

PERAN DEEP LEARNING DAN BIG DATA DALAM MENDEKTEKSI MASALAH KEUANGAN

Dara Sawitri

Prodi Teknik Elektro, Fakultas Teknik Dan Komputer, Universitas Harapan Medan, Indonesia

Article Info	ABSTRACT
Article history: Received: 27 Januari 2025 Revised: 05 Maret 2025 Accepted: 11 Maret 2025	Abstrak Pesatnya pertumbuhan data dan informasi pada saat ini membuat bidang keuangan banyak menghadapi tantangan dalam melakukan analisis informasi. Dengan kemampuan teknologi big data dan deep learning telah mengubah cara-cara operasional dibidang keuangan secara signifikan. Big data merevolusi cara pengelolaan bidang keuangan dengan menggunakan teknologi. Deep learning dan big data telah membantu akan standarisasi dan pemodelan didalam proses keuangan dalam meningkatkan pengambilan keputusan. Kedua teknologi ini mampu memfasilitasi pemrosesan serta analisis data yang lebih mendalam sehingga dapat memberikan pandangan yang lebih luas dalam mendukung proses pengambilan keputusan dibidang keuangan. Peran big data dan deep learning dapat digunakan secara bersama untuk meningkatkan efisiensi dan akurasi analisis data serta memfasilitasi kemampuan analisis agar dapat mendeteksi masalah keuangan untuk kepentingan dunia usaha. Pada penelitian ini merupakan tinjauan literatur, membahas bagaimana deep learning dan big data berperan dalam mendeteksi masalah keuangan, termasuk deteksi penipuan, prediksi kebangkrutan, dan analisis risiko kredit. Tinjauan literatur bertujuan untuk mengeksplorasi bagaimana teknologi diterapkan dalam sektor keuangan menggunakan arsitektur CNN dan RNN dimana model LSTM juga GRU efektif dalam menangani data untuk mendeteksi aktivitas resiko keuangan. Deep learning dapat mengenali anomali secara real-time dengan tingkat keandalan tinggi, mengoptimal keamanan data dan memaksimalkan pengelolaan risiko. Kata Kunci: Big Data, CNN, Deep Learning, Deteksi Masalah Keuangan, RNN. Abstract : <i>The rapid growth of data and information today makes the financial sector face many challenges in analyzing information. With the capabilities of big data and deep learning technology, it has significantly changed the operational methods in the financial sector. Big data revolutionizes the way the financial sector is managed using technology. Deep learning and big data have helped standardize and model in the financial process to improve decision making. Both of these technologies are able to facilitate deeper data processing and analysis so that they can provide a broader view in supporting the decision-making process in the financial sector. The role of big data and deep learning can be used together to improve the efficiency and accuracy of data analysis and facilitate analytical capabilities in order to detect financial problems for the benefit of the business world. This study is a literature review, discussing how deep learning and big data play a role in detecting financial problems, including fraud detection, bankruptcy prediction, and credit risk analysis. The literature review aims to explore how technology is applied in the financial sector using CNN and RNN architectures where LSTM and GRU models are effective in handling data to detect financial risk activities. Deep learning can recognize anomalies in real-time with a high level of reliability, optimize data security and maximize risk management.</i> Keywords: Big Data, CNN, Deep Learning, Financial Problem Detection, RNN. Djtechno: Jurnal Teknologi Informasi oleh Universitas Dharmawangsa Artikel ini bersifat open access yang didistribusikan di bawah syarat dan ketentuan dengan Lisensi Internasional Creative Commons Attribution NonCommercial ShareAlike 4.0 (CC-BY-NC-SA).



*Corresponding Author:*E-mail : dara.sawitri.24@gmail.com

1. PENDAHULUAN

Dengan semakin lajunya pertumbuhan teknologi digital serta terjadi peningkatan eksponensial pertumbuhan data telah memperbarui industri keuangan, membuka jalan bagi metode yang lebih moderen serta berbasis digital dalam melakukan pendeteksian masalah keuangan. Cara konvensional dalam mengolah data keuangan biasanya melibatkan cara-cara manual. Dalam pemrosesan data, terdapat banyak tugas keuangan yang bersifat sederhana dan berulang, sehingga tidak efisien dalam penggunaan tenaga kerja[1]. Peningkatan volume data dan informasi telah pesat membanjiri infrastruktur penyimpanan sehingga memerlukan adopsi teknologi big data dan deep learning. Penerapan deep learning terhadap permasalahan ini dapat memberikan hasil yang lebih bermanfaat dibandingkan metode standar di bidang keuangan [2]. Data keuangan dapat meliputi pendapatan, pengeluaran, laba, rugi, aset dan lain sebagainya yang terus tumbuh secara dinamis. Sehingga banyaknya volume data yang terus meningkat yang lebih sering dikenal dengan istilah big data, penggunaan istilah “big data” yang pertama kali sering dikutip adalah saat menghadiri diskusi tahunan USENIX konferensi teknis (Mashey 1999) [3]. Hal ini membutuhkan teknologi pengelolaan data yang lebih baik serta efisien berbasis teknologi. Hal ini mengungkapkan bahwa analisis big data sangat penting dalam mendorong inovasi, meningkatkan pengalaman pelanggan, dan meningkatkan efisiensi operasional dalam layanan keuangan [4]. Dalam memanfaatkan big data untuk deteksi masalah keuangan adalah dengan mengintegrasikan dan memproses data dari berbagai sumber. Hal ini melibatkan pembersihan, standarisasi, dan transformasi data ke dalam format yang sesuai untuk analisis[5].

