

Prediksi Pendapatan Penjualan Skala Multi-Kota Menggunakan Gated Recurrent Unit-Sequential Windowing

Ina Rahmi Diwasya^{1*}, Dian Nirmala Dewi², Koko Friansa³

^{1,2}Akuntansi Bisnis Digital, Politeknik Negeri Lampung, Indonesia

³Teknik Sistem Energi, Institut Teknologi Sumatera, Indonesia

^{1*}inadiwasya@polinela.ac.id, ²diannirmaladewi@gmail.com, ³koko.friansa@tse.itera.ac.id

Submitted	Accepted	Publish
26-September-2025	26-December-2025	31-December-2025

Abstrak: Prediksi pendapatan penjualan berskala multi-kota merupakan tantangan yang kompleks karena melibatkan dinamika non-linear, fluktuasi jangka pendek, serta pola musiman yang beragam antar wilayah, sementara model prediksi konvensional sering kali mengalami penurunan akurasi pada skenario *multi-output* atau multi-kota. Prediksi pendapatan penjualan berskala multi-kota merupakan tantangan yang kompleks karena melibatkan dinamika non-linear, fluktuasi jangka pendek, serta pola musiman yang beragam antar wilayah, sementara model prediksi konvensional sering kali mengalami penurunan akurasi pada skenario *multi-output*. Penelitian ini membahas prediksi pendapatan penjualan berskala multi-kota dengan menggunakan arsitektur *Gated Recurrent Unit* (GRU) yang dipadukan dengan teknik *sequential windowing*. Dataset yang digunakan berasal dari *Iowa dataset*, mencakup lebih dari 10 juta transaksi pada 442 kota selama periode empat tahun. Dari dataset tersebut dipilih kota-kota dengan kontribusi pendapatan terbesar dan pola data yang signifikan untuk dianalisis lebih lanjut. Proses penelitian mencakup tahapan persiapan data, pemrosesan, pemodelan, dan evaluasi. Dua pendekatan dibandingkan, yaitu GRU dengan *sequential windowing* (GRU-SW) dan GRU tanpa *sequential windowing*. Evaluasi menggunakan metrik *Root Mean Squared Error* (RMSE) dan *Willmott's d-index* menunjukkan bahwa GRU-SW secara konsisten menghasilkan prediksi yang lebih akurat pada level harian maupun bulanan. Hasil penelitian ini menegaskan keunggulan integrasi *sequential windowing* dalam meningkatkan kemampuan model GRU untuk menangkap pola temporal dan musiman, serta memberikan kontribusi praktis bagi perencanaan keuangan, strategi bisnis, dan kebijakan publik berbasis data.


Kata Kunci: prediksi pendapatan; analisis prediktif; pemodelan deret waktu; pembelajaran mesin; data sekuens;

Abstract: *Accurate multi-city sales revenue forecasting remains challenging due to non-linear temporal dependencies, heterogeneous seasonal patterns, and the limitations of conventional sequence modeling approaches in multi-output or multi-city settings. This study examines multi-city sales revenue forecasting using the Gated Recurrent Unit (GRU) architecture combined with the sequential windowing technique. The dataset employed is the Iowa dataset, comprising more than 10 million transactions across 442 cities over a four-year period. From this dataset, cities with the highest revenue contributions and significant data patterns were selected for further analysis. The research process involved four stages: data preparation, preprocessing, modeling, and evaluation. Two approaches were compared, namely GRU with sequential windowing (GRU-SW) and GRU without sequential windowing. The evaluation,*

Nama Penulis Korespondensi: * Ina Rahmi Diwasya



Copyright © 2025, Ina Rahmi Diwasya, Dian Nirmala Dewi, Koko Friansa.



conducted using the Root Mean Squared Error (RMSE) and Willmott's *d*-index metrics, demonstrated that GRU-SW consistently produced more accurate predictions at both daily and monthly levels. The findings highlight the superiority of integrating sequential windowing in enhancing the ability of GRU models to capture temporal and seasonal patterns, while also providing practical contributions to financial planning, business strategy, and data-driven public policy.

Keywords: revenue forecasting; predictive analytics; time series modeling; machine learning; sequence data;

1. PENDAHULUAN


Di era digital dan globalisasi saat ini, aktivitas bisnis semakin dinamis dan kompleks [1]. Pergeseran pola konsumsi dari *offline* ke *online*, perkembangan teknologi informasi, perubahan kebijakan fiskal, serta fluktuasi ekonomi global dan lokal menciptakan ketidakpastian yang signifikan dalam pengelolaan pendapatan bisnis [2]. Kondisi ini menuntut perusahaan atau pemerintah untuk memiliki kemampuan prediksi pendapatan yang akurat guna mendukung pengambilan keputusan yang efektif [3].

Dalam perspektif akuntansi dan manajemen keuangan, pendapatan penjualan tidak hanya dipandang sebagai estimasi angka, melainkan juga sebagai alat strategis dalam proses *data-driven decision making* [4]. Akurasi prediksi pendapatan penjualan memungkinkan perusahaan atau pemerintah menyusun anggaran realistis, mengelola arus kas dengan efisien, serta mengantisipasi potensi risiko keuangan di masa depan [5]. Bagi pemerintah, kemampuan memprediksi pendapatan jualan di wilayah tertentu seperti kabupaten atau kota berperan penting dalam merancang kebijakan fiskal, memperkirakan potensi penerimaan pajak, dan menentukan intervensi ekonomi yang tepat sasaran [6]. Namun, tingkat kompleksitas prediksi akan meningkat dan akurasi menurun, jika level prediksi yaitu multi-output, seperti prediksi pendapatan penjualan banyak daerah atau kota dengan satu model prediksi.

Metode tradisional dalam model prediksi pendapatan jualan yaitu ARIMA dan *Exponential Smoothing* [7],[8]. Akan tetapi ARIMA dan *Exponential Smoothing* sering gagal menangkap pola non-linear dan dependensi jangka panjang dalam data deret waktu atau sekuensial [8]. Kemajuan teknologi analitik, khususnya pembelajaran mesin, telah membuka peluang baru dalam mengolah data penjualan berbasis wilayah [7]. Sebaliknya, model berbasis deep learning seperti *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) terbukti lebih efektif dalam memodelkan data sekuensial, meskipun LSTM relatif kompleks dan membutuhkan sumber daya komputasi besar [9]. Salah satu alternatif yang lebih efisien adalah *Gated Recurrent Unit* (GRU), yang mampu menangkap ketergantungan jangka panjang dengan kompleksitas lebih rendah dibandingkan LSTM [10]. GRU dengan modifikasi bagian fitur dapat memanfaatkan informasi historis secara lebih komprehensif, termasuk fluktuasi jangka pendek dan pola musiman yang sering muncul dalam data penjualan [11], [12]. Sehingga, permasalahan utama yang akan dipecahkan dalam penelitian ini adalah bagaimana merancang model prediksi pendapatan penjualan multi-kota yang mampu menangkap dinamika non-linear, fluktuasi jangka pendek, dan pola musiman secara efektif, namun tetap mempertahankan kompleksitas komputasi yang rendah untuk aplikasi berskala besar.

