

BAB II

TINJAUAN PUSTAKA

2.1 Machine Learning untuk Forecasting Penjualan

Machine Learning (ML) telah menjadi pendekatan utama dalam *forecasting* penjualan modern karena kemampuannya mengolah data dalam jumlah besar dan kompleks, serta mendeteksi pola tersembunyi yang sulit diidentifikasi oleh metode statistik tradisional. Dalam beberapa tahun terakhir, adopsi *ML* dalam prediksi penjualan meningkat pesat, terutama di sektor ritel yang menghadapi dinamika pasar yang cepat berubah.

2.1.1 Peran *Machine Learning* dalam Prediksi Penjualan

Machine Learning (ML) memungkinkan sistem untuk belajar dari data historis dan membuat prediksi secara otomatis. Algoritma seperti *Decision Tree*, *Random Forest*, *Support Vector Regression* (SVR), dan *Gradient Boosting* telah digunakan untuk memodelkan tren penjualan dan perilaku konsumen. *Polynomial Regression* juga merupakan pendekatan yang efektif, terutama ketika hubungan antara variabel waktu dan penjualan menunjukkan pola nonlinier yang sederhana namun sistematis. Keunggulan *Polynomial Regression* terletak pada kemampuannya dalam menangkap tren melengkung tanpa memerlukan struktur pohon yang kompleks atau pemetaan fitur eksplisit seperti pada SVR. Selain itu, algoritma ini relatif ringan secara komputasi dan lebih mudah diinterpretasikan secara matematis.

Sebagai contoh, penelitian oleh Chen dkk., (2023) menunjukkan bahwa model *Polynomial Regression* mampu mencapai nilai R^2 sebesar 0,933 dalam memprediksi penjualan mingguan pada dataset Walmart, dengan performa yang stabil baik pada data pelatihan maupun pengujian, serta hasil yang kompetitif dibandingkan dengan model kompleks lainnya seperti *Random Forest* dan *Gradient Boosting*.

2.1.2 Adaptasi terhadap Perubahan Pasar

Krisis global seperti pandemi *COVID-19* telah menyoroti pentingnya adaptasi dalam forecasting penjualan, terutama dalam menghadapi perubahan perilaku konsumen yang tidak terduga. Studi oleh Kizgin dkk., (2025) meneliti strategi adaptasi prediksi penjualan selama krisis menggunakan berbagai metode machine learning seperti *Gradient Boosting* dan *CatBoost*. Kedua algoritma tersebut terbukti efektif dalam menyesuaikan prediksi penjualan terhadap dinamika pasar yang cepat berubah.

Namun demikian, algoritma-algoritma tersebut cenderung membutuhkan sumber daya komputasi yang tinggi serta parameter yang kompleks, yang tidak selalu dapat diakses oleh pelaku Usaha Mikro, Kecil, dan Menengah (UMKM). Dalam konteks ini, *Polynomial Regression* menjadi pilihan yang lebih praktis dan efisien. Dengan kemampuannya menangkap pola non-linier dalam data secara sederhana dan dapat diinterpretasikan dengan mudah, *Polynomial Regression* menawarkan pendekatan adaptif yang lebih ringan tetapi tetap akurat untuk menghadapi fluktuasi musiman, promosi dadakan, atau dampak krisis. Keunggulan

inilah yang menjadikannya sangat cocok untuk UMKM yang membutuhkan solusi prediktif yang tanggap, namun tetap terjangkau secara teknis.

2.1.3 Integrasi Data Eksternal dan Kompleksitas Model

Machine Learning juga memungkinkan integrasi berbagai variabel eksternal seperti data cuaca, tren media sosial, dan aktivitas promosi ke dalam model prediksi penjualan. Mirshekari dkk., (2024) mengembangkan model *Gaussian Process* yang menggabungkan berbagai kernel dan optimasi Bayesian untuk meningkatkan akurasi prediksi penjualan. Model ini menunjukkan kinerja tinggi namun membutuhkan proses komputasi dan tuning parameter yang sangat kompleks.

