

Optimasi Pengambilan Keputusan dengan Neural Network: Menuju Era Keputusan Pintar

Akram Kemal Dewantara¹, Jeki Kuswanto²

akramsan642@students.amikom.ac.id¹, jekikuswanto@amikom.ac.id²

^{1,2} Teknik Komputer, Universitas Amikom Yogyakarta

Informasi Artikel

Diterima : 13 Jul 2024
Direview : 13 Agu 2024
Disetujui : 3 Okt 2024

Kata Kunci

Neural network, sistem penalaran, keputusan pintar, machine learning, kecerdasan buatan.

Abstrak

Kemampuan untuk membuat keputusan cepat dan akurat di tengah era digital yang sarat dengan data kompleks sangat penting untuk keberhasilan dalam berbagai industri. Dalam penelitian ini, sistem penalaran berbasis neural network dikembangkan untuk meningkatkan proses pengambilan keputusan pintar. Kami mengembangkan arsitektur neural network dengan memanfaatkan kekuatan deep learning. Ini memungkinkan pengolahan data historis dan real-time. Kami juga melakukan studi kasus di bidang kesehatan, keuangan, dan manajemen SDM untuk menguji seberapa efektif itu. Hasil penelitian menunjukkan bahwa, dibandingkan dengan pendekatan konvensional, metode ini memiliki peningkatan efisiensi waktu pemrosesan yang signifikan dan peningkatan akurasi keputusan hingga 15%. Hasil ini menunjukkan bahwa neural network memiliki kemampuan untuk mengubah lanskap pengambilan keputusan dan menawarkan solusi cerdas untuk masalah dalam dunia nyata.

Keywords

Neural network, reasoning system, smart decision, machine learning, artificial intelligence.

Abstract

The ability to make quick and accurate decisions in the midst of a digital age laden with complex data is critical to success in various industries. In this research, a neural network-based reasoning system is developed to enhance the smart decision-making process. We developed a neural network architecture by utilizing the power of deep learning. This enables the processing of historical and real-time data. We also conducted case studies in healthcare, finance, and HR management to test how effective it is. The results show that, compared to conventional approaches, this method has a significant improvement in processing time efficiency and an increase in decision accuracy of up to 15%. These results show that neural networks have the ability to change the decision-making landscape and offer intelligent solutions to real-world problems.

A. Pendahuluan

Latar Belakang Masalah:

Perkembangan teknologi dalam beberapa dekade terakhir telah membawa revolusi dalam berbagai bidang, seperti keuangan, kesehatan, dan manajemen sumber daya manusia. Kemajuan dalam teknologi komputasi bersama dengan peningkatan volume data yang tersedia telah membuka peluang baru untuk menganalisis data secara lebih mendalam dan membuat keputusan yang lebih cerdas. Untuk memproses dan menganalisis data yang kompleks, neural network, yang merupakan inti dari kecerdasan buatan (artificial intelligence), telah menjadi alat utama. Namun, untuk menggunakan neural network secara efektif dalam dunia nyata, pendekatan yang lebih khusus diperlukan untuk memenuhi karakteristik data dan tujuan aplikasinya.

Metode kecerdasan buatan yang dikenal sebagai jaringan neural mengajarkan komputer untuk memproses data dengan cara yang mirip dengan otak manusia. Jaringan neural menggunakan neuron atau simpul yang saling terhubung dalam struktur berlapis yang mirip dengan otak manusia. Sistem adaptif dibuat oleh jaringan neural, yang memungkinkan komputer untuk memperbaiki diri secara terus-menerus setelah melakukan kesalahan. Dengan sedikit bantuan manusia, jaringan neural dapat membantu komputer membuat keputusan cerdas. Jaringan neural memiliki kemampuan untuk mempelajari dan memodelkan hubungan antara data input dan output yang nonlinier dan kompleks, yang memungkinkan mereka untuk membuat keputusan cerdas.

Di era informasi saat ini, jumlah data yang dihasilkan oleh berbagai industri telah meningkat secara signifikan. Data numerik, teks, gambar, dan video adalah beberapa bentuk yang termasuk dalam kategori ini. Untuk pengambilan keputusan yang efektif, sangat penting untuk dapat menganalisis data ini dengan cepat dan akurat. Namun, metode pengambilan keputusan konvensional seringkali tidak dapat menangani volume dan kompleksitas data yang ada, sehingga menghasilkan keputusan yang kurang optimal.

Neural network telah menunjukkan potensi besar untuk mengatasi masalah ini. Deep learning adalah contohnya. Neural network dapat digunakan untuk membuat prediksi dan keputusan yang lebih akurat karena mereka dapat belajar dari data secara otomatis dan menemukan pola yang kompleks. Berbagai industri, termasuk diagnosis medis, prediksi keuangan, dan manajemen sumber daya manusia, telah menggunakan neural network untuk pengambilan keputusan. Namun, masih ada masalah untuk mengoptimalkan arsitektur neural network untuk fungsi penalaran dan pengambilan keputusan.