Oleh karena itu, penelitian ini bertujuan untuk mengeksplorasi penerapan GRU sebagai model sederhana, dan mampu memprediksi pendapatan penjualan berskala multi-kota. Untuk menguji model GRU tersebut, peneliti menggunakan dataset penjualan minuman Iowa dataset, yang terdiri dari data penjualan minuman dari berbagai kota-kota dari negara bagian Iowa, Amerika Serikat. Dataset tersebut memiliki data lebih dari 10 juta transaksi pada 442 kota selama periode empat tahun. Kemudian, penelitian ini tidak hanya menguji efektivitas pendekatan GRU, namun juga meneliti pendekatan *sequence*





windowing pada GRU sebagai strategi pemodelan sekuensial yang bertujuan meningkatkan akurasi prediksi dibandingkan GRU konvensional.

2. TINJAUAN PUSTAKA

Prediksi pendapatan penjualan berbasis data deret waktu telah menjadi fokus berbagai penelitian [13]. Metode statistik konvensional, seperti ARIMA dan Exponential Smoothing, memang banyak digunakan, namun sering kali kurang mampu menangkap kompleksitas pola non-linear serta dependensi jangka panjang antartitik waktu [8]. Seiring perkembangan *deep learning*, model seperti *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) mulai diadopsi karena kemampuannya mengenali pola dinamis dalam data sekuensial, namun LSTM memiliki struktur yang lebih kompleks dan membutuhkan waktu pelatihan yang relatif lama [9].

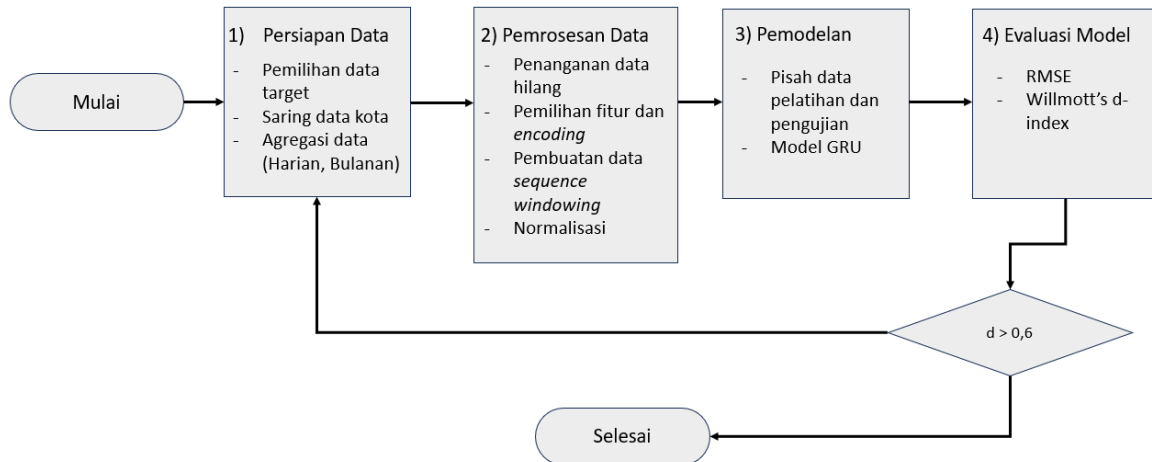
Gated Recurrent Unit (GRU) merupakan model yang ringan namun tetap efektif dalam memodelkan data sekuensial [10]. Di sisi lain, metode *sequential windowing* memiliki potensi besar untuk meningkatkan representasi pola deret waktu. Pendekatan *sequential windowing* memungkinkan model untuk melihat serangkaian data historis secara berurutan, sehingga model dapat mempelajari urutan dan hubungan temporal dibandingkan hanya menggunakan data titik Tunggal [14]. Penelitian [15] menunjukkan bahwa penggabungan representasi sekuensial melalui jendela waktu eksplisit dalam model prediksi dapat meningkatkan akurasi secara signifikan.

Berdasarkan literatur tersebut, masih terdapat kesenjangan penelitian terkait integrasi GRU dengan data sekuensial yang diolah menggunakan teknik *sequential windowing*. Oleh karena itu, hipotesis penelitian ini adalah bahwa: "Penggunaan arsitektur GRU yang dioptimalkan dengan teknik *sequential windowing* akan menghasilkan performa prediksi yang lebih baik dibandingkan pendekatan non-sekuensial atau model deret waktu konvensional." Hipotesis ini didasarkan pada keunggulan GRU dalam menangani dependensi temporal jangka panjang, sekaligus kemampuan *sequential windowing* untuk merepresentasikan pola dinamis dan urutan data secara lebih efektif. Dengan demikian, pendekatan ini diharapkan mampu menangkap fluktuasi jangka pendek sekaligus siklus musiman yang sering kali terlewatkan oleh model tradisional maupun pendekatan *machine learning* berbasis fitur skalar.

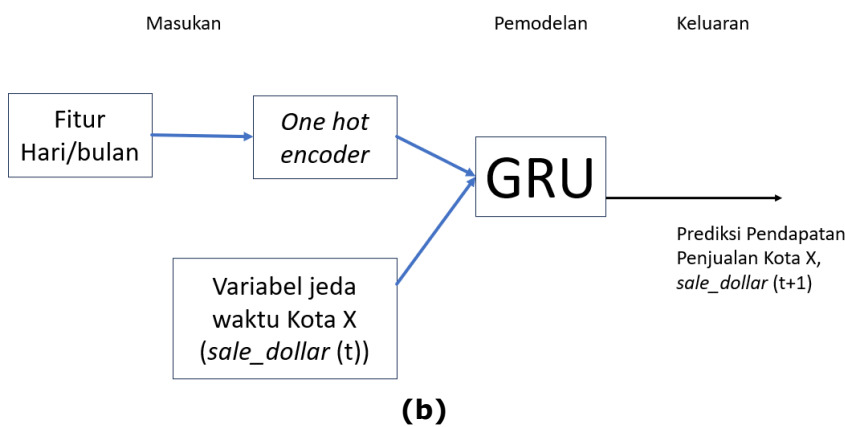
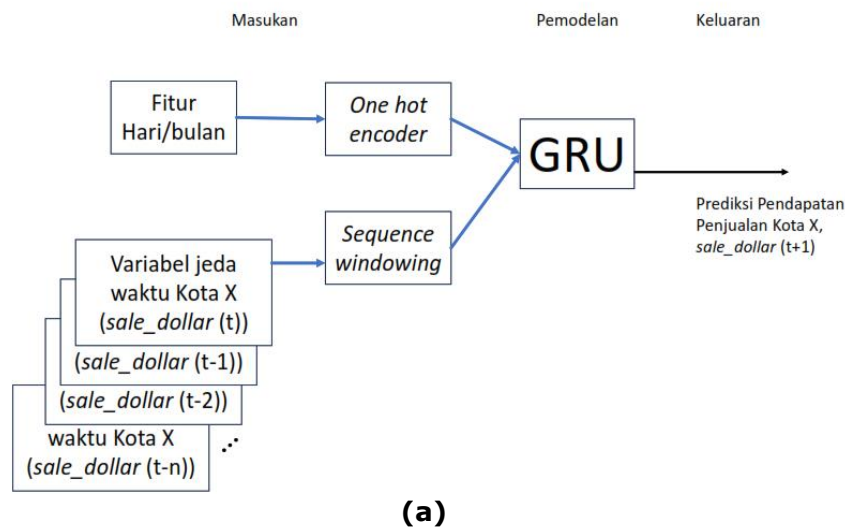
3. METODE PENELITIAN