Pertumbuhan volume data secara dinamis menjadi tantangan besar bagi deteksi masalah keuangan terutama dalam mengidentifikasi beberapa masalah potensial, seperti pengelolaan uang yang buruk, bisnis yang merugi, masalah kredit dan lain sebagainya. sehingga teknologi big data dan deep learning hadir sebagai jalan keluar inovatif untuk menganalisis data dalam skala besar, sehingga dapat tanggap terhadap potensi masalah keuangan. Menurut [6] telah muncul sebagai bagian mesin yang kuat. Deep learning beroperasi dengan cara menerapkan jaringan saraf buatan dengan

mempunyai banyak lapisan sehingga dapat memproses pembelajaran yang lebih rumit dan menghasilkan prediksi lebih akurat.

Tinjauan literatur mengenai peran deep learning dan big data untuk masalah keuangan bahwa kedua teknologi ini memiliki potensi besar agar terjadi peningkatan akurasi dan efisiensi dalam berbagai aspek analisis keuangan. Penerapan deep learning bagi sistem agar mampu mengenali pola kompleks dalam data keuangan yang besar dan dinamis, big data memiliki kemampuan untuk pengumpulan, penyimpanan, serta analisis data secara real-time. Masalah spesifik seperti deteksi kecurangan, identifikasi anomali transaksi, prediksi kebangkrutan, analisis sentimen pasar, dan manajemen risiko keuangan, menunjukkan bahwa metode berbasis deep learning lebih baik dibandingkan dengan teknik tradisional. Model recurrent neural networks (RNN), convolutional neural networks (CNN) dapat melakukan pemrosesan data keuangan dalam jumlah besar dengan akurasi yang cukup tinggi. Deteksi masalah keuangan digunakan model convolutional neural networks (CNN) dan recurrent neural networks (RNN). Deteksi masalah keuangan menggunakan model CNN dan RNN memungkinkan sistem untuk mengidentifikasi pola dalam data yang mengarah pada tanda-tanda risiko keuangan. Dimana kedua model ini memiliki cara yang berbeda dalam mendeteksi masalah keuangan. CNN adalah pembelajaran mendalam arsitektur yang menggunakan lapisan konvolusional untuk memetakan data masukan fitur [7]. CNN biasanya diperuntukan untuk data berbentuk gambar namun dapat diterapkan pada data keuangan dengan melakukan pemodelan data dalam bentuk matriks atau grid. RNN lebih sering digunakan untuk data keuangan yang bersifat sekuensial, seperti urutan transaksi, time series harga saham, atau laporan keuangan berkala. RNN adalah model digunakan untuk mempertimbangkan urutan dan dependensi temporal, hal ini merupakan yang sangat penting dalam analisis data keuangan. Keuntungan RNN dapat mempelajari fitur temporal dan konteks, terutama ketergantungan jangka panjang antara dua entitas [8].


2. METODE PENELITIAN

Metodologi deteksi masalah keuangan dengan memanfaatkan deep learning dan big data memiliki tahapan-tahapan yang penting dimana meliputi pengumpulan, pengolahan, analisis data, dan pengambilan keputusan. Dalam konteks keuangan, CNN dan RNN dapat diterapkan untuk mendeteksi dan menganalisis masalah keuangan. CNN

umumnya digunakan untuk menganalisis berbasis pola dan fitur spasial. Walaupun pada awal pengembangan untuk pemrosesan gambar, lalu kemudian CNN diterapkan dalam sektor keuangan untuk menganalisis data berbasis pola dan tren. Pada analisis pola transaksi kartu kredit dan mendeteksi anomali dalam data, CNN dapat melakukan pengubahan data transaksi keuangan menjadi representasi matriks maupun gambar. Selain itu CNN dapat mendeteksi pola tidak biasa atau pola anomali pada keuangan yang menyimpang norma historis. Pola ini dijadikan petunjuk untuk adanya penipuan, kesalahan transaksi, manipulasi pasar, atau risiko keuangan lainnya yang selama ini tidak terlihat oleh metode tradisional.

RNN biasanya digunakan untuk data berurutan pada data keuangan seperti harga saham, transaksi, dan laporan keuangan bersifat time-series. Long Short-Term Memory (LSTM) dan Gated Recurrent Units (GRU) merupakan bagian dari RNN dapat digunakan dalam memprediksi pergerakan harga saham, kedua model ini dapat menilai hubungan temporal jangka panjang data keuangan serta melakukan prediksi dengan lebih akurat dibandingkan metode statistik tradisional.