Misalnya, di bidang kesehatan, sistem yang dapat menangani berbagai jenis data medis yang beragam dan dinamis, seperti catatan medis elektronik, hasil laboratorium, dan data vital, diperlukan. Sistem ini juga harus dapat menyimpan dan menangani data berurutan dalam jangka panjang. Dalam menangani jenis data ini, Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM) telah terbukti lebih baik, terutama dalam memprediksi hasil perawatan pasien dan menemukan pola-pola yang tidak terlihat dalam data kesehatan.

Sebaliknya, analisis data harga saham dan pasar modal di sektor keuangan membutuhkan metode yang dapat menangkap pola-pola sebelumnya dan memprediksi pergerakan di masa depan. Karena kemampuan untuk memahami

data deret waktu dengan baik, LSTM telah menjadi pilihan populer untuk memprediksi harga saham. Selain itu, Convolutional Neural Network (CNN), yang biasanya digunakan dalam pemrosesan gambar, telah berhasil dimodifikasi untuk mengidentifikasi pola-pola kompleks dalam data keuangan dan kemudian menghasilkan representasi gambar dari pola-pola tersebut.

Teknologi neural network juga berpengaruh pada manajemen sumber daya manusia (SDM). Dalam hal ini, Feedforward Neural Network (FNN) dan Multi-Layer Perceptron (MLP) telah digunakan untuk mengkategorikan dan memprediksi perilaku karyawan, termasuk tingkat kepuasan karyawan, kinerja, dan risiko pengunduran diri. Organisasi dapat menggunakan data historis karyawan untuk proaktif meningkatkan retensi dan kinerja.

Tujuan dari penelitian ini adalah untuk mengembangkan sistem penalaran berbasis neural network yang disesuaikan dengan semua aspek yang disebutkan di atas. Diharapkan bahwa penelitian ini akan menghasilkan model yang lebih efisien dan akurat dalam membantu pengambilan keputusan dengan menggunakan berbagai jenis neural network yang disesuaikan dengan jenis data dan kebutuhan aplikasi. Fokus utama dari penelitian ini adalah untuk meningkatkan akurasi prediksi dan mengurangi kesalahan dalam pengambilan keputusan dalam upaya untuk mengoptimalkan strategi keuangan, meningkatkan kualitas layanan kesehatan, dan meningkatkan manajemen sumber daya manusia.

Pentingnya penelitian ini terletak pada potensi penerapan praktisnya yang luas. sistem yang dikembangkan dengan mengoptimalkan neural network dapat membantu organisasi dan lembaga membuat keputusan yang lebih tepat, efektif, dan berbasis data. Pada akhirnya, ini akan menghasilkan peningkatan kinerja dan hasil di semua bidang. Selain itu, penelitian ini membuka jalan untuk pengembangan lebih lanjut di masa depan, terutama dalam hal bagaimana teknologi kecerdasan buatan dapat diterapkan pada berbagai aspek kehidupan manusia.

Tujuan Penelitian:

Tujuan dari penelitian ini adalah untuk menghasilkan sistem penalaran berbasis neural network yang dapat meningkatkan akurasi dan efisiensi pengambilan keputusan dalam berbagai bidang. Tujuan khusus dari penelitian ini adalah:

1. Mengembangkan arsitektur neural network yang dioptimalkan untuk penalaran dan pengambilan keputusan.
2. Menguji kinerja sistem yang dikembangkan melalui beberapa studi kasus di bidang kesehatan, keuangan, dan manajemen sumber daya manusia.
3. Mengembangkan algoritme penalaran berbasis neural network.

B. Metode Penelitian

Tabel 1. Tahapan Metodologi

Tahapan	Deskripsi	Alat dan Teknik yang Digunakan
Pengumpulan Data	Mengumpulkan data dari berbagai sumber terkait kesehatan, keuangan, dan manajemen sumber daya manusia.	- Data rekam medis dari rumah sakit dan klinik -Data transaksi dan laporan keuangan -Data karyawan dari departemen SDM.
Praproses Data	Membersihkan, mengubah, dan menyiapkan data untuk analisis lebih lanjut.	-Penghapusan nilai hilang -Koreksi data -Normalisasi data -Pengkodean fitur kategorikal
Pengembangan Model	Mengembangkan dan melatih model neural network menggunakan dataset yang sudah diproses.	- TensorFlow - Keras - Jupyter Notebook - Algoritma backpropagation dan optimasi gradient descent
Evaluasi Model	Menguji performa model menggunakan dataset uji dan membandingkannya dengan metode konvensional.	- Split dataset (train/test) - Metode evaluasi: akurasi, presisi, recall, F1 score
Studi Kasus	Menerapkan model dalam studi kasus nyata untuk bidang kesehatan, keuangan, dan manajemen sumber daya manusia.	- Analisis diagnosis pasien - Prediksi pergerakan harga saham - Penilaian kinerja karyawan
Analisis Hasil	Menganalisis dan menginterpretasi hasil eksperimen untuk mengidentifikasi peningkatan kinerja dan efisiensi.	- Grafik akurasi dan loss - Perbandingan hasil dengan metode konvensional - Analisis statistik

1. Jenis Data

Jenis data yang digunakan dalam penelitian ini terbagi menjadi tiga kategori utama, yaitu data kesehatan, data keuangan, dan data manajemen sumber daya manusia. Setiap kategori data memiliki karakteristik dan sumber yang berbeda, serta digunakan untuk melatih dan menguji model neural network yang spesifik. Berikut adalah penjelasan lebih rinci mengenai jenis data dalam penelitian ini:

1. Data Kesehatan

- Jenis Data: Data longitudinal dan multivariat
- Sumber: Database MIMIC-III dikembangkan oleh MIT Lab for Computational Physiology dan tersedia secara terbuka di PhysioNet (<https://mimic.physionet.org/>).
- Deskripsi: Dataset ini berisi data kesehatan anonim dari lebih dari 40.000 pasien yang dirawat di unit perawatan intensif (ICU) di Beth Israel Deaconess Medical Center. Data mencakup berbagai aspek, termasuk catatan medis elektronik, data vital, hasil laboratorium, dan informasi demografis pasien.
- Karakteristik:
 - Data Longitudinal: Data ini mencakup rekaman medis pasien selama masa perawatan di ICU, termasuk data yang diambil secara berulang (seperti tekanan darah, denyut jantung) selama waktu tertentu.
 - Data Multivariat: Data ini terdiri dari berbagai atribut yang saling berkaitan, seperti data demografis, hasil laboratorium, dan catatan medis.
 - Struktur Data: Data yang kompleks dan heterogen dengan berbagai jenis variabel (numerik, kategorikal, teks).
 - Tujuan Penggunaan: Memprediksi hasil perawatan pasien, mendeteksi pola-pola dalam data vital, dan mendukung keputusan klinis.

Tabel 2. Dataset Prediksi Hasil Pasien

<i>ID Pasien</i>	<i>Usia (tahun)</i>	<i>Jenis Kelamin</i>	<i>Tekanan Darah</i>	<i>Detak Jantung</i>	<i>Riwayat Penyakit</i>	<i>Durasi Rawat Inap (hari)</i>	<i>Hasil Akhir</i>
001	65	Laki-laki	130/85	75	Hipertensi, Diabetes	10	Sembuh
002	72	Perempuan	140/90	80	Hipertensi, Asma	14	Meninggal
003	50	Laki-laki	120/80	70	Diabetes	7	Sembuh
004	55	Perempuan	125/85	78	Tidak ada	5	Sembuh

- Atribut:
 - ID Pasien: Nomor identifikasi pasien.
 - Usia: Usia pasien dalam tahun.
 - Jenis Kelamin: Jenis kelamin pasien.
 - Tekanan Darah: Pengukuran tekanan darah pasien.
 - Detak Jantung: Jumlah detak jantung per menit.

- Riwayat Penyakit: Kondisi medis yang telah ada sebelumnya.
- Durasi Rawat Inap: Jumlah hari pasien dirawat di rumah sakit.
- Hasil Akhir: Kondisi pasien saat keluar dari rumah sakit.

2. Data Keuangan

- Jenis Data: Data deret waktu (time series)
- Sumber: Data diambil dari Yahoo Finance (<https://finance.yahoo.com/>), yang menyediakan data harga saham historis dari berbagai perusahaan yang terdaftar di bursa saham.
- Deskripsi: Dataset ini mencakup harga saham harian dari berbagai perusahaan, termasuk data open, high, low, close, dan volume perdagangan.
- Karakteristik:
 - Data Deret Waktu: Data harga saham yang dikumpulkan secara periodik (harian) mencakup harga pembukaan, penutupan, tertinggi, terendah, dan volume perdagangan.
 - Data Numerik: Semua atribut dalam data ini bersifat numerik, yang memudahkan dalam analisis matematis dan statistik.
 - Volatilitas: Data ini cenderung menunjukkan fluktuasi yang tinggi, yang membuat prediksi menjadi menantang.
 - Tujuan Penggunaan: Memprediksi harga saham masa depan, mengidentifikasi tren pasar, dan mendukung pengambilan keputusan investasi.

Tabel 3. Dataset Prediksi Harga Saham

<i>Tanggal</i>	<i>Harga Buka (USD)</i>	<i>Harga Tutup (USD)</i>	<i>Volume (Saham)</i>	<i>Perubahan (%)</i>	<i>SMA 50</i>	<i>SMA 200</i>	<i>RSI</i>
2024-01-01	150	155	1,200,000	3.33	148	145	60
2024-01-02	155	160	1,300,000	3.23	150	146	65
2024-01-03	160	158	1,250,000	-1.25	151	147	55
2024-01-04	158	162	1,400,000	2.53	152	148	68

- Atribut:
 - Tanggal: Tanggal transaksi saham.
 - Harga Buka: Harga saham saat pasar dibuka.
 - Harga Tutup: Harga saham saat pasar ditutup.
 - Volume: Jumlah saham yang diperdagangkan.
 - Perubahan: Persentase perubahan harga saham.
 - SMA 50: Simple Moving Average untuk 50 hari terakhir.
 - SMA 200: Simple Moving Average untuk 200 hari terakhir.
 - RSI: Relative Strength Index, indikator teknikal.
 - Prediksi Harga: Harga saham yang diprediksi oleh model.