Berbeda dengan pendekatan tersebut, *Polynomial Regression* menawarkan solusi yang lebih sederhana namun tetap efektif, terutama ketika data eksternal dapat direpresentasikan dalam bentuk hubungan fungsional terhadap waktu atau variabel penentu lainnya. Meskipun tidak secara langsung menggabungkan variabel eksternal dalam struktur model yang kompleks, *Polynomial Regression* dapat menangkap efek tidak langsung dari faktor eksternal melalui perubahan pola dalam data penjualan historis. Misalnya, dampak promosi atau tren musiman dapat tercermin dalam pola naik-turun yang non-linier, yang sangat cocok dimodelkan oleh *Polynomial Regression* (Putra & Lestari, 2021).

Keunggulan utama *Polynomial Regression* dalam konteks ini terletak pada kemampuannya menangani kompleksitas data tanpa memerlukan proses *feature engineering* yang intensif (Gogoi dkk., 2023). Pendekatan ini memungkinkan

pelaku UMKM untuk tetap mendapatkan model prediktif yang andal tanpa harus memahami teknik lanjutan seperti *kernel optimization* atau *ensemble learning*. Selain itu, dengan pemilihan orde polinomial yang tepat, model ini dapat tetap presisi tanpa mengalami overfitting, menjadikannya sangat sesuai untuk dataset kecil seperti pada UMKM (Sutarno dkk., 2022).

2.1.4 Implementasi dalam Bisnis Mikro

Dalam konteks bisnis mikro, *machine learning* memberikan fleksibilitas dalam mengelola data penjualan yang fluktuatif dan musiman. Penggunaan algoritma seperti *XGBoost* dan *LSTM* telah terbukti efektif dalam memodelkan data penjualan dengan pola kompleks. Studi oleh Cao et al. (2024) menunjukkan bahwa model *CNN-LSTM hybrid* mampu mengatasi tantangan dalam prediksi penjualan ritel dengan akurasi yang tinggi.

Polynomial Regression menjadi alternatif yang unggul dan relevan. Model ini menawarkan keseimbangan antara akurasi dan kesederhanaan, serta mampu menangkap pola non-linier dalam data penjualan harian atau mingguan tanpa memerlukan arsitektur neural network atau tuning hiperparameter yang rumit.

Penelitian oleh (Yadav dkk., 2022) dan (Putra & Lestari 2021) menunjukkan bahwa *Polynomial Regression* dapat digunakan secara efektif dalam lingkungan bisnis berskala kecil, karena tidak membutuhkan data dalam jumlah besar dan dapat tetap memberikan prediksi yang stabil. Selain itu, (Gogoi dkk., 2023) menegaskan bahwa model ini memiliki fleksibilitas tinggi dalam menghadapi data penjualan yang tidak konsisten, suatu kondisi yang umum ditemukan di sektor UMKM.

Dengan demikian, *Polynomial Regression* sangat cocok diimplementasikan dalam sistem prediksi penjualan untuk UMKM, di mana keterbatasan sumber daya, kebutuhan respons adaptif terhadap pasar, dan preferensi terhadap metode yang dapat dijalankan secara cepat dan efisien menjadi pertimbangan utama.

2.1.5 Usaha Mikro dan Tantangannya dalam Peramalan Penjualan

Usaha Mikro, Kecil, dan Menengah (UMKM) merupakan tulang punggung perekonomian di banyak negara berkembang, termasuk Indonesia. Menurut data dari Kementerian Koperasi dan UKM RI, UMKM menyumbang lebih dari 60% terhadap Produk Domestik Bruto (PDB) nasional dan menyerap lebih dari 97% tenaga kerja Indonesia (KemenkopUKM, 2022). Di dalam kelompok ini, usaha mikro menempati porsi terbesar, baik dari sisi jumlah unit usaha maupun keterlibatan tenaga kerja.

Namun, meskipun berperan vital, usaha mikro menghadapi berbagai tantangan dalam hal pengelolaan bisnis, khususnya dalam melakukan peramalan penjualan (*sales forecasting*). Tantangan tersebut meliputi:

- a. Keterbatasan data historis yang terstruktur, karena pencatatan transaksi umumnya masih dilakukan secara manual atau tidak konsisten (Tambunan, 2019).
- b. Variabilitas permintaan yang tinggi akibat fluktuasi musiman, promosi spontan, atau pengaruh eksternal seperti pandemi dan inflasi.

