

Perbandingan Metode *Random Forest* dan *Gradient Boosting* dalam Peramalan Permintaan Multi-Produk di CV Healfit Pangan Sehat (DietGo Kitchen) dengan Karakteristik *Demand* Berbeda

Comparison of Random Forest and Gradient Boosting Methods for Multi-Product Demand Forecasting at CV Healfit Pangan Sehat (DietGo Kitchen) with Different Demand Characteristics

Nisa Noviani Sudarman^{1*}, Gina Rahayu Wardiani², Ladzwina Mahardini³

^{1,2}Program Studi Teknik Industri, Fakultas Teknik, Universitas Ma'soem, Bandung, Indonesia

³Program Studi Rekayasa Logistik, Fakultas Sains dan Teknologi, Universitas Taruna Bakti, Bandung, Indonesia

*Penulis korespondensi: nisasudarman@gmail.com

Abstrak

Peramalan permintaan yang akurat merupakan faktor krusial dalam manajemen rantai pasok industri kuliner. Penelitian ini membandingkan performa dua metode *ensemble learning*, yaitu *Random Forest* dan *Gradient Boosting*, dalam memprediksi permintaan enam produk kuliner dengan karakteristik permintaan berbeda. Data yang digunakan adalah data penjualan bulanan di CV Healfit Pangan Sehat (DietGo Kitchen). Model dievaluasi menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan *Random Forest* memberikan performa superior untuk 5 dari 6 produk dengan rata-rata MAPE 31.61%, dibandingkan *Gradient Boosting* dengan rata-rata MAPE 35.43%. *Random Forest* terbukti lebih robust dalam menangani produk dengan pola permintaan stabil (Sei Ayam: MAPE 19.76%, Sei Sapi: MAPE 21.38%) dan *intermittent demand* (Sei Domba: MAPE 26.88%). Analisis *feature importance* menunjukkan bahwa lag-3, lag-6, dan trend menjadi prediktor terkuat dalam kedua model. *Gradient Boosting* hanya unggul pada satu produk (Sambal Bawang: MAPE 37.16%). Produk dengan volatilitas tinggi seperti Baked Grill Chicken menghasilkan MAPE 32.98%. Penelitian ini memberikan kontribusi praktis berupa *framework* pemilihan metode peramalan berdasarkan karakteristik permintaan produk dan rekomendasi untuk implementasi pada industri kuliner.

Kata kunci: *error, feature engineering, forecasting, Gradient Boosting, Random Forest*

Abstract

Accurate demand forecasting is a crucial factor in culinary industry supply chain management. This study compares the performance of two ensemble learning methods, namely *Random Forest* and *Gradient Boosting*, in predicting demand for six culinary products with different demand characteristics. The data used consists of monthly sales data at CV Healfit Pangan Sehat (DietGo Kitchen). Models were evaluated using *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE) and *Mean Absolute Percentage Error* (MAPE). The results show that *Random Forest* delivered superior performance for 5 out of 6 products with an average MAPE of 31.61%, compared to *Gradient Boosting* with an average MAPE of 35.43%. *Random Forest* proved more robust in handling products with stable demand patterns (Sei Ayam: MAPE 19.76%, Sei Sapi: MAPE 21.38%) and *intermittent demand* (Sei Domba: MAPE 26.88%). *Feature importance* analysis revealed that lag-3, lag-6, and trend were the strongest predictors in both models. *Gradient Boosting* outperformed *Random Forest* on only one product (Sambal Bawang: MAPE 37.16%). High-volatility products such as Baked Grill Chicken yielded a MAPE of 32.98%. This study provides a practical contribution in the form of a forecasting method selection framework based on product demand characteristics, along with recommendations for implementation in the culinary industry.

Keywords: *error, feature engineering, forecasting, Gradient Boosting, Random Forest*

How to Cite:

Sudarman, N.N., Wardiani, G.R. and Mahardini, L. (2026) 'Perbandingan metode *Random Forest* dan *Gradient Boosting* dalam peramalan permintaan multi-produk di CV Healfit Pangan Sehat (DietGo Kitchen) dengan karakteristik demand berbeda', *Journal of Integrated System*, 9(1), pp. 72–88. Available at: <https://doi.org/10.28932/jis.v9i1.15125>.

1. Pendahuluan

Industri kuliner Indonesia mengalami pertumbuhan yang sangat pesat dalam dekade terakhir dan telah menjadi salah satu pilar penting ekonomi kreatif nasional. Menurut data Kementerian Pariwisata dan Ekonomi Kreatif (2023), sektor kuliner berkontribusi sebesar 3,2% terhadap Produk Domestik Bruto (PDB) nasional dan menyerap lebih dari 4 juta tenaga kerja. Namun di balik pertumbuhan yang mengesankan ini, industri kuliner menghadapi tantangan operasional yang serius, khususnya dalam hal efisiensi dan keberlanjutan. Salah satu masalah kritis yang dihadapi oleh pelaku usaha kuliner adalah kesulitan dalam meramalkan permintaan dengan akurat, yang berdampak langsung pada dua permasalahan utama: pemborosan bahan baku akibat produksi berlebih (*overproduction*) dan kehilangan kesempatan penjualan akibat kekurangan stok (*stockout*).

Permasalahan peramalan permintaan ini bukan hanya soal efisiensi bisnis, tetapi juga memiliki implikasi yang luas terhadap keberlanjutan lingkungan. Secara global, sistem pangan bertanggung jawab atas 26% dari total emisi gas rumah kaca (Poore and Nemecek, 2018), dan sekitar sepertiga dari seluruh produksi pangan dunia terbuang sia-sia setiap tahunnya (FAO, 2011). Dalam konteks Indonesia, limbah makanan dari sektor *food service* diperkirakan mencapai 13 juta ton per tahun (Bappenas, 2021). Ketidakakuratan dalam peramalan permintaan menjadi salah satu penyebab utama pemborosan ini. Dora *et al.* (2021) dalam penelitiannya menunjukkan bahwa penerapan teknologi digital dan peramalan yang lebih baik dapat mengurangi *food waste* hingga 25-40% dalam rantai pasok makanan. Dengan demikian, peningkatan akurasi peramalan tidak hanya meningkatkan profitabilitas bisnis tetapi juga memberikan kontribusi signifikan terhadap keberlanjutan lingkungan dan pencapaian pembangunan berkelanjutan.