Metode yang digunakan pada penelitian ini yaitu ditampilkan pada diagram alir pada Gambar 1. Diagram alir tersebut menggambarkan alur penelitian prediksi menggunakan model GRU yang terdiri dari empat tahapan. Tahap pertama adalah persiapan data, yang meliputi pemilihan data target, penyaringan data berdasarkan kota, serta agregasi data ke dalam skala waktu harian dan bulanan. Tahap kedua adalah pemrosesan data, yang mencakup penanganan data hilang, pemilihan fitur dan proses *encoding*, normalisasi data, serta pembentukan data sekuensial menggunakan teknik *sequence windowing*. Data yang telah diproses selanjutnya digunakan pada tahap ketiga, yaitu pemodelan, di mana dataset dibagi menjadi data pelatihan dan data pengujian, kemudian digunakan untuk membangun dan melatih model GRU. Tahap terakhir adalah evaluasi model, yang dilakukan dengan membandingkan hasil prediksi terhadap data aktual menggunakan metrik *Root Mean Squared Error* (RMSE)[16] dan *Willmott's d-index* [17]. Apabila nilai *d-index* yang dihasilkan lebih besar dari 0,6, maka model dinyatakan memenuhi kriteria evaluasi dan proses penelitian diakhiri. Sebaliknya, jika nilai *d-index* tidak memenuhi kriteria tersebut, proses penelitian diulang dengan melakukan perbaikan mulai dari tahap persiapan data.






Gambar 1. Diagram alir penelitian



Gambar 2. Pemodelan prediksi yang akan digunakan pada penelitian ini (a) GRU-sequence windowing (b) GRU tanpa sequence windowing



Gambar 2 menunjukkan dua pendekatan pemodelan prediksi pendapatan penjualan menggunakan arsitektur Gated Recurrent Unit (GRU). Target prediksi pada penelitian ini adalah pendapatan penjualan Kota X pada periode berikutnya, yang dinyatakan sebagai $sale_dollar(t+1)$.

Pada Gambar 2(a), model GRU dibangun dengan menerapkan teknik *sequence windowing*, yang memanfaatkan informasi historis berupa variabel jeda waktu (*lagged variables*) dari pendapatan penjualan, yaitu $sale_dollar$ pada periode saat ini (t), satu periode sebelumnya ($t-1$), dua periode sebelumnya ($t-2$), hingga n periode sebelumnya ($t-n$). Selain itu, fitur waktu berupa hari (untuk prediksi skala harian) atau bulan (untuk prediksi skala bulanan) turut disertakan setelah melalui proses *one-hot encoding* [26]. Dengan pendekatan ini, model GRU memperoleh representasi sekuensial yang lebih panjang, sehingga diharapkan mampu mempelajari pola temporal, tren jangka panjang, serta komponen musiman dalam data pendapatan penjualan secara lebih efektif.

Sebaliknya, Gambar 2(b) menggambarkan pemodelan GRU tanpa penerapan *sequence windowing*. Pada pendekatan ini, model hanya menggunakan informasi pendapatan penjualan pada periode saat ini (t) yang dikombinasikan dengan fitur waktu (hari atau bulan) yang telah dikodekan. Meskipun pendekatan ini lebih sederhana dan membutuhkan sumber daya komputasi yang lebih rendah, model berpotensi kehilangan informasi historis yang penting untuk mengidentifikasi tren dan pola musiman dalam data pendapatan penjualan. Perbandingan kedua pendekatan tersebut memungkinkan evaluasi yang komprehensif terhadap peran *sequence windowing* dalam meningkatkan kemampuan model GRU untuk memprediksi pendapatan penjualan secara akurat pada skala multi-kota.

Persiapan Data

Tahap pertama dalam penelitian ini adalah persiapan data, yang bertujuan untuk memastikan bahwa data yang digunakan dalam proses pelatihan model memiliki kualitas serta format yang sesuai untuk kebutuhan. Pada tahap ini, langkah-langkah utama yang dilakukan meliputi pemilihan data dan agregasi data.

Data yang digunakan dalam penelitian ini bersumber dari Iowa dataset yang bersifat terbuka [18], yang menyediakan catatan penjualan minuman di negara bagian Iowa, Amerika Serikat. Dataset ini ditampilkan pada Tabel 1, menyediakan catatan penjualan historis pada tingkat transaksi dan mencakup berbagai variabel, antara lain tanggal penjualan, jumlah botol yang terjual (*bottles sold*), total nilai penjualan dalam dolar ($sale_dollars$), serta informasi spasial seperti nama kota dan lokasi toko. Secara keseluruhan, dataset mencakup data dari 442 kota dengan total 10.514.546 entri yang dikumpulkan selama rentang waktu empat tahun dua bulan.


Dalam tahap persiapan data, dilakukan konversi kolom tanggal ke dalam format *datetime* agar dapat diolah secara kronologis. Untuk memfokuskan analisis pada kota-kota dengan volume penjualan signifikan, dipilih dua puluh kota dengan total penjualan tertinggi sebagai fokus utama.

Selanjutnya dilakukan agregasi dengan frekuensi harian (*daily resampling*) menggunakan fungsi $resample('D')$ untuk menjumlahkan total penjualan setiap harinya. Agregasi dengan frekuensi bulanan (*monthly resampling*) menggunakan fungsi $resample('M')$ untuk menjumlahkan total penjualan setiap bulannya. Agregasi bertujuan untuk skala prediksi yang dibutuhkan dari model yaitu skala harian dan bulanan.

Tabel 1. Jumlah dataset

Keterangan	Besaran Nilai
Jumlah data	10.514.546
Jumlah kota	442
Rentang waktu	4 Tahun 2 bulan





Pemrosesan Data

Tahapan kedua dari penelitian ini yaitu tahap pemrosesan data yang bertujuan memastikan bahwa data berada dalam format numerik yang sesuai, bebas dari nilai ekstrem yang mengganggu, serta siap digunakan untuk pelatihan model. Beberapa langkah utama dalam tahapan ini dijelaskan sebagai berikut: Pertama, pembersihan data dari entri kosong, nilai nol, dan penanganan potensi anomali, guna memastikan integritas dan kualitas data yang akan digunakan dalam proses pelatihan model.