Berikut adalah bagaimana kedua model ini digunakan dalam studi literatur mendeteksi permasalahan di sektor keuangan pengumpulan data keuangan baik data internal maupun eksternal dari ragam sumber yang ada lalu data yang ada dilakukan pembersihan data, menstandarisasi data, dan mengekstraksi fitur penting dari data. Setelah itu menentukan model deep learning yaitu CNN dan RNN serta melatih model dengan data yang sudah dilakukan pemrosesan. Mengukur kinerja model, mendeteksi anomali sehingga dapat memberikan hasil visualisasi. Berikut pada Gambar 1 tahapan yang dilakukan dalam metodologi ini :



Gambar 1. Alur flowchart untuk metodologi

Pembersihan Data atau data cleaning, hal ini dilakukan dikarenakan data keuangan sering kali memiliki noise, data yang hilang serta inkonsistensi. Oleh sebab itu, pembersihan data merupakan tahap awal dalam penelitian ini. Melakukan penghapusan data duplikat bertujuan menghindari bias dalam analisis. Untuk pengisian data yang hilang dapat digunakan teknik interpolasi atau imputasi berbasis statistik. Penghapusan outlier menggunakan metode IQR (Interquartile Range) maupun Z-score analysis untuk mengenali nilai yang terlalu ekstrem.

Standarisasi Data atau Data Standardization bertujuan supaya model deep learning dapat berkinerja lebih optimal sehingga data perlu dinormalisasi atau distandarisasi yaitu dengan cara :

1. min-max scaling: data berada dalam rentang 0 hingga 1 sehingga mudah diproses oleh model CNN dan RNN.
2. z-score normalization: mengubah distribusi data dengan mean = 0 dan standar deviasi = 1.
3. encoding data kategorikal menjadi dua yaitu one-hot encoding berguna untuk variabel kategorikal seperti jenis transaksi. Dan word embeddings (word2vec, fasttext, atau tf-idf) agar dapat mengubah data teks menjadi bentuk numerik.

Ekstraksi Fitur Penting (Feature Extraction) bertujuan agar memiliki pengaruh kuat dalam melakukan pendeteksian masalah keuangan dimana pada Model Time-Series (RNN, LSTM, GRU) sebagai contoh : Harga saham historis, moving average, volatilitas, sentimen pasar. Pada model Berbasis Pola (CNN) contoh: melakukan konversi grafik harga saham menjadi citra. Pemilihan Model Deep Learning CNN dan RNN dimana CNN digunakan untuk dapat mengenali beragam pola dari data yang dikonversi menjadi gambar atau matriks dan RNN sangat cocok untuk diterapkan dalam menganalisis data sekuensial yaitu data yang memiliki urutan dan ketergantungan antar elemen di dalamnya

1. LSTM (Long Short-Term Memory) dapat digunakan dalam menangani ketergantungan jangka panjang dalam data keuangan.
2. GRU (Gated Recurrent Unit) dapat digunakan dalam mengenali pola transaksi anomali atau transaksi dengan pola yang tidak seperti biasanya dalam rentang waktu tertentu.

Mengukur kinerja model bertujuan untuk dapat mengevaluasi model dilakukan dengan menggunakan metrik yaitu kinerja terhadap:

1. akurasi : menilai seberapa baik atau handal model dalam mengklasifikasikan transaksi normal dibandingkan transaksi anomali.
2. precision dan recall:
 - a. Precision: seberapa banyak transaksi yang dikenali sebagai anomali benar-benar anomali.
 - b. recall: seberapa banyak anomali yang dapat dikenali dengan sukses oleh model.

Pengumpulan Data Keuangan didapat dari sumber yang signifikan berupa data transaksi di bank, laporan pajak, pembelian online, media sosial maupun laporan keuangan yang bersifat datanya dapat diakses oleh masyarakat umum atau dapat dikatakan datanya bersifat publik. Pengumpulan data untuk pengolahan pada keuangan dapat mendeteksi masalah keuangan menggunakan teknologi big data dan deep learning harus memastikan bahwa data yang dikumpulkan terlindungi dari penyalahgunaan tanpa izin. Perlindungan data pribadi, seperti GDPR (General Data Protection Regulation) dan membatasi akses data hanya kepada yang memiliki izin untuk mengaksesnya. Mengumpulkan data pada tingkat yang mendalam bergantung pada aspek kemampuan mengandalkan pada sensor, sistem pengawasan keuangan, pengelolaan ekonomi berorientasi yang pada lingkungan, sistem kepercayaan, dan elemen lainnya untuk pengumpulan waktu nyata [9]. Data internal dan data eksternal dikumpulkan, dimana data internal berupa dalam transaksi Keuangan, laporan Keuangan, data kredit. Data eksternal sebagai contoh tren ekonomi, harga saham dan lain sebagainya.

2.1. Pembersihan Data, Standarisasi Data, Dan Ekstraksi Fitur (Feature Extraction)

Saat ini, ukuran data yang semakin besar mengharuskan hal tersebut untuk lebih mengembangkan proses pembersihan data [10]. Dalam proses deteksi masalah keuangan yang memanfaatkan big data dan deep learning melakukan teknik pembersihan data adalah langkah penting, dikarenakan agar hanya data yang relevan, konsisten, dan tidak bias masuk ke dalam analisis sehingga meminimalkan berbagai kesalahan. Untuk mencegah pengambilan kesimpulan yang salah, dilakukan pembersihan data untuk

memastikan keakuratan data. Pembersihan data adalah langkah penting dalam setiap operasi yang menggunakan data [11]. Pada tabel 1 berikut ini adalah proses pembersihan data dan penjelasan masing-masing:

Tabel 1. Pembersihan Data

Tahapan Pembersihan Data	Keterangan	Penanganan
1. Standarisasi Data	Format yang konsisten dan tidak bias untuk semua data. Contoh : Penyeragaman zona waktu.	Mengubah format data dalam bentuk seragam
2. Pengecekan duplikasi data	Mengisi data yang hilang atau data yang tercatat dua kali dilakukan penghapusan.	Menghapus data yang memiliki pola atau nilai yang sama persis.
3. Pengenalan data	Memeriksa data yang hilang atau tidak lengkap.	Melakukan teknik dalam pembersihan data mean imputation.
4. Normalisasi dan Skaling Data	Melakukan pengubahan skala nilai ditujukan agar memperoleh data yang seragam.	digunakan <i>min-max scaling</i> untuk rentang 0 hingga 1 untuk distribusi data normal, agar model dapat memproses data lebih akurat.
5. Data integration	Menyatukan format dan struktur data yang berbeda-beda.	Data disatukan ke data warehouse yang terpusat, dan format data diseragamkan.
6. Pengubahan data kategorikal	Mengubah data yang bersifat kategori atau teks.	Menggunakan one-hot encoding atau label encoding.

Standarisasi data merupakan proses penting dalam deteksi masalah keuangan menggunakan deep learning dan big data. Dimana dengan standarisasi dapat dipastikan data yang telah masuk dan memiliki format skala besar telah konsisten sehingga analisis dapat dilakukan dengan akurat. Menurut [12] Untuk model berbasis jarak, standarisasi dilakukan untuk mencegah fitur dengan rentang yang lebih luas mendominasi metrik jarak. Standarisasi pada data bertujuan untuk menyamakan format yang ada. Mengekstraksi fitur penting dari data adalah melakukan pengidentifikasian dengan cara memilih informasi yang paling signifikan dari data mentah (raw data) untuk diterapkan ke dalam model analitik, seperti deep learning. Pada deep learning, ekstraksi fitur membantu model untuk dapat mengurangi kompleksitas data dengan mengutamakan atribut yang benar-benar penting. Ekstraksi fitur penting bagi analisis keuangan dikarenakan dapat mengurangi dimensi data, meningkatkan akurasi dari model dan mempercepat proses pelatihan juga prediksi oleh model. Ekstraksi fitur dalam analisis keuangan merupakan hal yang penting agar model bekerja lebih efisien dan efektif untuk

mendeteksi masalah keuangan. Dalam konteks pendekatan ekstraksi dan pemilihan fitur berbasis pembelajaran mesin, bidang ilmu komputer ini memiliki tantangan besar yang belum terselesaikan [13]. Fitur yang diekstraksi dapat digunakan dalam algoritma pembelajaran mesin apa pun untuk memprediksi hasil keuangan [14]. Teknik yang digunakan dalam ekstraksi fitur yaitu berupa principal component analysis, seleksi fitur otomatis dan analisis deret waktu.

2.2. Model Model Deep Learning CNN Dan RNN

Sektor keuangan telah mengalami lonjakan penerapan teknik deep learning untuk mengatasi berbagai tantangan, termasuk pendeteksian masalah keuangan [15]. Jaringan Neural Konvolusional dan Jaringan Neural Berulang telah muncul sebagai model yang menjanjikan untuk tugas ini, menawarkan kemampuan untuk mengekstrak fitur kompleks dan mengidentifikasi pola tersembunyi dalam data keuangan [16], [17]. Penerapan model CNN dan RNN untuk deteksi masalah keuangan dimana studi yang dipilih dianalisis untuk mengidentifikasi pendekatan umum, teknik pemrosesan awal data, arsitektur model, dan metrik evaluasi yang digunakan. Penelitian ini bertujuan untuk menyelidiki kinerja model CNN dan RNN dalam mendeteksi masalah keuangan dengan memanfaatkan deep learning dan big data sehingga dapat melakukan perbandingan efektivitasnya untuk tugas-tugas seperti prediksi pasar saham, penilaian risiko keuangan, dan deteksi anomali. Kemampuan model deep learning untuk mengekstrak fitur-fitur canggih dan menangkap hubungan nonlinier yang kompleks dalam data deret waktu keuangan telah menghasilkan peningkatan signifikan dalam kinerja prediktif dibandingkan dengan cara-cara pendekatan pembelajaran mesin tradisional [18], [19]. Studi terbaru juga menekankan pentingnya mengintegrasikan beragam sumber data keuangan, seperti data harga, volume, dan sentimen, untuk meningkatkan kemampuan prediktif model pembelajaran mendalam [20]. CNN dan RNN merupakan dua arsitektur deep learning yang paling banyak digunakan, keduanya memiliki kekuatan dan penerapannya sendiri. CNN konvolusional biasanya diterapkan melibatkan data visual, dimana dirancang untuk mengekstrak dan mempelajari fitur suatu gambar secara otomatis. Salah satu perbedaan utama antara Jaringan Neural Konvolusional dan Jaringan Neural Berulang adalah pendekatannya dalam menangani ketergantungan spasial dan temporal. Jaringan Neural Konvolusional mahir dalam menangkap hubungan spasial dalam gambar, sedangkan Jaringan Neural Berulang

unggul dalam memodelkan ketergantungan temporal dalam data sekuensial [21], [22] RNN pada umumnya dirancang untuk menangani data berurutan atau data yang memiliki urutan berbasis waktu, seperti teks, audio, atau data deret waktu. Dimana RNN memiliki kemampuan untuk mengingat informasi dari langkah-langkah sebelumnya dalam data berurutan.