Perkembangan *machine learning* dalam dua dekade terakhir telah membuka paradigma baru dalam peramalan permintaan. *Random Forest*, yang diperkenalkan oleh Breiman (2001), menawarkan pendekatan *ensemble learning* dengan menggabungkan prediksi dari *multiple decision trees* yang dilatih secara independent. Keunggulan utama *Random Forest* terletak pada kemampuannya menangani ketidaklinearan, ketangguhan (*robustness*) terhadap *overfitting* melalui mekanisme *bagging*, dan kapabilitas untuk mengidentifikasi *feature importance* yang membantu interpretasi model. Fernández-Delgado *et al.* (2014) dalam studi komprehensif mereka yang pada 121 dataset menemukan bahwa *Random Forest* secara konsisten berada di antara metode dengan performa terbaik, terutama untuk dataset dengan ukuran kecil sampai menengah, karakteristik yang sangat relevan dengan kondisi data yang dimiliki oleh CV HealFit Pangan Sehat (DietGo Kitchen).

Gradient Boosting, dikembangkan oleh Friedman (2001), mengambil pendekatan yang berbeda dengan membangun *ensemble* secara sequential, dimana setiap *tree* baru dilatih untuk memperbaiki kesalahan dari *ensemble* sebelumnya. Metode ini telah menunjukkan hasil yang impresif dalam berbagai kompetisi *machine learning*, termasuk menjadi basis untuk *winning solution* (Smyl, 2020; Makridakis, Spiliotis and Assimakopoulos, 2022). Kristanti, Febrianta and Salim (2024) dalam penelitiannya pada prediksi *financial distress* perusahaan-perusahaan yang terdaftar di Indonesia menemukan bahwa *Random Forest* dan XGBoost menunjukkan performa yang superior dibandingkan metode tradisional, dengan *Random Forest* memberikan *robustness* yang konsisten sementara XGBoost menawarkan akurasi yang lebih tinggi ketika dilakukan *proper tuning*.

Meskipun terdapat banyak penelitian tentang aplikasi *machine learning* untuk peramalan, aplikasi spesifik pada peramalan permintaan untuk industri kuliner Indonesia masih sangat terbatas. Kajian terhadap literatur sebelumnya menunjukkan bahwa penelitian peramalan di Indonesia didominasi oleh domain lain. Amalia, Siregar and Nasution (2024) menggunakan ARIMA dan SVR untuk memprediksi harga saham Telkom Indonesia. Zulfia, Wibisono and Setiawan (2025) mengembangkan *decision support system* berbasis *Random Forest* untuk manajemen persediaan ritel, tetapi masih dalam tahap prototipe tanpa evaluasi metrik yang sistematis.

Penelitian ini berangkat dari identifikasi tiga *gap* fundamental dalam penelitian sebelumnya. Pertama, penelitian ini merupakan penelitian lanjutan dari penelitian sebelumnya yaitu “analisis perbandingan

metode *forecasting demand* untuk optimasi persediaan bahan baku di DietGo Kitchen” yang dilakukan oleh Sudarman (2024). Kedua, mayoritas penelitian sebelumnya menggunakan dataset dengan jumlah observasi yang sangat banyak. Kristanti, Febrianta and Salim (2024) menggunakan data dari 437 perusahaan dengan periode 10 tahun. Pradiptyo *et al.* (2024) menggunakan Rossmann dataset yang memiliki ribuan outlet dengan data terdahulu yang panjang. Sementara itu, realitas yang dihadapi oleh UMKM kuliner di Indonesia adalah keterbatasan data terdahulu atau banyak bisnis baru yang hanya memiliki 2-3 tahun data penjualan. Penelitian tentang efektivitas *ensemble methods* pada *limited data scenarios* (24-36 bulan) masih sangat jarang dilakukan. Ketiga, tidak ada penelitian yang secara eksplisit mengintegrasikan perspektif *sustainability* dalam evaluasi metode peramalan.

Karakteristik permintaan dalam industri kuliner memiliki keunikan yang membedakannya dari produk ritel pada umumnya. Hermawan and Kusuma (2023) mencatat bahwa produk ritel cenderung memiliki pola permintaan yang relatif homogen dalam satu kategori. Sebaliknya, dalam satu restoran, terdapat produk dengan pola permintaan yang sangat beragam: ada produk dengan permintaan yang stabil dan *predictable (stable demand)*, ada produk dengan fluktuasi yang sangat tinggi dan sulit diprediksi (*high volatility demand*), dan ada produk yang permintaannya jarang dan tidak teratur dengan *frequent zero-demand periods (intermittent demand)*. Syntetos and Boylan (2005) mengembangkan Croston's method untuk permintaan dengan fluktuasi yang sangat tinggi dan sulit diprediksi, namun metode ini tidak dirancang untuk barang tidak lama dengan keterbatasan kadaluwarsa seperti produk kuliner yang harus dijual dalam waktu singkat. Penelitian ini akan mengisi *gap* dengan menganalisis performa *Random Forest* dan *Gradient Boosting* untuk ketiga karakteristik permintaan tersebut dalam satu *framework* terpadu, memberikan arahan praktis untuk praktisi dalam memilih metode yang tepat untuk jenis produk yang berbeda.