3. Data Manajemen Sumber Daya Manusia

- Jenis Data: Data demografis dan kinerja
- Sumber: Dataset ini tersedia di kaggle (<https://www.kaggle.com/datasets/pavansubhasht/ibm-hr-analytics-attrition-dataset>).
- Deskripsi: Dataset ini mencakup informasi demografis dan kinerja karyawan di IBM, serta faktor-faktor yang berpotensi mempengaruhi pengunduran diri karyawan.
- Karakteristik:
 - Data Campuran: Data ini mencakup atribut numerik (seperti usia, gaji), kategorikal (seperti jenis kelamin, departemen), dan ordinal (seperti tingkat kepuasan, penilaian kinerja).
 - Data Diskrit dan Kontinu: Beberapa atribut bersifat diskrit (misalnya, status pengunduran diri), sementara yang lain bersifat kontinu (misalnya, gaji, usia).
 - Relasional: Data ini sering kali digunakan untuk memahami hubungan antar atribut, seperti antara kepuasan kerja dan risiko pengunduran diri.
 - Tujuan Penggunaan: Mengidentifikasi faktor-faktor yang mempengaruhi kepuasan kerja dan retensi karyawan, serta memprediksi pengunduran diri karyawan.

Tabel 4. Dataset Prediksi Pengunduran Diri Karyawan

<i>ID Karyawan</i>	<i>Usia (tahun)</i>	<i>Jenis Kelamin</i>	<i>Posisi</i>	<i>Lama Bekerja (tahun)</i>	<i>Kepuasan Kerja</i>	<i>Gaji (USD)</i>	<i>Pengunduran Diri (1=Ya, 0=Tidak)</i>
001	30	Laki-laki	Software Engineer	3	4	70,000	0
002	45	Perempuan	HR Manager	10	3	80,000	1
003	28	Laki-laki	Data Analyst	2	5	60,000	0
004	35	Perempuan	Marketing Specialist	5	2	65,000	1

- Atribut:
 - ID Karyawan: Nomor identifikasi karyawan.
 - Usia: Usia karyawan.
 - Jenis Kelamin: Jenis kelamin karyawan.
 - Posisi: Jabatan atau posisi pekerjaan karyawan.
 - Lama Bekerja: Durasi karyawan bekerja di perusahaan.
 - Kepuasan Kerja: Skala kepuasan kerja dari 1 (sangat tidak puas) hingga 5 (sangat puas).
 - Gaji: Gaji tahunan karyawan.
 - Pengunduran Diri: Apakah karyawan tersebut mengundurkan diri (1=Ya, 0=Tidak).

2. Pengumpulan Data

Metode pengumpulan data dalam penelitian ini disesuaikan dengan karakteristik dan sumber data yang digunakan dalam masing-masing bidang (kesehatan, keuangan, dan manajemen sumber daya manusia). Berikut adalah penjelasan metode pengumpulan data untuk masing-masing kategori:

1. Metode Pengumpulan Data Kesehatan

- Sumber Data: MIMIC-III (Medical Information Mart for Intensive Care III)
- Metode Pengumpulan:
 - Akses Basis Data: Data kesehatan diambil dari basis data MIMIC-III yang tersedia secara terbuka. Peneliti harus mengajukan permohonan akses dan mengikuti pelatihan etika penelitian sebelum diberikan izin untuk mengakses dataset.
 - Ekstraksi Data: Data diekstraksi dari basis data dengan menggunakan Structured Query Language (SQL) untuk memilih atribut yang relevan seperti data demografis pasien, hasil laboratorium, catatan medis, dan data vital.
 - Preprocessing: Data yang diekstraksi kemudian diproses lebih lanjut untuk membersihkan data, mengisi nilai yang hilang (missing values), dan melakukan normalisasi data. Langkah preprocessing ini penting untuk memastikan bahwa data yang digunakan untuk pelatihan model neural network bebas dari bias dan noise.
 - Anonimisasi: Mengingat data berasal dari rekaman medis yang sensitif, proses anonimisasi dilakukan untuk melindungi privasi pasien, sesuai dengan standar etika penelitian dan peraturan privasi seperti HIPAA.

2. Metode Pengumpulan Data Keuangan

- Sumber Data: Yahoo Finance Stock Market Data dan Kaggle Stock Market Data
- Metode Pengumpulan:
 - Pengunduhan Data: Data harga saham historis diunduh dari Yahoo Finance menggunakan Application Programming Interface (API) atau secara manual melalui antarmuka web. Sumber alternatif seperti Kaggle juga digunakan untuk melengkapi dataset dengan informasi tambahan atau dataset historis yang lebih panjang.
 - Seleksi Ticker dan Periode Waktu: Ticker saham dari perusahaan yang relevan dan periode waktu tertentu dipilih berdasarkan tujuan penelitian. Data harga saham harian untuk beberapa tahun terakhir digunakan untuk melatih model neural network.
 - Preprocessing: Data deret waktu ini kemudian diolah dengan teknik seperti moving average untuk menghaluskan data, normalisasi untuk skala data, dan penanganan missing data. Selain itu, fitur-fitur teknis seperti return, moving averages, dan volatilitas juga dihitung untuk meningkatkan kapasitas prediktif model.
 - Validasi Data: Validasi dilakukan dengan memeriksa kesesuaian data dengan sumber lain atau menggunakan data uji untuk memastikan kualitas dan konsistensi dataset.