3. HASIL DAN PEMBAHASAN

Berdasarkan literatur review, big data memberikan landasan kuat dalam mendeteksi masalah keuangan dengan cara mengumpulkan, menyimpan, dan menganalisis data dalam skala besar secara real-time. Deep Learning pada model CNN dan RNN (LSTM/GRU), dapat melakukan efektivitasnya dalam mendeteksi pola keuangan seperti prediksi harga saham dan deteksi transaksi anomali. CNN lebih efektif dalam analisis pola visual seperti grafik sementara LSTM/GRU unggul dalam memproses data time-series dan deteksi anomali transaksi. Dengan strategi yang tepat untuk melakukan pengolahan data dan pemilihan model maka deep Learning dan big data lebih mendukung keamanan dan efisiensi dalam sistem keuangan modern. RNN lebih baik jika digunakan dalam prediksi harga saham, analisis kredit, dan deteksi transaksi mencurigakan berbasis data sekuensial.

3.1 Pembahasan Algoritma Convolutional Neural Network (CNN)

Jaringan Neural Konvolusional atau CNN memiliki kemampuan mendeteksi masalah keuangan yaitu secara otomatis mengekstraksi dan mempelajari fitur-fitur yang relevan dari data sehingga sangat cocok untuk aplikasi keuangan yang kompleks. Arsitektur CNN merupakan lapisan konvolusional, dimana menerapkan serangkaian filter yang dapat dipelajari pada data masukan. Dimana pendeteksian pola atau fitur tertentu seperti tepi, tekstur, atau bentuk, yang relevan dengan tugas yang diberikan. Saat data melewati jaringan, fitur-fiturnya menjadi semakin kompleks, memungkinkan CNN untuk membangun. Model CNN memiliki kemampuan untuk secara efektif menangkap pola lokal dan ketergantungan jangka pendek dalam data deret waktu keuangan, sehingga model tersebut cocok untuk tugas-tugas seperti perkiraan harga saham dan deteksi anomali [23], [24], [25].

Convolutional Neural Network



Gambar 2 Algoritma CNN Sumber DQLab

Pendekatan ini sering kali berfokus pada identifikasi pola-pola terkenal dalam rangkaian pergerakan harga saham, sehingga memungkinkan investor merancang strategi yang menguntungkan dengan mengenali pola-pola yang sesuai dalam data [26]. Arsitektur Convolutional Neural Network (CNN). Arsitektur CNN biasanya terdiri dari lapisan konvolusional dan lapisan sub-sampling. Gambar 2 dibawah ini merupakan algoritma dari CNN. Algoritma deep learning menggunakan proses yang disebut backpropagasi untuk menyesuaikan bobot dan bias neuron, mengoptimalkan kinerja jaringan dari waktu ke waktu [27]. CNN biasanya digunakan untuk mengekstraksi fitur spasial. Seringkali, ketika digunakan dalam deret waktu keuangan, langkah pertama yang umum dilakukan adalah mengubah data deret waktu menjadi “gambar” sebelum memasukkannya ke dalam CNN [28]. Penerapan CNN dalam Deteksi Masalah Keuangan CNN dapat diterapkan untuk analisis dan deteksi masalah keuangan. Dimana data yang diproses berupa:

- **Data Transaksi:** Menyimpan data transaksi historis yang dapat dianalisis untuk mendeteksi pola atau kejanggalan yang mengindikasikan kemungkinan terjadinya tindakan penipuan dan kecurangan yang dilaksanakan untuk memperoleh keuntungan finansial .
- **Data Waktu Seri atau Time Series:** pola dalam data waktu seri atau Time seri merupakan kumpulan data yang diambil dan dicatat dalam urutan waktu tertentu, dimana dapat memberikan informasi tentang masalah atau risiko keuangan.


Adapun struktur dan Lapisan CNN untuk Data Keuangan pada umumnya terdapat beberapa lapisan utama yaitu lapisan konvolusi, lapisan pooling dan lapisan fully.