Kurangnya literasi digital dan teknologi prediktif, yang membuat pelaku usaha mikro belum mampu memanfaatkan algoritma prediksi modern seperti machine learning (World Bank, 2021).

2.1.6 *Machine Learning*

Machine Learning (Pembelajaran Mesin) adalah bagian dari ilmu kecerdasan buatan (Faggella, Bengio dan Faggella, 2019), yang membuat komputer belajar dan bertindak seperti yang dilakukan manusia, dan meningkatkan pembelajaran mereka dari waktu ke waktu secara otomatis, dengan menerima data dan informasi dalam bentuk pengamatan dan interaksi dunia nyata (Faggella, 2018).

Machine learning secara algoritmis adalah proses komputasi yang menggunakan data input untuk mencapai tugas yang diinginkan tanpa diprogram secara manual, menghasilkan hasil tertentu melalui algoritma “*soft coded*” yang secara otomatis mengubah atau mengadaptasi arsitekturnya melalui pengulangan untuk menjadi sistem yang semakin baik dalam mencapai tugas yang diinginkan. Proses adaptasi ini, disebut pelatihan (training), menyediakan sampel data input bersama dengan hasil yang diinginkan, memungkinkan algoritma untuk mengkonfigurasi dirinya sendiri secara optimal sehingga tidak hanya dapat menghasilkan hasil yang diinginkan ketika disajikan dengan input pelatihan, tetapi juga dapat menggeneralisasi untuk menghasilkan hasil yang diinginkan dari data baru yang sebelumnya tidak terlihat (Naqa dan Murphy, 2015).

2.1.7 *Polynomial Regression*

Polynomial Regression adalah salah satu bentuk regresi yang diperluas dari regresi linier, di mana hubungan antara variabel independen (*predictor*) dan variabel dependen (respon) dimodelkan sebagai polinomial orde n . Model ini sangat berguna ketika data menunjukkan pola non-linier yang tidak dapat ditangkap oleh model linier biasa.

Secara matematis, model *Polynomial Regression* dapat dinyatakan sebagai:

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_n x^n + \varepsilon$$

Persamaan 2.1 Regresi polinomial umum berderajat n

di mana:

- a. y adalah variabel target (misalnya penjualan).
- b. x adalah variabel prediktor (seperti waktu).
- c. $\beta_0 + \beta_1 + \beta_2 + \dots + \beta_n$ adalah koefisien model.
- d. ε adalah error term yang diasumsikan berdistribusi normal dengan rata-rata nol.

Untuk keperluan komputasi, model ini dapat direpresentasikan dalam bentuk notasi matriks sebagai berikut:

$$y = X\beta + \varepsilon$$

Persamaan 2.2 Notasi matriks model regresi linear

Persamaan diatas merupakan bentuk umum dari model regresi linear, yang juga digunakan dalam regresi polinomial sebagai kasus khusus. Dalam hal ini, vektor y merepresentasikan variabel dependen atau target, sedangkan matriks X merupakan matriks fitur hasil transformasi dari variabel independen ke dalam bentuk polinomial, yang meliputi $x, x^2, x^3, \dots, x^n$. Vektor β adalah sekumpulan parameter atau koefisien regresi yang akan dihitung untuk membentuk model prediktif. Estimasi parameter β dilakukan dengan pendekatan *least squares* (kuadrat terkecil), yaitu suatu metode yang bertujuan meminimalkan jumlah kuadrat selisih antara nilai aktual dan nilai hasil prediksi oleh model. Adapun rumus yang digunakan untuk menghitung parameter tersebut adalah sebagai berikut:

$$y = \begin{bmatrix} y1 \\ y2 \\ \dots \\ ym \end{bmatrix}, X = \begin{bmatrix} 1 & x_1 & x_1^2 & \dots & x_1^n \\ 1 & x_2 & x_2^2 & \dots & x_2^n \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_m & x_m^2 & \dots & x_m^n \end{bmatrix}, \beta = \begin{bmatrix} \beta1 \\ \beta2 \\ \dots \\ \beta n \end{bmatrix}$$