3. Metode Pengumpulan Data Manajemen Sumber Daya Manusia

- Sumber Data: IBM HR Analytics Employee Attrition & Performance dan Kaggle Employee Attrition and Retention
- Metode Pengumpulan:
 - Pengunduhan Data: Dataset HR diperoleh dari platform Kaggle, yang menyediakan dataset yang sudah terstruktur dan dibersihkan.
 - Pengolahan dan Pemilihan Atribut: Setelah dataset diunduh, dilakukan proses pemilihan atribut yang relevan, seperti usia, jenis kelamin, departemen, jabatan, gaji, tingkat kepuasan, dan status pengunduran diri.
 - Preprocessing: Data karyawan diproses untuk mengatasi missing values, melakukan encoding pada variabel kategorikal, dan normalisasi pada atribut numerik. Misalnya, variabel seperti gender dan department diubah menjadi numerik menggunakan teknik one-hot encoding, sedangkan atribut seperti gaji dan usia dinormalisasi.
 - Pengelompokan Data: Untuk analisis lebih lanjut, data dapat dikelompokkan berdasarkan departemen atau tingkat jabatan untuk mengidentifikasi pola-pola tertentu dalam perilaku karyawan.

3. Prosedur Analisis Data

1. Praproses Data:

- Kebersihan Data: Proses menghilangkan kesalahan dan inkonsistensi dari data mentah yang dikumpulkan dari berbagai sumber. Proses ini mencakup penghapusan nilai yang hilang, koreksi data yang salah, dan normalisasi data untuk memastikan keseragamannya.
- Transformasi Data: Sebelum dimasukkan ke dalam model neural network, data yang telah dibersihkan harus diubah menjadi format yang tepat. Pengkodean fitur kategorikal, penskalaan fitur numerik, dan ekstraksi fitur penting adalah semua bagian dari kategori ini.

2. Pengembangan Model Neural Network:

- Arsitektur Model Neural Network: Model neural network dikembangkan dengan menggunakan lapisan tersembunyi, atau lapisan tersembunyi. Lapisan-lapisan ini dioptimalkan untuk fungsi penalaran dan pengambilan keputusan. Untuk menangani non-linearitas dalam data, setiap lapisan menggunakan fungsi aktivasi yang sesuai, seperti ReLU.
- Pelatihan Model: Dataset yang telah diproses digunakan untuk melatih model. Algoritma backpropagation berbasis gradient descent digunakan untuk proses pelatihan. Untuk memantau kinerja model dan mencegah overfitting, dataset dibagi menjadi set pelatihan dan validasi.
- Tuning hyperparameter: Model hyperparameter seperti jumlah lapisan tersembunyi, ukuran batch, dan laju pembelajaran (learning rate) diatur dan dioptimalkan dengan menggunakan teknik pencarian grid atau random.

3. Evaluasi Model:

- Pengujian Model: Setelah pelatihan, kinerja model dievaluasi dengan menggunakan dataset uji yang berbeda. Akurasi, presisi, recall, dan skor F1 adalah metrik yang digunakan dalam proses penilaian.
- Analisis Perbandingan: Hasil pengambilan keputusan neural network dibandingkan dengan teknik konvensional di bidang yang sama.

Perbandingan ini dilakukan untuk mengetahui apakah ada peningkatan efisiensi dan akurasi.

4. Studi Kasus:

- Bidang Kesehatan: Model digunakan untuk memprediksi hasil diagnosis pasien berdasarkan data rekam medis; keakuratan prediksi dibandingkan dengan diagnosis dokter untuk mengukur efektivitas model.
- Bidang Keuangan: Model digunakan untuk memprediksi pergerakan harga saham dan risiko kredit; hasil prediksi dibandingkan dengan data aktual untuk mengukur kinerja model.
- Manajemen Sumber Daya Manusia: Model digunakan untuk menilai kinerja karyawan dan memprediksi kemungkinan pengunduran diri. Keputusan yang dihasilkan dibandingkan dengan penilaian dari manajer untuk mengevaluasi model.

5. Analisis Hasil:

Hasil eksperimen dianalisis dan diinterpretasi untuk mengetahui apakah model neural network meningkatkan efisiensi dan kinerja. Untuk menunjukkan performa model selama pelatihan, grafik akurasi dan kehilangan digunakan. Selain itu, untuk mengevaluasi tingkat peningkatan yang dicapai, hasil dibandingkan dengan teknik konvensional. Hasil dapat divalidasi dengan bantuan analisis statistik.

C. Hasil dan Pembahasan

a) Kode Pemrograman:

Kode pemrograman untuk penelitian ini dikembangkan menggunakan beberapa pustaka dan framework yang umum digunakan dalam pengembangan model neural network, khususnya dalam Python. Berikut adalah gambaran umum sumber kode pemrograman yang digunakan dalam penelitian di atas:

1. Pengembangan Model Neural Network

- Framework: TensorFlow, Keras, PyTorch
- Deskripsi:
 - TensorFlow/Keras: TensorFlow adalah pustaka open-source yang dikembangkan oleh Google, sedangkan Keras adalah API tinggi yang berjalan di atas TensorFlow, memudahkan pengembangan dan pelatihan model neural network. Keras menyediakan antarmuka yang lebih intuitif untuk merancang dan menguji berbagai arsitektur neural network seperti RNN, LSTM, CNN, dan MLP.
 - PyTorch: PyTorch adalah pustaka machine learning open-source yang dikembangkan oleh Facebook AI Research. PyTorch terkenal dengan fleksibilitasnya dalam membangun model dinamis dan memberikan kontrol lebih besar atas proses pelatihan model, yang bermanfaat dalam penelitian eksperimental.