Lapisan konvolusi digunakan untuk mengekstrak fitur dari data, pada lapisan ini dapat mengambil pola yang berulang dan mengenali fitur-fitur penting dalam data keuangan. Lapisan pooling biasanya digunakan untuk mengurangi dimensi data, meminimalkan kompleksitas model dan meminimalkan overfitting. Lapisan fully connected atau FC digunakan untuk menghubungkan seluruh node dari lapisan sebelumnya berada pada lapisan berikutnya untuk memberikan prediksi akhir. Fitur-fitur ini kemudian digabungkan dengan lapisan konvolusional berikutnya untuk mendeteksi fitur tingkat tinggi. Lebih jauh lagi, gagasan bahwa detektor fitur dasar, yang berguna pada suatu bagian suatu gambar, kemungkinan besar akan berguna pada keseluruhan gambar diimplementasikan dengan konsep bobot terikat[29]. Arsitektur CNN untuk data keuangan 1D CNN digunakan untuk menangani data time series satu dimensi sebagai contoh harga saham atau data kredit. CNN 1D dapat memperoleh pola dari tren data. Pemilihan tipe model yang optimal dan struktur untuk tugas tertentu atau untuk memahami secara mendalam alasan mengapa arsitektur atau algoritme tertentu efektif dalam tugas tertentu atau tidak [30]. CNN dapat secara otomatis mengekstraksi fitur-fitur yang relevan dari data keuangan yang cukup kompleks sehingga tidak bergantung pada kemampuan manusia. Kemajuan pesat dalam algoritma deep learning telah merevolusi banyak industri, termasuk sektor keuangan. CNN sebagai arsitektur deep learning telah memperlihatkan hasil yang menjanjikan dalam banyak aplikasi, termasuk prediksi deret waktu keuangan. Penelitian lebih lanjut juga menunjukkan potensi CNN dalam mengatasi tantangan data keuangan yang tidak normal. Dengan menggunakan teknik seperti analisis komponen utama, keakuratan prediksi model berbasis CNN dapat ditingkatkan, menjadikannya alat yang layak untuk evaluasi pengelolaan keuangan dan pengambilan keputusan [19], [24], [26].

3.2 Pembahasan Algoritma Recurrent Neural Network (RNN)

Jaringan neural berulang atau RNN telah hadir sebagai kelas model deep learning yang tangguh dan serbaguna. RNN memiliki kemahiran dalam memproses data sekuensial dan menghasilkan keluaran yang memahami konteks. Selain itu RNN memiliki kemampuan dalam memelihara juga memperbarui keadaan internal, sehingga mereka memiliki kemampuan menangkap ketergantungan dan pola dalam masukan yang berurutan. RNN untuk konsep unit berulang dimana dapat melakukan pemrosesan masukan saat sekarang dan keadaan tersembunyi yang dihasilkan sebelumnya agar menghasilkan

keadaan dan keluaran tersembunyi berikutnya. Dengan sifat rekursifnya maka RNN memodelkan hubungan temporal dan sekuensial secara maksimal, sehingga dapat diterapkan pada banyak tugas. Gambar 3 dibawah ini merupakan algoritma dari RNN.



Gambar 3 Algoritma CNN Sumber DQLab

Bidang keuangan memiliki tantangan dalam mengenali potensi masalah atau kesulitan keuangan dalam organisasinya. Secara tradisional, model prediktif menerapkan rasio keuangan, oleh sebab itu teknik yang lebih maju diperlukan bagi sifat kompleks dan dinamis dari data keuangan. Salah satu model yang banyak diaplikasikan adalah Recurrent Neural network (RNN), yang memiliki dua variasi utama yaitu Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) [31]. Penggunaan RNN, khususnya jaringan Long Short-Term Memory, dapat memprediksi kesulitan keuangan maupun kebangkrutan. RNN memiliki kemampuan dalam melakukan pemrosesan untuk data berurutan, seperti rangkaian waktu keuangan. Deteksi dengan menggunakan RNN sangatlah efektif untuk menganalisis data yang mempunyai urutan waktu sebagai contoh harga saham, aliran kas juga data keuangan perusahaan. Hal ini dikarenakan RNN memiliki kemampuan dalam mempertimbangkan urutan dan ketergantungan antar waktu agar dapat menangkap pola yang menyebabkan anomali dalam mengindikasikan masalah keuangan. RNN dapat juga diterapkan untuk beberapa masalah dalam keuangan seperti financial distress, fraud detection, analisis resiko kredit, anomali deteksi dan biasanya RNN seperti *Long Short-Term Memory (LSTM)* atau *Gated Recurrent Units (GRU)* akan lebih dipilih dikarenakan memiliki kemampuan dalam mengatasi masalah yang lebih kompleks untuk urutan data jangka panjang. Memori jangka pendek panjang (LSTM) untuk berbagai masalah pembelajaran yang melibatkan data sekuensial, jaringan saraf berulang dengan memori jangka pendek (LSTM) telah muncul sebagai

pendekatan yang efektif dan terukur[32]. Selain itu pada LSTM digunakan untuk data yang memiliki kompleksitas temporal yang tinggi, sehingga dapat digunakan untuk komputasi dengan menggunakan lebih banyak parameter. Untuk data keuangan maka LSTM dapat menangani data keuangan dengan multivarian juga mendeteksi anomali keuangan sebagai contoh : resiko kebangkrutan. Pada GRU memiliki arsitektur yang lebih sederhana dibandingkan LSTM sehingga dapat lebih cepat dilatih karena memerlukan lebih sedikit sumber daya komputasi. GRU cocok untuk data jangka pendek, seperti pada data keuangan ada beberapa pola yang bersifat jangka pendek contoh analisis tren harga. Pada GRU dapat mendeteksi anomali pada data transaksi keuangan fraud detection hal ini disebabkan kemampuan mengolah data suksensial, Kemampuan menangkap pola temporal seperti transaksi transfer uang dengan cara mendeteksi ketika suatu transaksi tidak sesuai dengan pola normal yang ada. GRU mempunyai struktur yang lebih sederhana dibandingkan LSTM hal ini dikarenakan menggunakan dua gerbang (update dan reset) sehingga dapat bekerja lebih cepat, hal ini sangat penting ketika mendeteksi penipuan keuangan secara real-time.

