN) yaitu jumlah data kelas positif yang diklasifikasikan dengan salah oleh model.

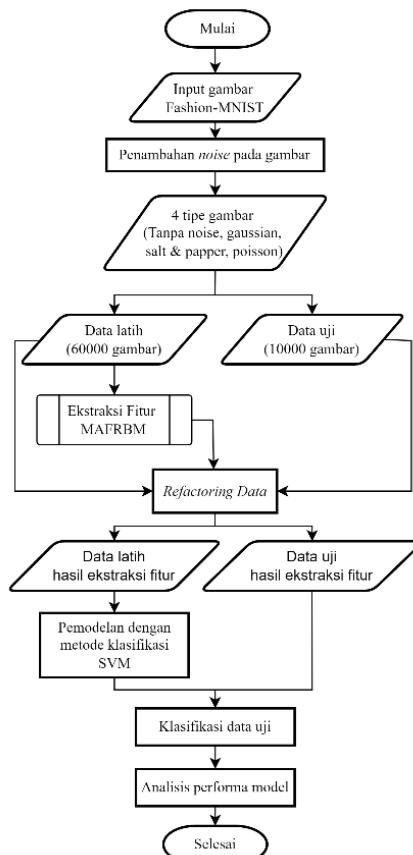
Confusion matrix yang diperoleh dapat digunakan untuk menghitung *performance metrics* yang digunakan dalam mengukur kinerja model klasifikasi (Pradana et al., 2022). Salah satu *performance metrics* paling umum digunakan yaitu akurasi yang dihitung menggunakan persamaan (4).

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}. \quad (4)$$

dengan TP, TN, FP, dan FN merupakan komponen dari *confusion matrix*.

3 METODE PENELITIAN

Metode yang digunakan pada penelitian ini adalah ekstraksi fitur menggunakan MAFRBM dan klasifikasi menggunakan SVM dengan diagram alir penelitian ditunjukkan oleh Gambar 4.

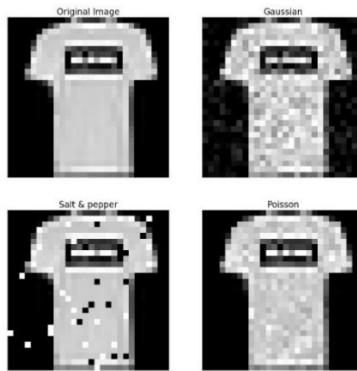


Gambar 4. Diagram Alir Penelitian

4 HASIL DAN PEMBAHASAN

4.1 Penambahan *Noise* pada *Fashion-MNIST*

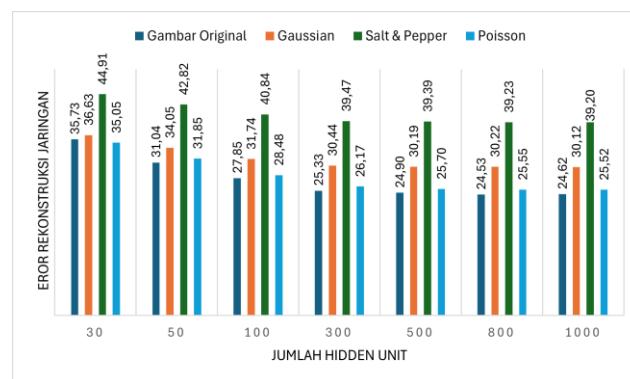
Pada dataset *Fashion-MNIST* ditambahkan tiga macam *noise* yang berbeda yaitu *gaussian*, *salt & pepper*, dan *poisson* dengan bantuan *library Skimage* di *Python*. Sampel gambar dengan dan tanpa *noise* dapat dilihat pada Gambar 5.