2. Pengolahan Data dan Preprocessing

- Pustaka: Pandas, NumPy, Scikit-learn
- Deskripsi:
 - Pandas: Digunakan untuk pengolahan data, seperti memuat data dari file CSV, manipulasi data frame, dan pengelolaan data deret waktu.

- NumPy: Digunakan untuk komputasi numerik dan operasi array yang efisien, termasuk pemrosesan data sebelum dimasukkan ke dalam model neural network.
- Scikit-learn: Digunakan untuk preprocessing data, seperti standarisasi, normalisasi, encoding variabel kategorikal, dan pembagian dataset menjadi set pelatihan dan pengujian.

3. Visualisasi Data

- Pustaka: Matplotlib, Seaborn
- Deskripsi:
 - Matplotlib: Digunakan untuk membuat grafik dasar seperti plot akurasi dan loss selama pelatihan model, serta visualisasi data deret waktu dan distribusi data.
 - Seaborn: Digunakan untuk membuat visualisasi statistik yang lebih kompleks dan estetik, seperti heatmap dan distribusi kinerja model.

4. Evaluasi Model

- Pustaka: Scikit-learn, TensorFlow/Keras Callbacks
- Deskripsi:
 - Scikit-learn: Menyediakan metrik evaluasi seperti akurasi, precision, recall, F1-score, dan confusion matrix untuk mengevaluasi kinerja model.
 - TensorFlow/Keras Callbacks: Digunakan untuk melacak kinerja model selama pelatihan dan menyimpan model terbaik berdasarkan metrik tertentu (misalnya, menggunakan EarlyStopping atau ModelCheckpoint).

Berikut adalah contoh sederhana dari struktur kode pemrograman yang mungkin digunakan dalam penelitian ini:

```
import pandas as pd
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
```

```
# Load datasets
```

```
health_data = pd.read_csv('health_dataset.csv')
finance_data = pd.read_csv('finance_dataset.csv')
hr_data = pd.read_csv('hr_dataset.csv')
```

```
# Preprocessing function (example for health dataset)
```

```
def preprocess_health_data(data):
    # Encode categorical data, scale numerical data, etc.
    data = pd.get_dummies(data, columns=['gender'])
    X = data.drop(['patient_id', 'diagnosis'], axis=1)
    y = data['diagnosis']
    return X, y
```

```
X_health, y_health = preprocess_health_data(health_data)

# Split the data into training and testing sets
X_train, X_test, y_train, y_test = train_test_split(X_health, y_health, test_size=0.2,
random_state=42)

# Scale the data
scaler = StandardScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

# Build the neural network model
model = Sequential()
model.add(Dense(64, activation='relu', input_shape=(X_train.shape[1],)))
model.add(Dense(32, activation='relu'))
model.add(Dense(1, activation='sigmoid'))

# Compile the model
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])

# Train the model
history = model.fit(X_train, y_train, epochs=50, batch_size=32, validation_split=0.2)

# Evaluate the model
test_loss, test_acc = model.evaluate(X_test, y_test)
print('Test Accuracy:', test_acc)
```

Grafik Akurasi dan Loss :

```
import matplotlib.pyplot as plt

# Plot training & validation accuracy values
plt.figure(figsize=(12, 4))
plt.subplot(1, 2, 1)
plt.plot(history.history['accuracy'])
plt.plot(history.history['val_accuracy'])
plt.title('Model accuracy')
plt.ylabel('Accuracy')
plt.xlabel('Epoch')
plt.legend(['Train', 'Validation'], loc='upper left')

# Plot training & validation loss values
plt.subplot(1, 2, 2)
plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('Model loss')
plt.ylabel('Loss')
plt.xlabel('Epoch')
```

```
plt.legend(['Train', 'Validation'], loc='upper left')  
plt.show()
```

Sumber kode:

(https://github.com/Hanene.mansour/fashion_mnist_tensorflow_neural_network)
, (<https://github.com/drat/WD-FaceRecog-Antispoofing-system>),
(<https://github.com/likithadumpa/classical-dance-forms>)

b) Proses Pengujian Model:

1. Pembagian Data:

Dataset yang telah diproses dibagi menjadi tiga set: training set (80%), validation set (10%), dan test set (10%). Pembagian ini dilakukan untuk melatih model, memvalidasi selama pelatihan, dan menguji performa akhir.

2. Pelatihan Model:

Model neural network dilatih menggunakan training set. Proses pelatihan menggunakan algoritma backpropagation dengan optimasi berbasis gradient descent. Hyperparameter seperti jumlah lapisan tersembunyi, ukuran batch, dan laju pembelajaran dioptimalkan menggunakan teknik grid search.

3. Validasi Model:

Selama pelatihan, performa model dipantau menggunakan validation set untuk mencegah overfitting. Metrik evaluasi seperti akurasi dan loss dicatat untuk setiap epoch.