Penelitian ini menggunakan data aktual CV Healfit Pangan Sheat dengan 6 produk kuliner untuk merepresentasikan karakteristik permintaan yang beragam. Data mencakup 36 bulan observasi dari Januari 2022 hingga Desember 2024. Pemilihan 36 bulan sebagai time horizon didasarkan pada beberapa pertimbangan. Pertama, durasi yang realistis dan terukur untuk restoran baru yang ingin mulai menerapkan peramalan berbasis data. Kedua, 36 bulan cukup untuk menangkap beberapa siklus musiman dan mengidentifikasi tren yang mendasar. Ketiga, durasi ini masih dalam *threshold* yang menantang untuk metode *machine learning*. Melalui system *feature engineering*, penelitian ini bertujuan memberikan rekomendasi yang berbasis bukti tentang metode *ensemble* mana yang paling efektif untuk karakteristik permintaan produk yang berbeda.

2. Metode

Penelitian ini menggunakan pendekatan kuantitatif dengan desain *comparative experimental research* untuk membandingkan performa dua metode *ensemble learning*, yaitu *Random Forest* dan *Gradient Boosting*, dalam konteks peramalan permintaan untuk industri kuliner Indonesia. Pemilihan pendekatan kuantitatif didasarkan pada karakteristik penelitian yang berfokus pada pengukuran objektif terhadap akurasi prediksi menggunakan metrik numerik (MAE, RMSE, MAPE) dan analisis statistik terhadap performa model (Creswell and Creswell, 2018).

Unit analisis penelitian adalah individual permintaan produk pada level SKU (*Stock Keeping Unit*) dengan 6 produk kuliner yang merepresentasikan karakteristik permintaan yang umum dijumpai dalam industri F&B: permintaan stabil, permintaan sangat fluktuatif, dan permintaan *intermittent*. Data yang digunakan dalam penelitian ini adalah data primer yang diperoleh langsung dari CV Healfit Pangan Sehat (DietGo Kitchen). Data mencakup histori penjualan data bulanan untuk 6 produk kuliner selama periode 36 bulan dari Januari 2022 hingga Desember 2024, menghasilkan total 216 data point (6 produk × 36 bulan). Periode 36 bulan dipilih karena durasi ini representatif untuk situasi nyata di UMKM yang umumnya memiliki keterbatasan historical data.

Feature engineering merupakan tahapan kritis dalam penelitian ini untuk mentransformasi *raw time series* data menjadi *feature matrix* yang dapat diproses oleh *machine learning algorithms*. Berbeda

dengan traditional metode *time series* seperti ARIMA dan Exponential Smoothing. Proses *feature engineering* dalam penelitian ini dilakukan secara sistematis dengan menciptakan empat kategori *features*, yaitu : *lag features*, *rolling statistics features*, *time-based features*, dan *trend features*. Pembagian data menjadi *training set* dan *test set* menggunakan *chronological split* dengan ratio 80:20, dimana 80% observasi awal (*approximately 24 bulan*) digunakan untuk *training* dan 20% observasi terakhir (*approximately 6 bulan*) digunakan untuk *testing*.

Seluruh proses pengolahan data dan analisis dilakukan dengan menggunakan metode *Random Forest* dan *Gradient Boosting* dengan menggunakan Python 3.8 dengan library scikit-learn untuk *machine learning*, pandas dan numpy untuk data manipulation, serta matplotlib dan seaborn untuk visualisasi hasil analisis. Evaluasi performa model dilakukan menggunakan empat aspek yang berbeda, diantara adalah *Mean Absolute Error (MAE)*, *Root Mean Square Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)*.

2.1 Random Forest

Metode *random forest* adalah pengembangan dari metode CART, yaitu dengan menerapkan metode *bootstrap aggregating (bagging)* dan *random feature selection* (Breiman 2001). Dalam *random forest*, banyak pohon ditumbuhkan sehingga terbentuk hutan (*forest*), kemudian analisis dilakukan pada kumpulan pohon tersebut. Pada gugus data yang terdiri atas n amatan dan p peubah penjelas, *random forest* dilakukan dengan cara (Breiman 2001; Breiman and Cutler 2003). Lakukan penarikan contoh acak berukuran n dengan pemulihan pada gugus data. Tahapan ini merupakan tahapan *bootstrap*.

- Dengan menggunakan contoh *bootstrap*, pohon dibangun sampai mencapai ukuran maksimum (tanpa pemangkasan). Pada setiap simpul, pemilihan pemilah dilakukan dengan memilih m peubah penjelas secara acak, dimana $m < p$. Pemilah terbaik dipilih dari m peubah penjelas tersebut. Tahapan ini adalah tahapan *random feature selection*.
- Ulangi langkah 1 dan 2 sebanyak k kali, sehingga terbentuk sebuah hutan yang terdiri atas k pohon. Respons suatu amatan diprediksi dengan menggabungkan (*aggregating*) hasil prediksi k pohon. Pada masalah klasifikasi dilakukan berdasarkan *majority vote* (suara terbanyak).

2.2 Gradient Boosting

Ide awal dari *Gradient Boosting* awalnya dikemukakan oleh Leo Breiman pada penelitiannya dimana mengatakan *boosting* memiliki *cost function* yang sesuai. Selanjutnya, *Gradient Boosting* dikembangkan lebih lanjut oleh Jerome H. Friedman yang dimana ia menggunakan algoritma tersebut untuk prediksi dan klasifikasi. Friedman juga menggambarkan *Gradient Boosting* yang mengonstruksikan model regresi dengan melakukan *fitting* secara sekuensial pada fungsi parameter sederhana ke “pseudo”-residual dengan square terkecil pada setiap iterasi. *Gradient Boosting* merupakan *learning tools* yang sangat kuat, sebuah model *ensemble* dari *decision tree* yang diperuntukan untuk klasifikasi dan regresi. Teknik *Gradient Boosting* dibuat dengan urutan pohon sederhana yang pada tiap pohon melakukan prediksi residual pada *tree* sebelumnya. Alur *Gradient Boosting* dimulai dengan:

1. Hitung inisialisasi prediksi dengan *decision tree* sederhana, menggunakan formula:

$$F_0(x) = \operatorname{argmin} \sum_{i=1}^n L(y_i, y) \quad (1)$$

2. Hitung kalkulasi residual yang merupakan nilai dari prediksi dengan menggunakan rumus :

$$\hat{y}_{im} = - \left[\frac{\partial \Psi(y_i, F(x_i))}{\partial F(x_i)} \right] F(x) = F_{m-1}(x) \quad (2)$$

3. Membangun *decision tree* lain yang melakukan prediksi pada residual dari semua variabel independen.
4. Memperbarui prediksi dengan prediksi baru yang dikalkulasi dengan *learning rate* menggunakan formulasi:

$$F_m(x) = F_{m-1}(x) + v \sum_{j=1}^{J_m} y_{jm} 1(x \in R_{jm}) \quad (3)$$

5. Mengulangi Langkah 2 sampai dengan 4 sesuai dengan jumlah tree.

2.3 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) adalah salah satu metode yang digunakan untuk mengukur tingkat keakuratan model peramalan. Nilai MAE menunjukkan rata-rata kesalahan (error) absolut antara hasil peramalan atau prediksi dengan nilai riil (Subagyo, 1986). Berikut formulasi untuk MAE.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_j - t_j| \quad (4)$$

2.4 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) Merupakan perhitungan yang digunakan untuk menghitung rata-rata persentase kesalahan mutlak (Sukerti, 2015). Semakin rendah nilai MAPE, kemampuan dari model peramalan yang digunakan dapat dikatakan baik (Maricar, 2019) dan untuk MAPE terdapat range nilai yang dapat dijadikan bahan pengukuran mengenai kemampuan dari suatu model peramalan (Hutasuhut, Anggraeni and Tyasnurita, 2014). Range nilai tersebut dapat dilihat pada Tabel 1.

Tabel 1. Range Nilai Akurasi Peramalan

MAPE (%)	Interpretasi Akurasi Peramalan
< 10	Sangat Baik
10 – 20	Baik
20 – 50	Cukup Baik
>50	Kurang

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_j - t_j|}{y_j} \quad (5)$$

2.5 Root Mean Square Error (RSME)

Root Mean Square Error (RMSE) merupakan metrik standar yang digunakan untuk mengukur performa model dan berfungsi sebagai bentuk standarisasi dari Mean Squared Error (MSE). RMSE mengukur akurasi keseluruhan model, namun cenderung memberikan bobot lebih besar pada kesalahan prediksi yang besar karena sifat kuadratnya. Formula untuk menghitung RMSE adalah sebagai berikut:

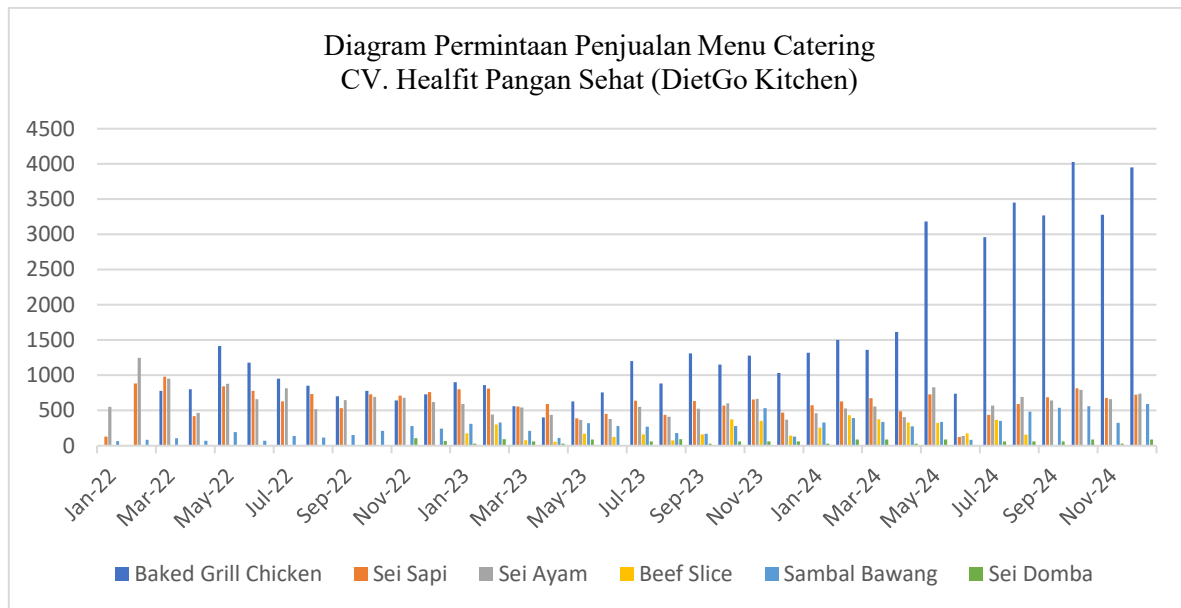
$$RSME = \sqrt{\frac{1}{n} \sum_{i=1}^N (y_j - t_j)^2} \quad (6)$$

3. Hasil dan Pembahasan

Pada bagian ini menyajikan hasil analisis perbandingan performa *Random Forest* dan *Gradient Boosting* dalam meramalkan permintaan produk kuliner, serta pembahasan mendalam terhadap temuan-temuan yang diperoleh. Analisis dilakukan terhadap 6 produk dengan karakteristik permintaan yang berbeda-beda, menggunakan 3 metrik evaluasi (MAE, RMSE, MAPE) untuk memberikan gambaran komprehensif tentang kinerja masing-masing metode.