Persamaan 2.3 *Vector and Matrix Polinomial Regression*

Parameter β dapat dihitung menggunakan pendekatan least squares:

$$\hat{\beta} = (X^T X)^{-1} X^T y$$

Persamaan 2.4 *Ordinary Least Squares formula*

Pendekatan ini meminimalkan jumlah kuadrat selisih antara nilai observasi dan nilai yang diprediksi oleh model. Semakin tinggi orde n , semakin fleksibel model dalam menyesuaikan pola data. Namun, peningkatan orde polinomial secara berlebihan dapat menyebabkan *overfitting*, yakni model terlalu akurat terhadap data pelatihan tetapi buruk dalam memprediksi data baru.

Dalam konteks *forecasting* penjualan, *Polynomial Regression* memungkinkan pemodelan terhadap pola penjualan yang tidak mengikuti tren linier misalnya, fluktuasi musiman, pertumbuhan awal yang cepat lalu stabil, atau adanya siklus tertentu. Hal ini membuatnya ideal untuk digunakan dalam bisnis mikro yang sering mengalami perubahan permintaan berdasarkan waktu, promosi, atau faktor eksternal lainnya (Yadav dkk., 2022). Keunggulan utama dari *Polynomial Regression* adalah kemampuannya menyesuaikan model dengan tren data yang kompleks tanpa memerlukan pendekatan berbasis *neural network* yang lebih rumit. Dengan menambahkan derajat (orde) polinomial yang sesuai, model dapat menangkap dinamika perubahan penjualan secara lebih presisi. Namun, penentuan orde yang terlalu tinggi dapat menyebabkan *overfitting*, yaitu ketika model terlalu menyesuaikan diri dengan data pelatihan dan kehilangan kemampuan generalisasi terhadap data baru.

Dalam studi (Yadav dkk., 2022), *Polynomial Regression* berhasil memodelkan tren penjualan ritel dengan akurasi yang lebih baik dibandingkan regresi linier sederhana. Hal ini sejalan dengan temuan (Fahrudin dkk., 2022) yang menunjukkan bahwa penggunaan *Polynomial Regression* dalam bisnis UMKM dapat meningkatkan keakuratan perencanaan produksi dan stok, terutama ketika data penjualan bersifat tidak stabil atau bersiklus. Model ini juga sangat fleksibel dalam implementasinya karena dapat dibangun dengan pustaka *scikit-learn* di *Python*, serta dapat dikombinasikan dengan teknik validasi silang (*cross-validation*) dan tuning parameter untuk mengoptimalkan performa prediksi

Alur dari algoritma *Polynomial Regression* dimulai dengan menyiapkan data input, yaitu pasangan nilai variabel independen (fitur) dan variabel dependen (target). Selanjutnya, dilakukan proses transformasi fitur di mana variabel independen dinaikkan ke pangkat tertentu sesuai derajat polinomial yang dipilih (misalnya derajat 2, 3, atau 4). Setelah fitur ditransformasikan, model melakukan pelatihan (training) menggunakan data latih untuk mencari koefisien terbaik yang meminimalkan selisih antara nilai prediksi dan nilai aktual. Setelah model dilatih, dilakukan prediksi terhadap data uji untuk mengukur kemampuan generalisasi model. Terakhir, hasil prediksi dievaluasi menggunakan metrik seperti *R-Squared* (R^2) dan *Root Mean Square Error* (RMSE) guna menilai akurasi dan performa model. Alur ini menjadikan *Polynomial Regression* efektif dalam menangkap hubungan non-linier antara variabel, khususnya dalam data time-series penjualan.

2.2 *State-of-the-Art*

Penelitian ke-1 dengan judul “*The Predictive Analysis of Sales Using Polynomial Regression*” oleh Yadav et al. (2022)¹ dalam *Journal of Artificial Intelligence Research*, 12(1), 77–85. Penelitian ini mengevaluasi kinerja Polynomial Regression dalam memprediksi data penjualan e-commerce di India dan membandingkannya dengan regresi linier. Hasilnya menunjukkan bahwa Polynomial Regression memberikan nilai MAPE dan MSE yang lebih rendah, serta R^2 yang lebih tinggi, menandakan model lebih efektif dalam menangani pola non-linier.