4. SIMPULAN

Peran deep learning dan big data untuk mendeteksi masalah keuangan dimana big data memungkinkan melakukan pengolahan serta menganalisis data keuangan yang kompleks, beragam dan dengan berskala besar lebih efisien. Pada penelitian ini big data melakukan pengumpulan, pemrosesan berskala besar data keuangan yang datanya dapat diakses oleh masyarakat umum . Melakukan analisis data keuangan dengan big data dapat mengenali pola pasar, tren keuangan serta anomali transaksi keuangan dengan lebih cepat dibandingkan pendekatan tradisional. Deep Learning memiliki kemampuan untuk memprediksi dan mendeteksi anomali, model CNN (Convolutional Neural Network) dapat melakukan analisis terhadap pola grafik saham, heatmap transaksi, dan deteksi dokumen keuangan palsu. RNN (Recurrent Neural Network), khususnya LSTM (Long Short-Term Memory), memiliki kemampuan menganalisis data sekuensial keuangan, menangkap pola temporal, mendeteksi anomali transaksi, dan penilaian risiko keuangan. Penerapan CNN dan RNN pada fraud detection lebih efektifitas dalam mendeteksi transaksi mencurigakan dan mencegah kejahatan keuangan. Dapat disimpulkan bahwa secara keseluruhan, big data dan deep learning memiliki kemampuan untuk membawa perubahan besar dalam sistem keuangan untuk mendeteksi masalah keuangan seperti deteksi fraud, analisis risiko juga memiliki kemampuan memprediksi tren pasar. Dengan strategi yang tepat, penerapan big data dan deep learning akan semakin berkontribusi dalam pengembangan sistem keuangan yang lebih terpercaya, jelas, dan efektif di masa depan. Walaupun begitu dapat dikatakan bahwa sangat penting dalam pemilihan algoritma untuk mempertimbangkan karakteristik dataset. Sehingga big data dan deep

learning dalam mendeteksi masalah keuangan dapat memberika prediksi yang lebih akurat agar tercipta keputusan tepat bagi dunia usaha, lembaga keuangan, dan para pembuat kebijakan.

REFERENCES

- [1] Z. Yi, X. Cao, Z. Chen, and S. Li, "Artificial Intelligence in Accounting and Finance: Challenges and Opportunities," *IEEE Access*, vol. 11, pp. 129100–129123, 2023, doi: 10.1109/ACCESS.2023.3333389.
- [2] J. B. Heaton, N. G. Polson, and J. H. Witte, "Deep learning for finance: deep portfolios," Jan. 01, 2017, *John Wiley and Sons Ltd*. doi: 10.1002/asmb.2209.
- [3] S. Cockcroft and M. Russell, "Big Data Opportunities for Accounting and Finance Practice and Research," Sep. 01, 2018, *Blackwell Publishing Ltd*. doi: 10.1111/auar.12218.
- [4] Samuel Aderemi, David Olanrewaju Olutimehin, Uchenna Innocent Nnaomah, Omamode Henry Orieno, Tolulope Esther Edunjobi, and Sodiq Odetunde Babatunde, "Big data analytics in the financial services industry: Trends, challenges, and future prospects: A review," *International Journal of Science and Technology Research Archive*, vol. 6, no. 1, pp. 147–166, Mar. 2024, doi: 10.53771/ijstra.2024.6.1.0036.
- [5] H. Sun, M. R. Rabbani, M. S. Sial, S. Yu, J. A. Filipe, and J. Cherian, "Identifying big data's opportunities, challenges, and implications in finance," *Mathematics*, vol. 8, no. 10, pp. 1–19, Oct. 2020, doi: 10.3390/math8101738.
- [6] F. M. Shiri, T. Perumal, N. Mustapha, and R. Mohamed, "A Comprehensive Overview and Comparative Analysis on Deep Learning Models."
- [7] I. K. Sastrawan, I. P. A. Bayupati, and D. M. S. Arsa, "Detection of fake news using deep learning CNN–RNN based methods," *ICT Express*, vol. 8, no. 3, pp. 396–408, Sep. 2022, doi: 10.1016/j.ict.2021.10.003.
- [8] X. Zhang, F. Chen, and R. Huang, "A combination of RNN and CNN for attention-based relation classification," in *Procedia Computer Science*, Elsevier B.V., 2018, pp. 911–917. doi: 10.1016/j.procs.2018.04.221.
- [9] Y. Liang, D. Quan, F. Wang, X. Jia, M. Li, and T. Li, "Financial big data analysis and early warning platform: A case study," *IEEE Access*, vol. 8, pp. 36515–36526, 2020, doi: 10.1109/ACCESS.2020.2969039.
- [10] M. Hosseinzadeh *et al.*, "Data cleansing mechanisms and approaches for big data analytics: a systematic study," *J Ambient Intell Humaniz Comput*, vol. 14, no. 1, pp. 99–111, Jan. 2023, doi: 10.1007/s12652-021-03590-2.
- [11] M. A. Oladipupo, P. C. Obuzor, B. J. Bamgbade, K. M. Olagunju, A. E. Adeniyi, and S. A. Ajagbe, "An Automated Python Script for Data Cleaning and Labeling using Machine Learning Technique," *Informatica (Slovenia)*, vol. 47, no. 6, pp. 219–232, 2023, doi: 10.31449/inf.v47i6.4474.
- [12] S. Vinay, "STANDARDIZATION IN MACHINE LEARNING." [Online]. Available: <https://www.researchgate.net/publication/349869617>
- [13] D. Ruano-Ordás, "Machine Learning-Based Feature Extraction and Selection," Aug. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/app14156567.
- [14] N. Kanungsukkasem and T. Leelanupab, "Financial Latent Dirichlet Allocation (FinLDA): Feature Extraction in Text and Data Mining for Financial Time Series Prediction," *IEEE Access*, vol. 7, pp. 71645–71664, 2019, doi: 10.1109/ACCESS.2019.2919993.
- [15] Z. Berradi, M. Lazaar, O. Mahboub, and H. Omara, "A comprehensive review of artificial intelligence techniques in financial market," in *Colloquium in Information Science and Technology, CIST*, Institute of Electrical and Electronics Engineers Inc., Jun. 2020, pp. 367–371. doi: 10.1109/CiSt49399.2021.9357175.
- [16] E. Chong, C. Han, and F. C. Park, "Deep Learning Networks for Stock Market Analysis and Prediction: Methodology, Data Representations, and Case Studies."
- [17] W. Shi, L. Xu, and D. Peng, "Application of Deep Learning in Financial Management Evaluation," *Sci Program*, vol. 2021, 2021, doi: 10.1155/2021/2475885.
- [18] W. Bao, J. Yue, and Y. Rao, "A deep learning framework for financial time series using stacked autoencoders and long-short term memory," *PLoS One*, vol. 12, no. 7, Jul. 2017, doi: 10.1371/journal.pone.0180944.
- [19] E. Chong, C. Han, and F. C. Park, "Deep Learning Networks for Stock Market Analysis and Prediction: Methodology, Data Representations, and Case Studies."
- [20] S. Il Lee and S. J. Yoo, "Multimodal Deep Learning for Finance: Integrating and Forecasting International Stock Markets," Mar. 2019, [Online]. Available: <http://arxiv.org/abs/1903.06478>