3.1 Karakteristik Data Penelitian

Dataset penelitian ini terdiri dari 6 produk kuliner dengan pola permintaan yang sangat beragam. Produk-produk tersebut adalah Baked Grill Chicken, Sei Sapi, Sei Ayam, Sei Domba, Beef Slice, dan Sambal Bawang. Keberagaman ini merupakan representasi dari realitas bisnis kuliner dimana dalam satu restoran biasanya terdapat produk dengan tingkat popularitas yang berbeda-beda. Berikut karakteristik untuk masing-masing produk yang terdapat di CV Healfit Pangan Sehat (DietGo Kitchen). Berdasarkan grafik pada Gambar 1, maka dilakukan klasifikasi berdasarkan karakteristik pada masing-masing produk yang terdapat di CV Healfit Pangan Sehat (DietGo Kitchen). Klasifikasi dilakukan menjadi tiga bagian.



Gambar 1. Diagram permintaan penjualan menu catering CV Healfit Pangan Sehat (DietGo Kitchen)

3.1.1 Data dengan Permintaan Stabil

Sei Sapi dan Sei Ayam merupakan dua produk yang menunjukkan pola permintaan yang relatif stabil dan dapat diprediksi. Sei Sapi memiliki rata-rata penjualan 620 unit per bulan dengan standar deviasi 185 unit, yang berarti sebagian besar bulan penjualannya berkisar antara 435-805 unit. Pola ini menunjukkan bahwa produk ini memiliki basis pelanggan yang loyal dan tidak terlalu terpengaruh oleh fluktuasi eksternal. Apabila sebuah restoran yang setiap bulannya konsisten menjual sekitar 600 porsi, tidak terlalu naik drastis, tidak terlalu turun drastis. Ini adalah tipe produk yang aman untuk direncanakan karena dapat diperkirakan dengan cukup akurat berapa banyak bahan baku yang perlu disiapkan. Data permintaan untuk Sei Sapi dan Sei Ayam dapat dilihat pada Tabel 2.

Sei Ayam menunjukkan pola serupa dengan rata-rata 601 unit per bulan dan standar deviasi 198 unit. *Coefficient of variation* (perbandingan standar deviasi terhadap rata-rata) hanya sekitar 30%, yang menyatakan bahwa tingkat ketidakpastiannya hanya sepertiga dari nilai rata-ratanya, sehingga sei ayam ini tergolong sangat stabil. Stabilitas ini sangat menguntungkan untuk *forecasting* karena pola masa lalu cukup *reliable* untuk memprediksi masa depan.

Tabel 2. Tabel permintaan Sei Sapi dan Sei Ayam

Bulan	Sei Sapi			Sei Ayam		
	2022	2023	2024	2022	2023	2024
Januari	129	804	575	550	593	460
Februari	884	812	631	1246	442	531
Maret	978	557	675	954	544	555
April	420	593	490	464	437	405
Mei	844	390	731	878	365	829
Juni	781	450	125	660	380	140
Juli	631	640	440	817	550	570
Agustus	732	437	595	520	410	692
September	532	632	689	646	526	643
Oktober	727	572	816	691	600	791
November	713	655	678	679	665	662
Desember	759	471	723	621	368	739
Rata-rata		620			601	
Std		185			198	

3.1.2 Data dengan Permintaan Sangat Fluktuatif

Baked Grill Chicken dan Sambal Bawang adalah dua produk yang menunjukkan permintaan sangat berfluktuatif. Baked Grill Chicken memiliki rata-rata penjualan 1,401 unit tetapi dengan standar deviasi yang hampir sama besarnya (1,091 unit). Terdapat bulan dimana produk ini tidak memiliki permintaan sama sekali, tetapi terdapat bulan dimana permintaannya melonjak hingga 4,030 unit. *Coefficient of variation* mencapai 102%, yang artinya tingkat ketidakpastiannya lebih besar dari nilai rata-rata itu sendiri. Tabel permintaan untuk Baked Grill Chicken dan Sambal Bawang dapat dilihat pada Tabel 3. Permintaan yang sangat fluktuatif ini kemungkinan sangat terpengaruh oleh faktor musiman atau event tertentu. Misalnya, Baked Grill Chicken mungkin menjadi favorit saat musim liburan atau *event gathering*. Dengan karakteristik permintaan yang sangat fluktuatif maka pola masa lalu tidak bisa langsung dipakai untuk prediksi masa depan tanpa mempertimbangkan konteks yang lebih luas.

Tabel 3. Tabel permintaan Baked Grill Chicken dan Sambal Bawang

Bulan	Baked Grill Chicken			Sambal Bawang		
	2022	2023	2024	2022	2023	2024
Januari	0	900	1320	65	312	330
Februari	0	863	1501	82	330	391
Maret	780	560	1360	107	210	339
April	800	402	1614	70	110	276
Mei	1414	631	3182	193	321	338
Juni	1180	755	740	70	280	85
Juli	950	1200	2960	137	270	350
Agustus	850	882	3450	117	180	485
September	700	1310	3270	153	170	540
Oktober	780	1150	4030	211	280	560
November	641	1280	3278	280	535	325
Desember	730	1033	3950	241	130	595
Rata-rata	1401			263		
Std	1091			149		

3.1.3 Data dengan Permintaan Intermittent

Beef Slice dan Sei Domba merepresentasikan kategori produk yang dalam literatur supply chain disebut '*intermittent demand*' atau '*sporadic demand*' karena memiliki ciri-ciri khas yaitu sering tidak ada penjualan sama sekali (*zero demand*), kemudian tiba-tiba terdapat permintaan dalam jumlah tertentu. Hal ini serupa dengan penelitian Møller Christensen *et al.* (2021) yang melakukan kolaborasi dengan grosir besar di Scandinavia, ditemukan bahwa kontrol inventori untuk *fast-moving perishable products* (FFP) sangat menantang karena permintaan bervariasi pada hari-hari berikutnya, misalnya permintaan turun menjadi nol pada beberapa hari bahkan bulan akibat hari libur, musiman, cuti, atau menjelang akhir kampanye. Tabel permintaan untuk Beef Slice dan Sei Domba dapat dilihat pada Tabel 4.