Kedua, pemodelan difokuskan pada kota dengan pendapatan terbesar dan kota dengan *outlier* besar berdasarkan total penjualan kumulatif selama periode 2018-2022. Untuk menangkap pola musiman mingguan dalam data penjualan, dilakukan rekayasa fitur *dayofweek* (0 untuk Senin hingga 6 untuk Minggu) dari *timestamp*. Fitur ini kemudian direpresentasikan menggunakan teknik *one-hot encoding* sehingga menjadi variabel biner yang dapat diolah oleh model GRU.

Ketiga, untuk dapat digunakan oleh model GRU, data diubah ke dalam bentuk deret waktu dengan jendela berurutan (*sequential window*) sepanjang T hari (misalnya, 15 atau 30 hari). Setiap potongan deret waktu sepanjang T dijadikan sebagai input untuk memprediksi nilai penjualan pada hari ke-t+1.

Keempat, data pendapatan penjualan dinormalisasi menggunakan metode *MinMaxScaler* seperti pada persamaan (1) [19]. Normalisasi dilakukan agar skala antar fitur konsisten, sehingga tidak ada fitur yang paling dominan diakibatkan angka yang besar. Skala normalisasi *MinMaxScaler* memiliki rentang dari 0 hingga 1 [20].


$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Pemodelan

Pada tahap ini, dilakukan pembangunan model pembelajaran mendalam menggunakan arsitektur GRU untuk memprediksi nilai penjualan berdasarkan data historis berurutan. GRU dipilih karena kemampuannya dalam menangkap ketergantungan jangka panjang dari data sekuensial secara lebih efisien dibandingkan arsitektur *Recurrent Neural Network* (RNN) dan lebih cepat komputasinya dibandingkan dengan *Long-Short Term Memory* (LSTM) [10]. Persamaan GRU ditampilkan pada persamaan (2) yang terdiri dari beberapa komponen utama: *reset gate* r_t , *update gate* z_t , *candidate hidden state* \tilde{h}_t , dan *hidden state* h_t saat ini [GRUequation][21]. Pertama, *reset gate* $r_t = \sigma_g(W_r X_t + R_r h_{t-1} + b_{Wr})$ mengontrol seberapa banyak informasi dari *hidden state* h_{t-1} sebelumnya yang harus dilupakan. Kemudian, *update gate* $z_t = \sigma_g(W_z X_t + R_z h_{t-1} + b_{Wz})$ menentukan proporsi informasi yang akan dibawa dari *hidden state* sebelumnya versus dari *state* kandidat. *Candidate hidden state* dihitung dengan $\tilde{h}_t = \tanh(W_x X_t + r_t * R_h h_{t-1})$, yang memadukan masukan saat ini dan informasi terdahulu yang telah disaring. Akhirnya, *hidden state* saat ini diperbarui dengan interpolasi antara *candidate* dan *previous state* menggunakan $h_t = (1 - z_t) * \tilde{h}_t + z_t * h_{t-1}$. Output model GRU dihitung dengan $y_{tGRU} = \sigma_g(W_y h_t + b_y)$. Kombinasi gerbang ini memungkinkan GRU secara adaptif menyimpan atau melupakan informasi sesuai kebutuhan, membuatnya efisien dalam memodelkan dinamika temporal tanpa kompleksitas sebanyak LSTM.

$$\begin{cases} r_t = \sigma_g(W_r X_t + R_r h_{t-1} + b_{Wr}) \\ z_t = \sigma_g(W_z X_t + R_z h_{t-1} + b_{Wz}) \\ \tilde{h}_t = \tanh(W_x X_t + r_t * R_h h_{t-1}) \\ h_t = (1 - z_t) * \tilde{h}_t + z_t * h_{t-1} \\ y_{tGRU} = \sigma_g(W_y h_t + b_y) \end{cases} \quad (2)$$





- X_t (Input): Vektor input pada waktu t , berisi fitur masukan (seperti harga, volume, waktu, dll).
- W (Bobot input): Matriks bobot yang menghubungkan input X_t ke berbagai komponen internal GRU (gate dan candidate state). Contoh: W_r , W_z , dan W_x .
- R (Bobot rekuren): Matriks bobot yang menghubungkan *hidden state* sebelumnya h_{t-1} ke gate. Contoh: R_r , R_z , R_h . Biasanya disebut juga *recurrent weight*.
- b (Bias): Vektor bias yang ditambahkan pada perhitungan masing-masing gate dan output. Contoh: b_{W_r} , b_{W_z} , b_{W_y} .

Model yang digunakan terdiri atas dua lapisan GRU bertingkat (*stacked GRU*) dengan ukuran tersembunyi (*hidden size*) sebesar 64 unit. Setiap input ke model memiliki dimensi *input_size* yang disesuaikan dengan jumlah fitur yang telah dikonstruksi dari data sekuensial dan variabel waktu seperti hari dalam seminggu (*day of week*) dan bulan dalam setahun yang telah diencode secara *one-hot*. Jika targetnya dalam skala harian, maka jumlah fitur hasil rekayasa fitur variabel waktu yaitu 7 fitur (senin, selasa, ... minggu). Jika targetnya dalam skala bulanan, maka jumlah fitur hasil rekayasa fitur variabel waktu yaitu 12 fitur (Januari, Februari, ... Desember).


Arsitektur model diakhiri dengan satu lapisan linier penuh (*fully connected layer*) yang mengubah keluaran dari lapisan GRU menjadi satu nilai skalar yang merepresentasikan hasil prediksi. Untuk mengatasi prediksi bernilai negatif yang tidak realistis dalam konteks nilai penjualan, diterapkan fungsi aktivasi *Leaky ReLU* pada output akhir. Fungsi aktivasi *Leaky ReLU* memungkinkan sejumlah kecil nilai negatif tetap lolos, yang berguna untuk menghindari *dying ReLU problem*, sambil tetap membatasi dominasi nilai negatif yang besar [22]. *Dying ReLU problem* menyebabkan sewaktu-waktu model sulit belajar dan selalu menghasilkan nilai 0 saat pelatihan. Setelah melewati proses fungsi aktivasi, keluaran dari jaringan dibandingkan dengan nilai target untuk menghitung nilai kerugian. Dalam penelitian ini, fungsi kerugian utama yang digunakan adalah *Root Mean Squared Error* (RMSE) karena sensitivitasnya terhadap prediksi ekstrem dan kesesuaiannya dengan satuan metrik asli yang digunakan dalam penilaian performa model [16]. Fungsi kerugian RMSE memiliki sifat tidak terlalu sensitif terhadap nilai ekstrim seperti halnya *Mean Squared Error* (MSE) dan tidak terlalu halus seperti *Root Mean Squared Logarithmic Error* (RMSLE) [23]. Setelah melalui proses fungsi kerugian, model dioptimasi menggunakan algoritma *Adam Optimizer* dengan laju pembelajaran sebesar 0,001. Model dilatih selama 100 epoch dan diuji terhadap data uji yang telah dipisahkan sebelumnya.