Penelitian ke-2 dengan judul “*Sales Forecasting Web Application in Small and Medium Enterprise*” oleh Fahrudin et al. (2022) dalam Jurnal 2021 International Seminar on Machine Learning, Optimization, and Data Science (ISMODOE). Fokus penelitian ini mengembangkan aplikasi berbasis web untuk memprediksi penjualan di sektor usaha kecil dan menengah (UKM). Aplikasi ini mengintegrasikan algoritma machine learning untuk membantu pelaku UKM melakukan estimasi penjualan secara real-time, sehingga dapat meningkatkan efisiensi operasional dan pengambilan keputusan bisnis yang lebih tepat.

Penelitian ke-3 dengan judul “*Comparative Analysis of Machine Learning Models for Accurate Retail Sales Demand Forecasting*” oleh Jewel et al., (2024) dalam *Journal of Computer Science and Technology Studies* (2024) 6(1) 204-210. Penelitian ini mengevaluasi dan membandingkan kinerja beberapa algoritma machine learning seperti Decision Tree, Random Forest, dan Support Vector Regression dalam memprediksi penjualan ritel. Studi ini menyoroti kekuatan dan

kelemahan masing-masing algoritma berdasarkan akurasi prediksi dan efisiensi komputasi, serta merekomendasikan model yang paling optimal untuk implementasi dalam sistem prediksi penjualan ritel.

Penelitian ke-4 dengan judul “Sales Forecasting for Small Medium Enterprises Using Machine Learning” oleh Yadav et al. (2023) dalam NORMA eResearch @NCI Library. Penelitian ini mengevaluasi efektivitas algoritma machine learning dalam memprediksi penjualan pada UKM. Menggunakan data toko farmasi dan superstore, studi ini menunjukkan bahwa XGBoost dan Random Forest mampu memberikan prediksi akurat, dengan R^2 tertinggi mencapai 0,98. Hasilnya menegaskan bahwa model prediktif berbasis ML dapat membantu UKM dalam perencanaan penjualan yang lebih tepat.

Penelitian ke-5 dengan judul “Sales Forecasting Using Regression-Based Machine Learning Algorithms in Supply Chain Environment” oleh Kanik (2023) dalam Thesis Master. Penelitian ini membahas penerapan berbagai model regresi, termasuk regresi polinomial, dalam memprediksi permintaan penjualan pada rantai pasok. Hasilnya menunjukkan bahwa regresi polinomial efektif dalam menangkap pola musiman dan tren non-linear, sehingga meningkatkan akurasi prediksi.

Penelitian ke-6 dengan judul “*A Comparative Study of Linear and Nonlinear Models for Aggregate Retail Sales Forecasting*” oleh Ching-Wu Chu & Guoqiang Peter Zhang (2003) dalam *International Journal of Production Economics*. Penelitian ini membandingkan efektivitas model linier (dengan pendekatan time series musiman) dan model non-linier seperti jaringan saraf tiruan

(neural networks) dalam memprediksi penjualan ritel agregat. Hasil penelitian menunjukkan bahwa model non-linier, khususnya neural networks yang dibangun dari data penjualan yang telah deseasonalized, mampu menghasilkan prediksi lebih akurat dibandingkan model linier. Penyesuaian musiman menjadi kunci penting untuk meningkatkan kinerja prediksi. Studi ini relevan bagi UKM atau bisnis musiman yang ingin mengadopsi metode prediktif non-linier seperti regresi polinomial atau jaringan saraf sederhana.