Tabel 4. Tabel permintaan Beef Slice dan Sei Domba

Bulan	Beef Slice			Sei Domba		
	2022	2023	2024	2022	2023	2024
Januari	0	175	255	0	30	30
Februari	0	300	432	0	95	90
Maret	0	80	375	0	61	90
April	0	55	331	0	30	30
Mei	0	171	324	0	90	90
Juni	0	125	175	0	0	0
Juli	0	160	366	0	60	60
Agustus	0	75	155	0	95	60
September	0	161	0	0	30	60
Oktober	0	376	0	0	60	89
November	0	352	0	105	60	30
Desember	0	145	0	64	60	90
Rata-rata	127			43		
Std	144			37		

Beef Slice, meskipun rata-ratanya 127 unit per bulan, ternyata 39% dari bulan-bulan observasi (14 dari 36 bulan) tidak ada penjualan sama sekali. Ketika ada permintaan, biasanya dalam range 200-600 unit. Sei Domba adalah produk *slow-moving* dengan rata-rata hanya 43 unit per bulan dan juga *frequent zero-demand periods*. Produk seperti ini biasanya adalah menu spesial atau premium yang hanya dipesan oleh konsumen tertentu.

3.2 Analisis Perbandingan Performa Model

Pada subbab ini menyajikan analisis komprehensif terhadap hasil evaluasi performa *Random Forest* dan *Gradient Boosting* dalam meramalkan permintaan enam produk dengan karakteristik *demand* yang berbeda. Berikut merupakan hasil evaluasi model (lihat Tabel 5).


Tabel 5. Hasil Evaluasi Model

Nama Menu	Metode	MAE	RSME	MAPE (%)	Dipilih
Sei Ayam (Stabil)	Random Forest	142.29	170.23	19.76	RF
	<i>Gradient Boosting</i>	191.29	207.68	27.18	
Sei Sapi (Stabil)	Random Forest	141.66	165.67	21.38	RF
	<i>Gradient Boosting</i>	157.67	181.76	24.51	
Baked Grill Chicken (Fluktuatif)	Random Forest	1170.77	1253.21	32,98	RF
	<i>Gradient Boosting</i>	1339.48	1466.49	38.05	
Beef Slice (Intermittent)	Random Forest	213.26	225.77	Invalid	RF
	<i>Gradient Boosting</i>	229.81	244.79	Invalid	
Sambal Bawang (Fluktuatif)	<i>Random Forest</i>	208.22	232.88	40.56	GB
	Gradient Boosting	195.76	228.2	37.16	
Sei Domba (Intermittent)	Random Forest	13.66	17.12	26.88	RF
	<i>Gradient Boosting</i>	17.26	19.72	33.67	

3.2.1 Produk dengan Permintaan Stabil


Berdasarkan Tabel 1 diatas menyatakan bahwa Sei Ayam menghasilkan nilai MAPE 19.76% menggunakan metode *Random Forest* sedangkan untuk metode *Gradient Boosting* menghasilkan nilai 27.18%. Dalam konteks praktis, jika permintaan aktual adalah 600 unit, *Random Forest* akan memprediksi dalam rentang 481-719 unit ($\pm 19.76\%$), sementara *Gradient Boosting* memprediksi dalam rentang yang lebih lebar yaitu 437-763 unit ($\pm 27.18\%$). Range prediksi yang lebih sempit dari *Random Forest* mengindikasikan tingkat kepastian yang lebih tinggi, yang sangat *valuable* untuk perencanaan persediaan dan penjadwalan produksi. Hasil peramalan untuk Sei Ayam dapat dilihat pada Gambar 2 berikut ini.

Mean Absolute Error untuk Sei Ayam menunjukkan bahwa *Random Forest* rata-rata 142.29 unit per bulan, dibandingkan 191.29 unit untuk *Gradient Boosting*. Selisih 49 unit ini memiliki implikasi finansial yang signifikan. Dalam skenario *overstock*, dimana produksi melebihi *demand*, error 49 unit dapat mengakibatkan *waste*. Dalam skenario *stockout*, dimana *demand* melebihi *available inventory*, error 49 unit dapat mengakibatkan *lost revenue*.



Gambar 2. Hasil peramalan Sei Ayam


Sei Sapi menunjukkan *pttern* yang konsisten dengan Sei Ayam, dimana *Random Forest* menghasilkan MAPE 21.38% dibandingkan 24.51% untuk *Gradient Boosting*. Konsistensi pattern ini sangat penting karena mengindikasikan bahwa keunggulan *Random Forest* bukan anomali statistik dari spesifik dataset, melainkan *systematic advantage* yang dapat diandalkan untuk produk dengan karakteristik serupa. Hasil peramalan untuk Sei Sapi dapat dilihat pada Gambar 3. *Random Forest* menggunakan *bootstrap aggregating (bagging)* dimana *multiple decision trees* dilatih secara independent pada random subsets dari training data, kemudian hasil prediksi dirata-ratakan. Untuk data dengan pola yang relatif stabil dan konsisten, *averaging mechanism* ini sangat efektif dalam *reducing variance* dan *smoothing out random fluctuations*, menghasilkan prediksi yang lebih *reliable*. Sebaliknya, *Gradient Boosting* menggunakan *sequential boosting approach* dimana setiap pohon baru dilatih untuk memperbaiki error dari *ensemble* sebelumnya. Untuk data yang stabil, cara kerja *Gradient Boosting* yang memperbaiki kesalahan secara bertahap justru cenderung 'mengejar' variasi-variasi kecil yang sebetulnya bukan pola sebenarnya, melainkan hanya gangguan acak. Hal ini dapat menyebabkan model terlalu menyesuaikan diri dengan data (*overfitting*). Karena prosesnya berurutan, *Gradient Boosting* juga lebih mudah terpengaruh oleh nilai-nilai ekstrem atau data yang tidak normal dalam data, yang pada akhirnya dapat menurunkan akurasi prediksi ketika model digunakan pada data yang baru.