Evaluasi Model

Tahapan keempat dari penelitian ini yaitu Evaluasi Model. Untuk mengevaluasi kinerja model prediktif yang dikembangkan pada tahapan ketiga, digunakan dua metrik utama, yaitu *Root Mean Squared Error* (RMSE) dan *Willmott's d-index* (*d-index*). Pemilihan metrik ini mempertimbangkan kebutuhan untuk menilai akurasi absolut dan kesesuaian pola prediksi terhadap data aktual.

RMSE digunakan untuk mengukur deviasi rata-rata kuadrat antara nilai yang diprediksi oleh model dan nilai aktual. RMSE dihitung berdasarkan akar dari rata-rata kuadrat error, yang memberikan hasil dalam satuan yang sama dengan target aslinya. Persamaan RMSE ditampilkan pada persamaan (3). Semakin kecil nilai RMSE, semakin baik performa prediktif model. Sementara itu, *Willmott's d-index* (d) [24] digunakan sebagai metrik komplementer untuk mengukur tingkat kesesuaian atau kecocokan antara pola hasil prediksi dengan data actual dan persamaannya ditampilkan pada persamaan (4). *d-index* berada pada rentang antara 0 (model buruk) hingga 1 (model sempurna). Berdasarkan penelitian [17], hasil prediksi dikatakan baik apabila nilai *d-index* melebihi nilai 0,58. Pada





penelitian ini, target nilai *d-index* pada prediksi baik skala harian maupun bulanan yaitu sebesar 0,6.

Kombinasi penggunaan RMSE dan Willmott's *d-index* memungkinkan evaluasi model yang lebih unggul [24]. RMSE mengindikasikan seberapa besar rentang kesalahan prediksi secara absolut (dalam penelitian ini yaitu \$), sedangkan *d-index* mengindikasikan seberapa baik model mengikuti pola variasi data aktual. Pendekatan evaluasi ini memberikan landasan yang kuat dalam membandingkan performa antar model maupun antar skenario masukan fitur.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad (3)$$

$$d = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (4)$$

Keterangan:

RMSE = Root Mean Squared Error

P_i = nilai prediksi ke-*i*

O_i = nilai observasi (aktual) ke- *i*

\bar{O} = rata-rata nilai observasi

n = jumlah data

d = Willmott's *d-index* (Nilai *d* berada pada rentang 0 sampai 1, dengan *d* = 1 menunjukkan prediksi sangat sesuai dengan data aktual, dan *d* = 0 menunjukkan prediksi sangat buruk)


4. HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini yaitu data penjualan minuman dan didapatkan pada Iowa dataset yang bersifat terbuka. Jumlah dataset yang digunakan dapat dilihat pada Tabel 1 yang mencakup data dari 442 kota dengan total 10.514.546 entri yang dikumpulkan selama periode empat tahun dua bulan. Untuk memastikan kualitas data dan representativitas analisis, dilakukan proses pembersihan data dengan menghapus entri yang jumlahnya sangat sedikit pada kota tertentu. Selain itu, kota-kota yang menunjukkan nilai nol secara terus-menerus selama beberapa hari juga dikeluarkan dari pemodelan, karena kondisi tersebut mengindikasikan ketidakaktifan atau ketidakrepresentatifan data terhadap fenomena yang dianalisis.

Pola pendapatan pada dataset ditunjukkan pada Gambar 3. Secara umum, pendapatan memperlihatkan karakteristik yang fluktuatif dengan kecenderungan tren jangka panjang yang meningkat selama periode 2018–2022. Pada awal periode pengamatan, yaitu tahun 2018, pendapatan berada pada kisaran \$22.500.000 dan mengalami berbagai perubahan signifikan sepanjang waktu observasi. Beberapa puncak pendapatan tercatat pada awal tahun 2019, 2020, dan 2022, sementara nilai tertinggi terjadi pada akhir tahun 2021 dengan pendapatan mendekati \$42.500.000. Selain tren peningkatan jangka panjang, pola pendapatan juga menunjukkan fluktuasi musiman yang cukup jelas. Secara umum, lonjakan pendapatan cenderung terjadi pada awal tahun, diikuti oleh penurunan pada pertengahan hingga akhir tahun. Namun demikian, pada beberapa periode tertentu, khususnya menjelang akhir tahun, pendapatan relatif lebih tinggi dibandingkan awal tahun. Pola ini mengindikasikan adanya komponen musiman yang kuat dalam data pendapatan. Meskipun tren pendapatan secara keseluruhan menunjukkan peningkatan dari tahun 2018 hingga 2022, tingkat variabilitas pendapatan tetap tinggi dengan fluktuasi




yang tajam sepanjang tahun. Kondisi ini mengindikasikan bahwa selain tren dan musiman, terdapat faktor lain seperti aktivitas promosi, perubahan perilaku konsumsi, atau pengaruh eksternal yang turut memengaruhi dinamika pendapatan.




Gambar 3. Total Pendapatan Penjualan Per Bulan

Total pendapatan yang ditampilkan pada Gambar 3, menunjukkan total pendapatan penjualan dari total 442 kota. Namun, dari total 442 kota, hanya 20 kota dengan pendapatan tertinggi yang dipertahankan untuk pemodelan. Hal ini dilakukan karena dengan memilih pendapatan tertinggi, secara tidak langsung juga memilih kota dengan jumlah data yang paling banyak dan berpengaruh signifikan terhadap akurasi model prediksi. Daftar ke 20 kota yang terbesar ditampilkan pada Gambar 4. Namun dalam penelitian ini, dari ke 20 kota tersebut akan dipilih 2 kota untuk dijadikan pemodelan prediksi. Kota tersebut yaitu kota dengan pendapatan terbesar, kemudian dengan jumlah outlier terbesar.

Berdasarkan hasil visualisasi pada Gambar 4, Kota Des Moines menempati posisi teratas dengan pendapatan sebesar \$213.561.455, menjadikannya kota dengan kontribusi terbesar secara signifikan. Nilai ini lebih dari dua kali lipat penjualan kota di peringkat kedua, yaitu Cedar Rapids yang mencatat \$103.919.103. Perbedaan ini menunjukkan adanya konsentrasi aktivitas ekonomi yang sangat tinggi di Des Moines dibandingkan wilayah lain. Selain kota dengan pendapatan terbesar, pemodelan selanjutnya akan memilih kota dengan jumlah *outlier* terbesar dari ke 20 kota terbaik (Lihat Gambar 5). Hasil analisis menunjukkan bahwa Ankeny merupakan kota dengan jumlah *outlier* tertinggi, yaitu lebih dari 110 *outlier*, menjadikannya jauh lebih dominan dibandingkan kota-kota lain. Pemilihan kota dengan data yang memiliki jumlah *outlier* tertinggi yaitu melatih model agar handal dalam memprediksi pendapatan ketika terjadi perubahan data ekstrim [25].