-
- [21] S. Siami-Namini, N. Tavakoli, and A. S. Namin, "A Comparative Analysis of Forecasting Financial Time Series Using ARIMA, LSTM, and BiLSTM," Nov. 2019, [Online]. Available: <http://arxiv.org/abs/1911.09512>
 - [22] R. K. Sinha, R. Pandey, and R. Pattnaik, "Deep Learning For Computer Vision Tasks: A review."
 - [23] Z. Zeng, R. Kaur, S. Siddagangappa, S. Rahimi, T. Balch, and M. Veloso, "Financial Time Series Forecasting using CNN and Transformer," Apr. 2023, [Online]. Available: <http://arxiv.org/abs/2304.04912>
 - [24] E. Hoseinzade and S. Haratizadeh, "CNNPred: CNN-based stock market prediction using several data sources," Oct. 2018, [Online]. Available: <http://arxiv.org/abs/1810.08923>
 - [25] L. Di Persio and O. Honchar, "Artificial Neural Networks architectures for stock price prediction: comparisons and applications."
 - [26] J. Sen and S. Mehtab, "This is the accepted version in the IEEE Accurate Stock Price Forecasting Using Robust and Optimized Deep Learning Models."
 - [27] B. Via Tarissa and T. Dewayanto, "PENERAPAN MACHINE LEARNING DAN DEEP LEARNING PADA PENINGKATAN DETEKSI CREDIT CARD FRAUD-A SYSTEMATIC LITERATURE REVIEW," *DIPONEGORO JOURNAL OF ACCOUNTING*, vol. 13, no. 3, pp. 1–15, 2024, [Online]. Available: <http://ejournal-s1.undip.ac.id/index.php/accounting>
 - [28] W. Chen, W. Hussain, F. Cauteruccio, and X. Zhang, "Deep Learning for Financial Time Series Prediction: A State-of-the-Art Review of Standalone and Hybrid Models," 2023, *Tech Science Press*. doi: 10.32604/cmes.2023.031388.
 - [29] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, "Deep Learning for Computer Vision: A Brief Review," 2018, *Hindawi Limited*. doi: 10.1155/2018/7068349.
 - [30] Z. Zhang, X. Zhou, X. Zhang, L. Wang, and P. Wang, "A Model Based on Convolutional Neural Network for Online Transaction Fraud Detection," *Security and Communication Networks*, vol. 2018, 2018, doi: 10.1155/2018/5680264.
 - [31] C. Alkahfi, A. Kurnia, and A. Saefuddin, "Perbandingan Kinerja Model Berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1235–1243, Jul. 2024, doi: 10.57152/malcom.v4i4.1415.
 - [32] M. J. Hamayel and A. Y. Owda, "A Novel Cryptocurrency Price Prediction Model Using GRU, LSTM and bi-LSTM Machine Learning Algorithms," *AI (Switzerland)*, vol. 2, no. 4, pp. 477–496, Dec. 2021, doi: 10.3390/ai2040030.