Penelitian ke-7 dengan judul “*Automated Demand Forecasting in Small to Medium-Sized Enterprises*” oleh Gaertner, T., Lippert, C., & Konigorski, S. (2024) dalam *arXiv preprint arXiv:2412.20420*. Penelitian ini mengembangkan sistem otomatis untuk peramalan permintaan pada UKM, mencakup pipeline lengkap mulai dari preprocessing data, pelatihan model, hingga pemilihan model terbaik berdasarkan validasi silang. Fokusnya adalah efisiensi dan skalabilitas sistem agar dapat diadopsi oleh UKM dengan keterbatasan teknis dan sumber daya. Studi ini mendukung penggunaan machine learning berbasis regresi ringan dan validasi adaptif sebagai solusi praktis dalam forecasting UMKM.

Penelitian ke-8 dengan judul “*Predictive Analysis for Big Mart Sales Using Machine Learning Algorithms*” oleh Ranjitha P. dan Spandana M. (2022) dalam *International Journal for Research in Applied Science and Engineering Technology (IJRASET)*. Penelitian ini membangun dan membandingkan beberapa model machine learning untuk memprediksi penjualan di Big Mart, dengan fokus pada algoritma regresi linier, regresi polinomial, regresi Ridge, dan XGBoost. Studi ini menunjukkan bahwa regresi polinomial mampu menangkap pola non-linier dalam

data penjualan lebih baik dibanding regresi linier, meskipun performa tertinggi dicapai oleh model XGBoost. Namun demikian, regresi polinomial tetap menonjol sebagai metode yang sederhana namun cukup akurat, terutama dalam konteks dataset dengan volume terbatas, seperti yang sering dijumpai dalam praktik usaha mikro dan kecil. Oleh karena itu, temuan ini memperkuat pilihan regresi polinomial sebagai pendekatan prediktif yang relevan untuk UKM yang ingin meningkatkan akurasi peramalan tanpa kompleksitas implementasi tinggi.

Penelitian ke-9 dengan judul *“Forecasting E-Commerce Trends: Utilizing Linear Regression, Polynomial Regression, Random Forest, and Gradient Boosting for Accurate Sales and Demand Prediction”* oleh Panga, N. K. R. (2023) dalam *International Journal of HRM and Organizational Behavior*. Penelitian ini menekankan bahwa regresi polinomial dapat menjadi solusi prediktif yang seimbang antara kompleksitas dan akurasi, terutama pada sektor e-commerce yang mengalami fluktuasi penjualan musiman. Meskipun ensemble model seperti Gradient Boosting lebih unggul secara akurasi, regresi polinomial memberikan hasil cukup kompetitif dengan pengolahan lebih ringan.

Penelitian ke-10 dengan judul *“Sales Prediction for Imported Fruits using a Linear Regression Model”* oleh Bhumireddy (2024) dalam *Proceedings of the 16th International Conference on Computational Intelligence and Communication Networks*. Penelitian ini menerapkan regresi linier untuk memprediksi penjualan buah impor berdasarkan harga, musim, dan volume. Meskipun fokus pada regresi linier, pendekatan ini menunjukkan pentingnya model prediktif sederhana yang

kemudian dapat dikembangkan lebih lanjut menggunakan regresi polinomial untuk pola penjualan non-linier dalam bisnis kecil

.

2.3 Matriks Penelitian

Di dalam matriks penelitian akan menjelaskan penelitian terkait yang berhubungan dengan penggunaan metode, tujuan, dan objek penelitian. Tabel 2.1 menggambarkan penelitian yang diusulkan dengan penelitian terkait.

Tabel 2.1 *State Of The Art*

No	Judul	Penulis dan Tahun	Ruang lingkup				
			Metode	Tujuan			Objek
				M	P	A	
1	The Predictive Analysis of Sales Using Polynomial Regression	Yadav dkk. (2022)	Polynomial Regression	✓	✓	✓	E-commerce

2	Sales Forecasting Web Application in Small and Medium Enterprise	Fahrudin dkk. (2022)	Polynomial Regression + Web App ML	✓	-	✓	UMKM makanan
3	Comparative Analysis of Machine Learning Models for Accurate Retail	Jewel dkk. (2024)	Poly. Regr. & lainnya	✓	✓	✓	Ritel urban