Gambar 4. Kota terbaik berdasarkan total penjualan




Gambar 5. Jumlah outlier pada 20 kota dengan pendapatan tertinggi

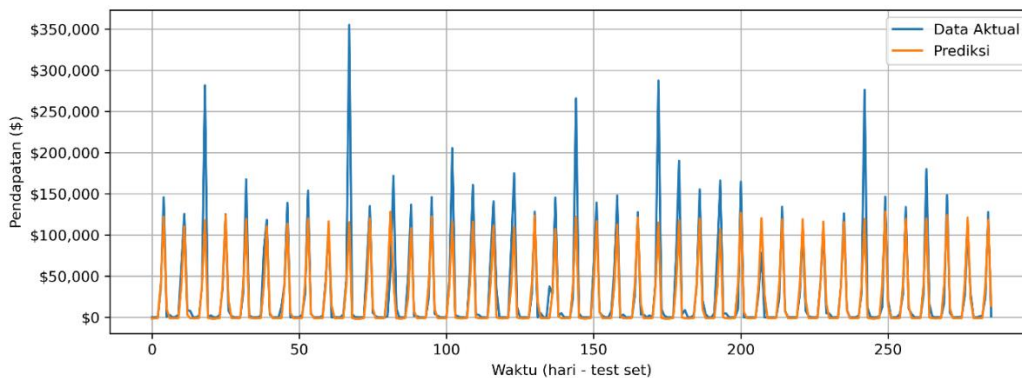
Hasil prediksi kedua kota yang dipilih yaitu Des Moines dan Ankeny berturut-turut ditampilkan pada Gambar 6-7 untuk skala prediksi harian dan Gambar 8-9 untuk skala prediksi bulanan. Pada Gambar 6 menunjukkan prediksi skala harian pada Kota Des Moines. Hasil prediksi menunjukkan pola prediksi mampu menggambarkan siklus pola pendapatan, meskipun data actual bersifat fluktuatif dengan puncak dan lembah yang cukup ekstrem. Nilai prediksi maksimum hanya mencapai \$400.000, meskipun data pendapatan aktual dapat mencapai \$500.000. Hal ini dikarenakan model gagal menangkap puncak penjualan yang sangat tinggi maupun lembah yang terlalu rendah, sehingga akurasi prediksi berkurang pada titik-titik ekstrem.

Untuk hasil prediksi skala harian pada Kota Ankeny ditampilkan pada Gambar 7. Model prediksi menunjukkan pola yang lebih stabil dan mampu mengikuti tren data aktual,

dengan nilai berada di sekitar kisaran \$100.000 dan hampir tidak pernah mencapai puncak ekstrem. Pada beberapa titik, khususnya hari-hari dengan penjualan ekstrem, perbedaan antara nilai aktual dan prediksi sangat besar. Keterbatasan ini menegaskan bahwa meskipun model dapat menangkap pola aktual, kemampuannya dalam memprediksi *outlier* atau kejadian ekstrem masih rendah. Hal ini dapat mempengaruhi keakuratan prediksi pada periode dengan lonjakan pendapatan signifikan. Dalam kasus prediksi pendapatan pada Kota Ankeny yang memiliki outlier yang tinggi, kecenderungan model masih bersifat *underestimation* pada hari dengan lonjakan besar. Faktor ini mungkin disebabkan oleh keterbatasan data latih yang tidak merepresentasikan frekuensi dan magnitudo lonjakan ekstrem secara memadai. Kemudian model cenderung menghasilkan nilai yang lebih aman atau mendekati rata-rata, sehingga tidak cukup responsif terhadap fluktuasi besar yang terjadi dalam data aktual.



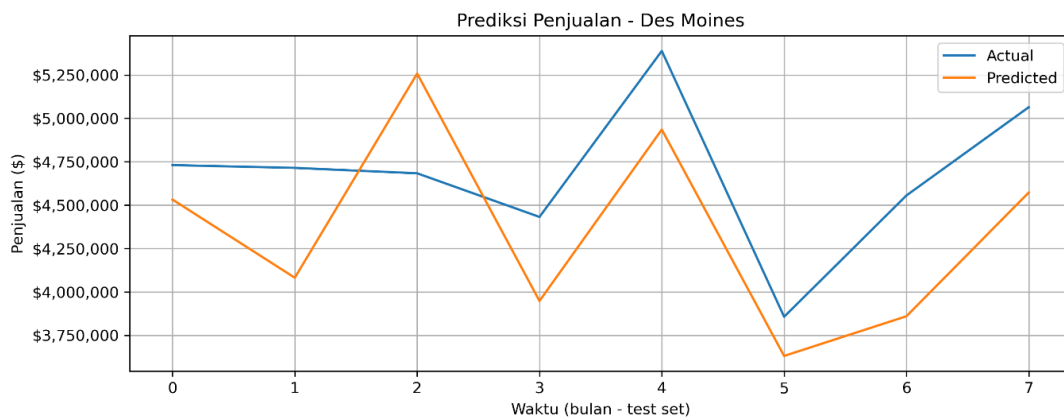
Gambar 6. Hasil prediksi harian dari model GRU-SW untuk kota Des Moines selama 7 bulan




Gambar 7. Hasil prediksi harian dari model GRU-SW untuk kota Ankeny selama 7 bulan

Hasil prediksi skala bulanan pada Kota Des Moines dan Ankeny berturut-turut ditampilkan pada Gambar 8-9. Grafik perbandingan penjualan aktual dan prediksi selama 7 bulan pada Kota Des Moines ditampilkan pada Gambar 8. Hasil menunjukkan bahwa model prediksi mampu mengikuti pola umum pergerakan pendapatan penjualan, meskipun masih terdapat ketidaktepatan pada beberapa titik. Secara keseluruhan, model berhasil menangkap tren naik-turun secara bulanan, tetapi tidak selalu akurat dalam memprediksi nilai puncak maupun titik terendah. Misalnya, pada bulan ke-2, prediksi penjualan lebih tinggi dari nilai aktual, dengan prediksi mendekati \$5,25 juta sementara nilai aktual berada di bawah \$4,75 juta. Sebaliknya, pada bulan ke-4, penjualan aktual mencapai puncak tertinggi lebih dari \$5,25 juta, sedangkan prediksi berada sedikit di bawahnya, sekitar \$5 juta.