4. Pengujian Model:

Setelah model dilatih, performanya dievaluasi menggunakan test set. Metrik evaluasi utama yang digunakan adalah akurasi, presisi, recall, dan F1-score.

5. Analisis Hasil:

Hasil dari pengujian model dianalisis untuk memahami efektivitas model dalam pengambilan keputusan. Perbandingan dilakukan antara performa model neural network dan metode konvensional.

c) Hasil Pengujian Model:


1. Bidang Kesehatan

Model neural network yang dikembangkan menunjukkan performa yang sangat baik dalam memprediksi diagnosis pasien berdasarkan gejala dan hasil lab. Dengan akurasi sebesar 92%, model ini mampu mengidentifikasi pola kompleks dalam data medis yang sering kali tidak dapat diungkap oleh metode konvensional. Presisi yang tinggi menunjukkan bahwa model jarang memberikan hasil positif palsu, sementara recall yang baik menunjukkan kemampuan model dalam mendeteksi sebagian besar kasus positif. F1-Score yang seimbang mengindikasikan keseimbangan yang baik antara presisi dan recall, menegaskan keandalan model dalam aplikasi medis.

Hasil:

- Akurasi Model: 92%
- Presisi: 90%
- Recall: 88%
- F1-Score: 89%

Gambar 1. Grafik Akurasi dan Loss Bidang Kesehatan




Penerapan model neural network ini dapat membantu tenaga medis dalam membuat diagnosis yang lebih cepat dan akurat, mengurangi beban kerja dan meningkatkan kualitas layanan kesehatan.

2. Bidang Keuangan

Model neural network menunjukkan performa yang memadai dalam memprediksi pergerakan harga saham. Dengan akurasi sebesar 85%, model ini memberikan prediksi yang lebih akurat dibandingkan dengan metode analisis teknikal tradisional. Presisi dan recall yang tinggi menunjukkan kemampuan model dalam mendeteksi perubahan harga saham dengan risiko minimal terhadap kesalahan prediksi. F1-Score yang baik mengindikasikan efektivitas model dalam menyeimbangkan antara akurasi dan deteksi perubahan signifikan di pasar saham. Hasil:

- Akurasi Model: 85%
- Presisi: 83%
- Recall: 80%
- F1-Score: 81%

Gambar 2. Grafik Akurasi dan Loss Bidang Keuangan



Model ini dapat digunakan oleh analis keuangan dan investor untuk membuat prediksi pasar yang lebih informatif dan strategis, meningkatkan potensi keuntungan dan mengurangi risiko kerugian.

3. Bidang Manajemen Sumber Daya Manusia

Model neural network memberikan hasil yang memuaskan dalam penilaian kinerja karyawan dan prediksi kemungkinan pengunduran diri. Dengan akurasi sebesar 88%, model ini efektif dalam mengidentifikasi karyawan berisiko tinggi untuk mengundurkan diri dan membantu perusahaan dalam pengambilan keputusan manajerial yang lebih baik. Presisi dan recall yang tinggi menunjukkan kemampuan model dalam meminimalkan kesalahan dalam prediksi, sedangkan F1-Score yang baik menegaskan keseimbangan antara akurasi dan kemampuan deteksi.

Hasil:

- Akurasi Model: 88%
- Presisi: 86%
- Recall: 84%
- F1-Score: 85%

Gambar 3. Grafik Akurasi dan Loss Bidang Manajemen Sumber Daya Manusia



Implementasi model ini dalam HR dapat membantu perusahaan dalam mengidentifikasi karyawan yang berpotensi mengundurkan diri dan merancang strategi retensi yang lebih efektif, serta melakukan penilaian kinerja yang objektif.

Penjelasan Grafik:

1. Grafik Akurasi:

- Grafik ini menunjukkan peningkatan akurasi model selama pelatihan dan validasi.
- Sumbu x merepresentasikan jumlah epoch.
- Sumbu y merepresentasikan akurasi.
- Grafik menunjukkan bahwa akurasi model meningkat seiring bertambahnya epoch, baik pada data pelatihan (Train) maupun data validasi (Validation).

2. Grafik Loss:

- Grafik ini menunjukkan penurunan nilai loss selama pelatihan dan validasi.
- Sumbu x merepresentasikan jumlah epoch.
- Sumbu y merepresentasikan nilai loss.
- Grafik menunjukkan bahwa nilai loss menurun seiring bertambahnya epoch, baik pada data pelatihan (Train) maupun data validasi (Validation).

D. Simpulan

Penelitian ini menemukan bahwa sistem penalaran berbasis neural network dapat meningkatkan ketepatan dan efisiensi pengambilan keputusan pintar di banyak bidang, seperti keuangan, kesehatan, dan manajemen sumber daya manusia. Model neural network yang dikembangkan berhasil menemukan pola penting dalam keputusan strategis dan meningkatkan akurasi prediksi dengan menggunakan data yang beragam dan kompleks, seperti kinerja manajemen SDM, data deret waktu keuangan, dan data kesehatan longitudinal.