	Sales Demand Forecasting						
4	Sales Forecasting for Small Medium Enterprises Using Machine Learning	Yadav dkk. (2023)	XGBoost, RF	✓	✓	✓	Apotek & Superstore (UKM)
5	Sales Forecasting Using Regression- Based ML	(Kanik (2023)	Polynomial Regression & Regresi lainnya	✓	-	✓	Rantai pasok

	Algorithms in Supply Chain Environment						
6	A Comparative Study of Linear and Nonlinear Models for Aggregate Retail Sales Forecasting	Chu dkk., (2003)	Regresi Linier vs Neural Networks	✓	✓	✓	Ritel agregat musiman
7	Automated Demand Forecasting in	Gaertner dkk., (2023)	ML pipeline + Poly. Regr.	✓	-	✓	UKM manufaktur

	Small to Medium-Sized Enterprises						
8	Predictive Analysis for Big Mart Sales Using ML Algorithms	Hussain dkk., (2022)	Poly. Regr., XGBoost	✓	✓	✓	Ritel (Big Mart)
9	Prediksi penjualan ritel menggunakan regresi polinomial	Putra dkk., (2023)	Poly. Regr.	✓	-	✓	Ritel

10	Sales Prediction for Imported Fruits using a Linear Regression Model	Bhumiredy (2024)	Linear Regression (dasar)	✓	-	✓	Buah impor musiman
11	Forecasting Penjualan UMKM Menggunakan Polinomial Regression	Ramadhan (2025)	Polinomial Regression	✓	-	✓	Penjualan UMKM

Keterangan Kolom:

Metode: algoritma utama yang digunakan

M (Memprediksi): fokus pada prediksi penjualan

P (Perbandingan): membandingkan Polynomial Regression dengan metode lain

A (Akurasi): mengevaluasi model berdasarkan RMSE, dan/atau R^2

Objek: domain atau sektor yang diteliti.

Berdasarkan Tabel 2.1 di atas, dapat disimpulkan bahwa penelitian ini mengadaptasi beberapa parameter dari penelitian-penelitian sebelumnya, terutama dari sisi metode, tujuan, dan objek penelitian. Secara umum, metode yang banyak digunakan dalam studi terdahulu adalah Polynomial Regression, baik secara tunggal maupun dikombinasikan dengan algoritma lain seperti XGBoost, Random Forest, atau ML pipeline. Objek penelitian yang dianalisis juga beragam, mulai dari ritel, apotek, hingga berbagai jenis UKM. Penelitian ini memiliki kemiripan paling dekat dengan studi yang dilakukan oleh Fahrudin dkk. (2022), yang menggunakan Polynomial Regression untuk memprediksi penjualan pada UMKM makanan, serta penelitian oleh Gaertner dkk. (2023) yang memanfaatkan ML pipeline berbasis Polynomial Regression untuk memodelkan permintaan penjualan pada UKM manufaktur.

Terdapat beberapa *gap* yang belum banyak disentuh dalam penelitian-penelitian tersebut. Pertama, sebagian besar penelitian terdahulu menggunakan data penjualan yang sudah terstruktur atau bersumber dari sistem digital, sementara penelitian ini secara khusus berfokus pada UMKM mikro yang masih menggunakan pencatatan manual atau semi-digital, sehingga membutuhkan proses *pre-processing* dan normalisasi data yang lebih kompleks. Kedua, pendekatan yang digunakan dalam studi sebelumnya cenderung mengandalkan sistem dan sumber daya komputasi yang tidak selalu tersedia di lingkungan UMKM skala mikro. Sebaliknya, penelitian ini justru menawarkan pendekatan sederhana yang aplikatif dan dapat diadopsi secara langsung oleh pelaku usaha dengan keterbatasan infrastruktur. Ketiga, hingga saat ini belum banyak penelitian yang menguji

efektivitas Polynomial Regression dalam konteks perbandingan lintas rentang waktu (harian, mingguan, dan bulanan) secara eksplisit untuk UMKM lokal, sebagaimana dilakukan dalam studi ini. Oleh karena itu, penelitian ini menghadirkan kontribusi baru melalui pendekatan praktis yang kontekstual dan relevan dengan kebutuhan UMKM mikro di Indonesia.