Hasil prediksi skala bulanan pada Kota Ankeny ditampilkan pada Gambar 9. Grafik perbandingan penjualan aktual dan prediksi bulanan menunjukkan bahwa model prediksi memiliki kemampuan yang cukup baik dalam mengikuti tren umum pergerakan data. Pada bulan ke-1, prediksi sangat mendekati nilai aktual, menunjukkan performa yang baik di awal periode. Namun, terdapat perbedaan signifikan pada bulan ke-2 dan ke-3, di mana model cenderung memberikan prediksi lebih tinggi daripada nilai aktual. Sementara itu, puncak penjualan terjadi pada bulan ke-4 dengan nilai aktual di atas \$1.200.000, sedangkan prediksi berada sedikit lebih rendah, sekitar \$1.100.000. Baik nilai aktual maupun prediksi mengalami penurunan tajam pada bulan ke-5, meskipun model masih belum sepenuhnya tepat dalam memperkirakan kedalaman penurunan.



Gambar 8. Hasil prediksi bulanan dari model GRU-SW untuk kota Des Moines selama 7 bulan



Gambar 9. Hasil prediksi bulanan dari model GRU-SW untuk kota Ankeny selama 7 bulan

Model prediksi yang telah didapatkan pada penelitian ini perlu dievaluasi secara terukur menggunakan RMSE dan *Willmott's d-index* (d) yang dapat dilihat pada Tabel 2 dan 3. Secara keseluruhan pada tabel tersebut, model yang diajukan menggunakan GRU-SW memiliki kinerja model yang lebih baik dibandingkan GRU konvensional, baik untuk kota Des Moines maupun Ankeny. Evaluasi model prediksi skala harian ditunjukkan pada Tabel 2. Pada kota Des Moines, metode ini menghasilkan RMSE sebesar 64,080 dan nilai d sebesar 0,947, yang menunjukkan tingkat akurasi sangat tinggi. Sebaliknya, metode tanpa *sequential windowing* memiliki RMSE lebih besar (69,545) dan d sedikit lebih rendah (0,938), sehingga performanya kurang optimal. Pola serupa juga terjadi di kota Ankeny, di mana GRU dengan *sequential windowing* memberikan RMSE lebih rendah (30,171) dan d lebih tinggi (0,904) dibanding metode tanpa *sequential* (RMSE = 33,549 dan d = 0,869).

Sedangkan, Tabel 3 menyajikan hasil perbandingan kinerja model prediksi skala bulanan untuk dua kota: Des Moines dan Ankeny. Untuk Des Moines, model GRU-SW menunjukkan kinerja yang baik dengan nilai RMSE yang lebih rendah (513,46) dan d yang lebih tinggi (0,661) dibandingkan model GRU yang memiliki RMSE 556,67 dan d 0,537. Pola yang sama juga terlihat pada kota Ankeny, di mana model GRU-SW unggul dengan RMSE 112,81 dan d 0,846, sementara model GRU memiliki RMSE 131,53 dan d 0,792. Model GRU konvensional untuk memprediksi pendapatan penjualan dalam skala bulanan, gagal memenuhi target $d > 0,6$. Hasil ini secara konsisten membuktikan bahwa penggunaan metode GRU-Sequential Windowing menghasilkan akurasi prediksi yang lebih baik, dengan nilai RMSE yang lebih rendah dan d -index yang lebih tinggi, untuk kedua kota yang diteliti.

Table 2. Hasil evaluasi model prediksi harian

Metode	Metrik Evaluasi	Kota	
		Des Moines	Ankeny
GRU- <i>Sequential Windowing</i> (GRU-SW)	RMSE	64,080	30,171
	d	0,947	0,904
GRU	RMSE	69,545	33,549
	d	0,938	0,869

Table 3. Hasil evaluasi model prediksi bulanan


Metode	Metrik Evaluasi	Kota	
		Des Moines	Ankeny
GRU- <i>Sequential Windowing</i> (GRU-SW)	RMSE	513,46	112,81
	d	0,661	0,846
GRU	RMSE	556,67	131,53
	d	0,537	0,792

5. KESIMPULAN

Di era digital dan globalisasi saat ini, aktivitas bisnis semakin dinamis dan kompleks dengan adanya pergeseran pola konsumsi dari *offline* ke *online*, perkembangan teknologi informasi, perubahan kebijakan fiskal, serta fluktuasi ekonomi global dan lokal menciptakan ketidakpastian yang signifikan dalam pengelolaan pendapatan bisnis. Kondisi ini menuntut perusahaan dan pemerintah daerah untuk memiliki kemampuan prediksi pendapatan yang akurat guna mendukung pengambilan keputusan yang efektif.

Pada penelitian ini telah dibangun model prediksi pendapatan penjualan menggunakan data Iowa dataset sebagai data latih. Model yang digunakan yaitu menggunakan metode *machine learning* dengan pendekatan *sequential windowing* pada gated recurrent unit (GRU). Secara keseluruhan, metode GRU *sequential windowing* (GRU-SW) terbukti meningkatkan kualitas prediksi, karena model lebih mampu menangkap pola urutan data historis dengan baik.

Penelitian ini berhasil menjawab tantangan prediksi pendapatan penjualan berskala multi-kota yang ditandai oleh dinamika non-linear, fluktuasi temporal, dan perbedaan karakteristik antar wilayah. Hasil penelitian menunjukkan bahwa penerapan *sequential windowing* pada model GRU (GRU-SW) mampu meningkatkan akurasi prediksi pendapatan penjualan dibandingkan GRU konvensional. Model GRU-SW menghasilkan nilai RMSE yang lebih rendah dan d -index yang lebih tinggi, menandakan kesesuaian prediksi yang lebih




baik dengan data aktual. Meski demikian, prediksi pada kota dengan variasi data lebih besar (Des Moines) lebih menantang dibandingkan kota dengan pola data yang relatif stabil (Ankeny). Secara keseluruhan, GRU-SW terbukti menjadi pendekatan yang lebih unggul dalam menangkap pola temporal dan musiman, sehingga layak dijadikan pilihan utama untuk pemodelan prediksi pendapatan skala multi-kota.

Penelitian selanjutnya dapat memanfaatkan data penjualan dan pendapatan daerah lokal di tingkat kabupaten/kota di Indonesia untuk memvalidasi pendekatan GRU-SW pada konteks pasar yang berbeda. Integrasi faktor lokal seperti hari libur nasional, kebijakan daerah, dan heterogenitas spasial antar wilayah diharapkan dapat meningkatkan akurasi prediksi serta memperluas penerapan model sebagai alat pendukung perencanaan fiskal dan kebijakan publik berbasis data.