Gambar 5. *Fashion-MNIST* dengan dan tanpa *Noise*

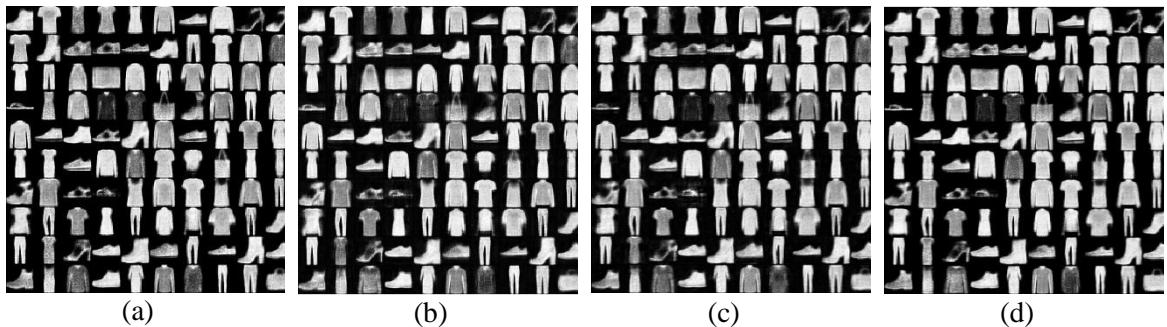
4.2 Hasil Ekstraksi fitur MAFRBm

Ekstraksi fitur MAFRBm menggunakan beberapa jumlah unit tersembunyi yang berbeda yaitu 30, 50, 100, 300, 500, 800, 1000. Error rekonstruksi jaringan dari hasil ekstraksi fitur gambar dengan dan tanpa *noise* dapat dilihat pada Gambar 6.



Gambar 6. Error Rekonstruksi Jaringan

Pada Gambar 6 menunjukkan nilai error rekonstruksi jaringan terkecil diperoleh dari ekstraksi fitur pada gambar original disetiap jumlah unit tersembunyi. Selain itu, hasil rekonstruksi gambar ditunjukkan pada Gambar 7.



Gambar 7. Rekonstruksi Fashion-MNIST (a) Gambar original

(b) Gaussian (c) Salt & pepper (d) Poisson

Gambar 7 menunjukkan bahwa hasil rekonstruksi gambar dapat menyerupai gambar aslinya. Hal ini membuktikan bahwa MAFRBM berhasil mengekstrak fitur dengan baik pada gambar *fashion-MNIST* yang ditambahkan *noise* maupun tidak.

4.3 Evaluasi model SVM

SVM dilatih dengan data latih hasil ekstraksi fitur menggunakan *hyperparameter* $C = 10$ dan $\lambda = 0,01$. Akurasi dari klasifikasi data uji hasil ekstraksi fitur dengan model SVM ditunjukkan pada Tabel 3.

Tabel 3. Akurasi model SVM dari ekstraksi fitur MAFRBM

n	Akurasi			
	Gambar Original	Gaussian	Salt & pepper	Poisson
30	73,1%	77,4%	77,5%	75,6%
50	81,9%	81,2%	81,1%	81,3%
100	85,5%	85,0%	84,9%	85,5%
300	88,0%	86,8%	86,6%	88,1%
500	88,2%	86,8%	86,8%	88,0%
800	87,9%	86,7%	87,1%	88,2%
1000	87,9%	86,8%	86,7%	88,0%

Tabel 3 menunjukkan nilai akurasi terbesar sebesar 88,2%, sedangkan terkecil sebesar 73,1%. Selain itu, dapat dilihat bahwa akurasi dari hasil ekstraksi fitur gambar dengan dan tanpa *noise* tidak jauh berbeda. Hal ini menunjukkan bahwa MAFRBM *robust* dalam mengekstrak fitur yang terdapat *noise* didalamnya.

Sementara itu, hasil klasifikasi ini juga menunjukkan bahwa SVM tidak dapat mengklasifikasikan dengan baik pada kelas *T-shirt*, *Pullover*, *Coat*, *Shirt*. Hal ini terjadi kemungkinan dikarenakan antara kelas tersebut memiliki bentuk gambar yang relatif sama, sehingga fitur yang berhasil diekstrak juga relatif sama. Hal ini mengakibatkan model lebih cenderung mengklasifikasikan pada salah satu kelas saja.