Gambar 3. Hasil Peramalan Sei Sapi

3.2.2 Produk dengan Permintaan Sangat Fluktuatif

Baked Grill Chicken menunjukkan karakteristik permintaan yang sangat fluktuatif dengan *coefficient of variation* melebihi 100% dan *range* permintaan dari 0 hingga 4,030 unit. MAPE tidak dapat dikalkulasi untuk produk ini, kemungkinan besar karena *presence of zero actual demand* dalam test set yang menyebabkan *division by zero* dalam formula MAPE. Ketidakmampuan menghitung MAPE itu sendiri merupakan indikator dari *extreme nature* data ini. Evaluasi berdasarkan MAE dan RMSE menunjukkan bahwa *Random Forest* menghasilkan *error* absolut yang lebih rendah dibandingkan *Gradient Boosting* (MAE 1170.77 dan 1339.48, *improvement* 12.6%). Error sebesar 1,170 unit pada rata-rata permintaan 1,070 unit berarti prediksi rata-rata meleset sebesar 109% dari nilai aktual, yang dalam *practical terms* hampir sama dengan *random guessing*. Hasil peramalan untuk Baked Grill Chicken dapat dilihat pada Gambar 4.




Gambar 4. Hasil Peramalan Baked Grill Chicken

Permintaan yang sangat fluktuatif ini kemungkinan besar disebabkan oleh faktor yang tidak tertangkap dalam *pure time series features* yang digunakan dalam penelitian ini. Produk seperti Baked Grill Chicken mungkin sangat dipengaruhi oleh aktivitas promosi, acara tertentu, atau bahkan efek viral dari sosial media yang menyebabkan lonjakan permintaan yang secara tiba-tiba. Sambal Bawang menunjukkan volatilitas yang lebih *moderate* dan satu-satunya produk dimana *Gradient Boosting* mengungguli *Random Forest*. *Gradient Boosting* menghasilkan MAE 195.76 dibandingkan 208.22 untuk *Random Forest*, improvement sebesar 6.0%. Meskipun margin relatif kecil, konsistensi *across* MAE dan RMSE metrics mengindikasikan keunggulan. Hasil peramalan untuk Sambal Bawang dapat dilihat pada Gambar 5.

Keunggulan *Gradient Boosting* untuk Sambal Bawang menawarkan *insight* penting tentang kondisi dimana pendekatan *Gradient Boosting* lebih unggul. Hipotesis yang dapat dikemukakan adalah bahwa fluktuasi Sambal Bawang, meskipun tinggi, memiliki struktur yang mendasari atau pattern yang dapat dipelajari. Perbedaan *Gradient Boosting* antara Baked Grill Chicken dan Sambal Bawang mengindikasikan *threshold effect* untuk permintaan yang sangat fluktuatif dan tidak dapat diprediksi, Namun untuk permintaan yang memiliki fluktuatif yang tinggi tapi masih terstruktur, pendekatan *Gradient Boosting* dapat memberikan keuntungan.

Hasil pada peramalan Sambal Bawang ini parallel dengan penelitian yang dilakukan oleh penelitian sebelumnya. Amalia, Siregar and Nasution (2024) membandingkan ARIMA dan SVR untuk prediksi harga saham Telkom Indonesia dan menemukan bahwa SVR mampu mengungguli ARIMA pada kondisi data non-linear. Paralel dengan penelitian ini, yaitu *Gradient Boosting* hanya mengungguli *Random Forest* pada Sambal Bawang. Produk Sambal Bawang pada penelitian disini merupakan produk dengan fluktuasi yang masih memiliki pola terstruktur, mirip dengan kondisi dimana SVR unggul atas ARIMA karena kemampuan menangkap non-linearitas. Ini menguatkan hipotesis bahwa metode berbasis *gradient* lebih efektif bila terdapat pola non-linear yang terstruktur, bukan volatilitas murni yang acak.




Gambar 5. Hasil peramalan Sambal Bawang

3.2.3 Produk dengan Permintaan Intermittent

Beef Slice menunjukkan pola permintaan yang unik diramalkan. Dari 36 bulan pengamatan, ternyata 39% bulan (sekitar 14 bulan) tidak terdapat penjualan sama sekali (*zero demand*). Sementara itu, pada bulan-bulan lainnya, permintaan berkisar antara 200 hingga 600 unit. Pola seperti ini sering terjadi periode tanpa penjualan yang diselingi dengan periode permintaan normal disebut sebagai *intermittent demand* atau permintaan terputus-putus.

Hasil peramalan dapat dilihat pada Gambar 6. Untuk produk ini, *Random Forest* menunjukkan hasil yang lebih baik dibandingkan *Gradient Boosting*. MAE untuk metode *Random Forest* 213.26 unit dan metode *Gradient Boosting* 229.81 unit. Peningkatan akurasinya 7.2% lebih baik dengan *Random Forest*. Sedangkan untuk RMSE pola konsisten dengan peningkatan 7.8%.