6. REFERENSI

- [1] T. Lynn, P. Rosati, E. Conway, D. Curran, G. Fox, and C. O’Gorman, *Digital Towns Accelerating and Measuring the Digital Transformation of Rural Societies and Economies*. 2022. doi: 10.1007/978-3-030-91247-5_3.
- [2] X. Tu, V. Shi, M. Zhang, and G. Lv, “The impact of residents’ online consumption on offline consumption—an ordered probit semi-parametric estimation method,” *Sustain.*, vol. 13, no. 18, 2021, doi: 10.3390/su131810047.
- [3] A. Hamzah, “Daya Prediksi Pajak, Laba Dan Arus Kas Terhadap Pajak Masa Depan Dengan Variabel Kontrol Ukuran Perusahaan (Studi Empiris Pada Perusahaan Manufaktur Yang Terdaftar Di Bei Tahun 2009 – 2014),” *J. Audit. Financ. Forensic Account.*, vol. 3, no. 2, pp. 1–12, 2015, [Online]. Available: <https://journal.trunojoyo.ac.id/jaffa/article/view/1394>
- [4] M. Kureljusic and E. Karger, “Forecasting in financial accounting with artificial intelligence – A systematic literature review and future research agenda,” *J. Appl. Account. Res.*, vol. 25, no. 1, pp. 81–104, 2024, doi: 10.1108/JAAR-06-2022-0146.
- [5] S. Danninger, “Revenue Forecasts As Performance Targets,” *IMF Work. Pap.*, vol. 05, no. 14, p. 1, 2005, doi: 10.5089/9781451860337.001.
- [6] S. E. Larson and M. R. Overton, “Centric Approach to Sales Tax Revenue Forecasting,” vol. X, pp. 1–22, 2025.
- [7] M. F. F. de Oliveira, P. H. M. Albuquerque, P. Y. Hao, and P. A. Henrique, “Mapping regional business opportunities using geomarketing and machine learning,” *Gest. e Prod.*, vol. 27, no. 3, pp. 1–15, 2020, doi: 10.1590/0104-530X4158-20.
- [8] M. Mujiyanto, S. Nurindahsari, and R. N. Izza, “Comparison of Linear Regression, ARIMA, Simple Exponential Smoothing, Hybrid ARIMA-LSTM, and EWMA in Forecasting Commodity Prices,” *Telematika*, vol. 17, no. 2, pp. 112–127, 2024, doi: 10.35671/telematika.v17i2.2932.
- [9] S. Nosouhian, F. Nosouhian, and A. K. Khoshouei, “A review of recurrent neural network architecture for sequence learning: Comparison between LSTM and GRU,” *Preprints.org*, no. July, pp. 1–7, 2021, doi: 10.20944/preprints202107.0252.v1.
- [10] N. Chandra, L. Ahuja, S. K. Khatri, and H. Monga, “Utilizing Gated Recurrent Units to Retain Long Term Dependencies with Recurrent Neural Network in Text Classification,” *J. Inf. Syst. Telecommun.*, vol. 9, no. 34, pp. 89–102, 2021, doi: 10.29252/jist.9.34.89.
- [11] Y. Zhang, R. Wu, S. M. Dascalu, and F. C. Harris, “A novel extreme adaptive GRU for multivariate time series forecasting,” *Sci. Rep.*, vol. 14, no. 1, pp. 1–10, 2024, doi: 10.1038/s41598-024-53460-y.
- [12] D. Pyo, “Enhancing GDP Growth Forecasting with LSTM , GRU , and Hybrid Model : Evidence from South Korea,” no. September, pp. 1–23, 2025, doi: 10.1177/21582440251359828.
- [13] C. Anusha and S. Maiti, “Optimizing Retail Inventory and Sales through Advanced Time Series Forecasting using Fine Tuned PrGB Regressor,” *IEEE Access*, vol. PP, p. 1, 2025, doi: 10.1109/ACCESS.2025.3605229.
- [14] Y. Ensafi, S. H. Amin, G. Zhang, and B. Shah, “Time-series forecasting of seasonal items sales using machine learning – A comparative analysis,” *Int. J. Inf. Manag. Data Insights*, vol. 2, no. 1, p. 100058, 2022, doi: 10.1016/j.jjimei.2022.100058.
- [15] H. Yang, P. Gupta, R. Fernández Galán, D. Bu, and D. Jia, “Seasonal Relevance in E-Commerce Search,” *Int. Conf. Inf. Knowl. Manag. Proc.*, pp. 4293–4301, 2021, doi:





- 10.1145/3459637.3481951.
- [16] I. A. Hasan and M. I. Yuca, "Prediction of Potential Evapotranspiration via Machine Learning and Deep Learning for Sustainable Water Management in the Murat River Basin," *Sustain.*, vol. 16, no. 24, 2024, doi: 10.3390/su162411077.
- [17] E. P. dos Santos, D. D. da Silva, C. H. do Amaral, E. I. Fernandes-Filho, and R. L. S. Dias, "A Machine Learning approach to reconstruct cloudy affected vegetation indices imagery via data fusion from Sentinel-1 and Landsat 8," *Comput. Electron. Agric.*, vol. 194, no. February, 2022, doi: 10.1016/j.compag.2022.106753.
- [18] State of Iowa, "IOWA Open Data."
- [19] F. D. Wahyuningtyas, A. Arafat, A. Stiawan, and D. Rolliawati, "Komparasi Algoritma Hierarchical, K-Means, dan DBSCAN pada Analisis Data Penjualan Melalui Facebook," *Explor. J. Sist. Inf. dan Telemat.*, vol. 14, no. 1, p. 7, 2023, doi: 10.36448/jsit.v14i1.2931.
- [20] L. Muradkhanli and Z. Karimov, "Customer Behavior Analysis Using Big Data Analytics and Machine Learning," *Probl. Inf. Soc.*, vol. 14, no. 2, pp. 61–67, 2023, doi: 10.25045/jpis.v14.i2.08.
- [21] G. Yigit and M. F. Amasyali, "Simple but effective GRU variants," *2021 Int. Conf. Innov. Intell. Syst. Appl. INISTA 2021 - Proc.*, 2021, doi: 10.1109/INISTA52262.2021.9548535.
- [22] K. Shivam, J. C. Tzou, and S. C. Wu, "A multi-objective predictive energy management strategy for residential grid-connected PV-battery hybrid systems based on machine learning technique," *Energy Convers. Manag.*, vol. 237, no. 195, p. 114103, 2021, doi: 10.1016/j.enconman.2021.114103.
- [23] L. Ciampiconi, A. Elwood, M. Leonardi, A. Mohamed, and A. Rozza, "A survey and taxonomy of loss functions in machine learning," pp. 1–55, 2024, [Online]. Available: <http://arxiv.org/abs/2301.05579>
- [24] C. J. Willmott, "On the validation of models," *Phys. Geogr.*, vol. 2, no. 2, pp. 184–194, 1981, doi: 10.1080/02723646.1981.10642213.
- [25] Y. Venkateswarlu *et al.*, "An Efficient Outlier Detection with Deep Learning-Based Financial Crisis Prediction Model in Big Data Environment," *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/4948947.
- [26] S. A. Makhmudov, "Forecasting banking system liquidity using payment system data in Uzbekistan," Graduate Institute of International and Development Studies, Working Paper HEIDWP05-2025, 2025.