5 SIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat disimpulkan bahwa MAFRBM dapat mengekstrak fitur pada *fashion-MNIST* tanpa *noise* maupun dengan *noise*. Selain itu, akurasi tertinggi yang dapat dicapai pada klasifikasi data latih sebesar 88,2%. Penelitian selanjutnya disarankan melakukan *hyperparameter tuning* untuk mendapatkan model SVM yang lebih optimal.

DAFTAR PUSTAKA

Alamsyah, D., & Pratama, D. (2019). Deteksi Ujung Jari menggunakan Faster-RCNN dengan Arsitektur Inception v2 pada Citra Derau. *JuSiTik : Jurnal Sistem Dan Teknologi Informasi Komunikasi*, 2(1), 1.

Deng, N., Tian, Y., & Zhang, C. (2012). *Support Vector Machines: Optimization Based Theory, Algorithms, and Extensions* (1st ed.). Chapman & Hall/CRC.

Diantarakita, Widodo, A. W., & Rahman, M. A. (2019). Ekstraksi Ciri pada Klasifikasi Tipe Kulit Wajah Menggunakan Metode Local Binary Pattern. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 3(8), 7938–7945.

Feng, S., & Chen, C. L. P. (2018). A Fuzzy Restricted Boltzmann Machine: Novel Learning Algorithms Based on the Crisp Possibilistic Mean Value of Fuzzy Numbers. *IEEE Transactions on Fuzzy Systems*, 26(1), 117–130. <https://doi.org/10.1109/TFUZZ.2016.2639064>

Lü, X., Long, L., Deng, R., & Meng, R. (2022). Image feature extraction based on fuzzy restricted Boltzmann machine. *Measurement*, 204(52075316), 112063. <https://doi.org/10.1016/j.measurement.2022.112063>

Pradana, Z. H., Nafi'ah, H., & Rochmanto, R. A. (2022). *Chatbot-based Information Service using RASA Open-Source Framework in Prambanan Temple Tourism Object*. <https://api.semanticscholar.org/CorpusID:252026904>

Prayogi, M. D., & Nababan, A. A. (2021). Implementasi Reduksi Noise Pada Citra Rontgen Menggunakan Algoritma Arithmetic Mean Filter. *Jurnal Ilmu Komputer Dan Sistem Informasi*, 3(3), 84–90.

Priyowidodo, S. (2019). Klasifikasi Gambar Dataset Fashion-Mnist Menggunakan Deep Convolutional Neural Network. *Jitekh*, 7(1), 34–38.

Purbolaksono, M. D., Irvan Tantowi, M., Imam Hidayat, A., & Adiwijaya, A. (2021). Perbandingan Support Vector Machine dan Modified Balanced Random Forest dalam Deteksi Pasien Penyakit Diabetes. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(2), 393–399. <https://doi.org/10.29207/resti.v5i2.3008>

Puspitasari, N., Septiarini, A., & Aliudin, A. R. (2023). Metode K-Nearest Neighbor Dan Fitur Warna Untuk Klasifikasi Daun Sirih Berdasarkan Citra Digital. *PROSISKO: Jurnal Pengembangan Riset Dan Observasi Sistem Komputer*, 10(2), 165–172. <https://doi.org/10.30656/prosisko.v10i2.6924>

Reddy, M. A., Krishna, G. S. S. R., & Kumar, T. T. (2021). Malaria Cell-Image Classification using InceptionV3 and SVM. *International Journal of Engineering Research & Technology (Ijert)*, 10(8), 6–10.

Taye, M. M. (2023). Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. In *Computers* (Vol. 12, Issue 5). <https://doi.org/10.3390/computers12050091>

Wang, P., Fan, E., & Wang, P. (2021). Comparative analysis of image classification algorithms based on traditional machine learning and deep learning. *Pattern Recognition Letters*, 141, 61–67. <https://doi.org/https://doi.org/10.1016/j.patrec.2020.07.042>