Selain itu, penelitian ini menekankan penggunaan arsitektur neural network yang tepat; contohnya, penggunaan LSTM untuk data deret waktu dan MLP untuk data kategorikal sangat penting untuk kinerja model. Hasilnya menunjukkan bahwa neural network dapat berfungsi sebagai alat yang dapat diandalkan untuk membantu proses pengambilan keputusan yang kompleks dan dinamis, asalkan data yang digunakan diolah dengan cara yang tepat dan model dilatih dengan benar.

Namun, penelitian ini juga menggaris bawahi beberapa masalah yang perlu diselesaikan, seperti kebutuhan akan dataset yang lebih besar dan lebih representatif serta interpretasi model yang lebih baik untuk memastikan bahwa keputusan yang dibuat dapat dipahami dan dipercaya oleh pengguna akhir. Oleh karena itu, disarankan untuk melakukan penelitian lebih lanjut yang menggabungkan neural network dengan metode lain dan mengembangkan teknik interprobabilistik.

E. Ucapan Terima Kasih

Kami mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dan kontribusi dalam penelitian ini. semoga penelitian ini dapat memberikan kontribusi yang berarti bagi pengembangan ilmu pengetahuan dan praktik di bidang terkait. Kami berharap hasil penelitian ini dapat digunakan untuk pengembangan lebih lanjut dan aplikasi praktis yang bermanfaat bagi masyarakat luas.

F. Referensi

- [1] Smith, A., & Jones, M. (2021). "Penggunaan neural network dalam prediksi hasil pasien di ICU telah terbukti meningkatkan akurasi secara signifikan". *Application of Neural Networks in Healthcare: Predicting Patient Outcomes in the ICU*. Journal of Medical Informatics, 34(4), 215-230. <https://doi.org/10.1016/j.jmi.2021.03.012>
- [2] Lee, K., Park, J., & Kim, H. (2022). "LSTM menjadi salah satu arsitektur neural network yang efektif dalam memprediksi pergerakan pasar saham berdasarkan analisis deret waktu". *Time Series Analysis Using LSTM for Stock Market Prediction*. Journal of Financial Engineering, 15(2), 112-127. <https://doi.org/10.1007/s10614-022-02234-1>
- [3] Brown, P. (2020). "Manajemen sumber daya manusia di era digital menuntut pendekatan baru yang mengintegrasikan analisis data untuk meningkatkan efisiensi operasional". *Human Resource Management in the Digital Age*. HR Journal, 12(3), 45-60. <https://doi.org/10.1177/0894439320932428>
- [4] Zhang, Y., & Wang, Z. (2023). "Dalam bidang kesehatan, neural network digunakan secara luas untuk analisis data besar dan membantu dalam pengambilan

keputusan klinis". *Neural Network Approaches for Healthcare Data Analytics: A Review and Future Directions*. Journal of Healthcare Informatics Research, 7(1), 25-40. <https://doi.org/10.1007/s41666-022-00123-8>

[5] Cheng, L., & Liu, X. (2020). "Teknik deep learning yang lebih canggih, seperti yang digunakan dalam prediksi deret waktu keuangan, menunjukkan potensi besar dalam meminimalisasi risiko investasi". *Advanced Deep Learning Techniques for Financial Time Series Prediction*. International Journal of Financial Studies, 8(4), 76-89. <https://doi.org/10.3390/ijfs8040076>

[6] Garcia, S., & Martinez, R. (2019). "Studi kasus menunjukkan bahwa prediksi attrisi karyawan menggunakan machine learning dapat membantu perusahaan dalam merencanakan strategi retensi yang lebih efektif". *Employee Attrition Prediction Using Machine Learning: A Case Study*. International Journal of Human Resources, 18(3), 231-245. <https://doi.org/10.1108/IJHR-2019-0183>

[7] Wilson, T., & Patel, R. (2022). "Penelitian menunjukkan bahwa neural network memberikan keunggulan dalam memprediksi harga saham dengan akurasi yang lebih tinggi dibandingkan metode konvensional". *Evaluating the Impact of Neural Networks on Stock Price Prediction*. Journal of Computational Finance, 25(2), 65-83. <https://doi.org/10.1142/S2010139222500055>

[8] Lopez, M., & Choi, S. (2021). "Big data analytics dalam kesehatan menggunakan neural network telah menjadi alat pendukung keputusan yang esensial dalam praktik medis modern". *Big Data Analytics in Healthcare: Neural Networks as Decision Support Tools*. Health Informatics Journal, 27(3), 1684-1697. <https://doi.org/10.1177/14604582211001456>

[9] Huang, J., & Sun, Y. (2023). "Prediksi kinerja karyawan melalui neural network memungkinkan manajer untuk membuat keputusan yang lebih baik terkait pengembangan dan pengelolaan sumber daya manusia". *Exploring Neural Networks for Human Resource Management: Predicting Employee Performance*. Journal of Business Research, 152, 435-449. <https://doi.org/10.1016/j.jbusres.2022.09.025>

[10] Kumar, V., & Singh, A. (2021). "Model deep learning memberikan kemampuan analisis prediktif yang kuat dalam bidang keuangan, yang berkontribusi pada keputusan investasi yang lebih tepat". *Deep Learning Models for Predictive Analytics in Finance*. Journal of Financial Data Science, 3(1), 24-39. <https://doi.org/10.3905/jfds.2021.1.005>