Gambar 6. Hasil peramalan Beef Slice

Nilai MAPE untuk Beef Slice adalah 225.77%, atau sama dengan nilai RMSE (225.77). Hal ini terjadi karena MAPE memang tidak cocok untuk produk dengan permintaan intermitten karena rumus MAPE membagi kesalahan dengan nilai aktual maka ketika permintaan aktual adalah nol, terjadi pembagian dengan nol (*undefined*), sehingga hasilnya bisa sangat tinggi atau tidak dapat dihitung sama sekali. Oleh karena itu, untuk produk seperti Beef Slice, akan difokuskan pada MAE dan RMSE. MAE sebesar 213 unit dengan rata-rata permintaan 180 unit menyatakan bahwa kesalahan relatif sekitar 118% dari nilai rata-rata sehingga terlihat tidak wajar. Sehingga untuk kasus seperti ini terdapat metode khusus seperti Croston's method atau Syntetos-Boylan Approximation yang dirancang khusus menangani pola permintaan jenis ini.

Random Forest unggul untuk produk Beef Slice karena *Random Forest* menggabungkan prediksi dari banyak "pohon keputusan" yang berbeda-beda. Keberagaman ini membuatnya lebih kuat dalam menangani pola yang tidak teratur. Bootstrap aggregating untuk metode ini menciptakan banyak variasi dari data, sehingga model dapat belajar dari berbagai kemungkinan pola permintaan, baik pada saat terdapat permintaan maupun tidak ada. *Random Forest* tidak mudah "bingung" oleh perubahan mendadak antara periode tanpa permintaan (0 unit) dan periode dengan permintaan (200-600 unit). Sebaliknya, *Gradient Boosting* kesulitan karena metode ini bekerja dengan memperbaiki kesalahan secara bertahap. Ketika dihadapkan pada perubahan drastis dari 0 unit ke 500 unit (atau sebaliknya), mekanisme perbaikan kesalahannya menjadi tidak efektif. Hasilnya bisa berupa prediksi yang terlalu ekstrem (*oscillating predictions*).

Sei Domba adalah produk dengan *volume* penjualan sangat rendah dengan rata-rata hanya 43 unit per bulan dan juga sering mengalami periode tanpa penjualan. Untuk produk ini, dapat dilihat pada Gambar 7, *Random Forest* menunjukkan lebih unggul dalam kategori intermitten. Nilai MAE untuk metode *Random Forest* adalah 13.66 unit sedangkan untuk metode *Gradient Boosting* 17.26 unit, dan peningkatan akurasi adalah 20.9%. Sama seperti Beef Slice, nilai MAPE untuk Sei Domba (17.12%) sama persis dengan RMSE (17.12) hal ini terjadi karena alasan yang sama dengan yang terjadi pada Beef Slice.



Gambar 7. Hasil peramalan Sei Domba

Produk dengan volume rendah seperti Sei Domba ini memiliki kesalahan dalam angka absolut memang kecil (tidak terlalu berdampak finansial). Tetapi kesalahan dalam persentase tetap besar (kurang dapat diandalkan untuk planning). Meskipun begitu, *Random Forest* tetap pilihan terbaik karena konsisten memberikan hasil lebih akurat dibanding *Gradient Boosting*.

3.3 Feature Importance

Feature importance menunjukkan fitur-fitur atau faktor-faktor mana yang paling berpengaruh terhadap akurasi prediksi permintaan. Dengan kata lain, dari semua informasi yang digunakan untuk meramalkan, informasi mana yang paling penting.

3.3.1 Feature Importance untuk Pemintaan Stabil

Berdasarkan pada Tabel 6 dapat dilihat lima *feature importance* teratas untuk masing-masing produk dan masing-masing metode. Pada metode *Random Forest* memprediksi penjualan Sei Ayam, terdapat satu fitur yang paling dominan, yaitu permintaan 3 bulan yang lalu (*lag_3*), yang berkontribusi sebesar 22.1% terhadap akurasi prediksi. Hal ini menyatakan bahwa dari semua informasi yang digunakan model, permintaan yang terjadi 3 bulan sebelumnya adalah informasi paling penting karena industri kuliner di Indonesia bekerja dalam siklus 3 bulan (kuartal). Jika penjualan Desember Sei Ayam 680 unit, maka Maret tahun depan akan sangat mirip. Pelanggan memiliki pola pemesanan yang regular, dan momentum yang terjadi satu kuartal memiliki kecenderungan untuk bertahan ke kuartal berikutnya. Artinya, setiap 3 bulan, tim perlu melakukan *review* dan *planning*. Jangan hanya menggunakan data bulan lalu untuk merencanakan bulan depan melainkan menggunakan data 3 bulan lalu sebagai acuan utama.

Fitur kedua yang penting adalah permintaan 6 bulan yang lalu (*lag_6*), dengan kontribusi 17.4%. Hal ini memberikan referensi yang lebih jauh ke belakang, seperti membandingkan normal atau tidak normal bulan sekarang dibanding setengah tahun lalu. Permintaan 6 bulan lalu berfungsi sebagai *baseline* atau nilai pembanding yang lebih stabil dibanding hanya melihat bulan sebelumnya saja. Fitur ketiga adalah rata-rata permintaan 6 bulan terakhir (*rolling_mean_6*), yang berkontribusi 14.2%. Hal ini berbeda dari *lag_6* karena bukan hanya melihat satu bulan yang spesifik, melainkan rata-rata 6 bulan. Seperti perbandingan jika ingin mengetahui suatu permintaan dikatakan normal untuk sebuah produk, tidak hanya melihat pada permintaan satu bulan saja karena bisa kebetulan tinggi atau rendah, akan tetapi dapat dilihat juga pada rata-rata beberapa bulan untuk mendapat gambaran yang lebih informatif. Sehingga rata-rata 6 bulan untuk produk ini adalah angka normal yang paling *reliable*.

Tabel 6. *Feature Importance* Sei Ayam dan Sei Sapi

Sei Ayam				Sei Sapi			
<i>Random Forest</i>		<i>Gradient Boosting</i>		<i>Random Forest</i>		<i>Gradient Boosting</i>	
<i>Feature</i>	<i>Importance</i>	<i>Feature</i>	<i>Importance</i>	<i>Feature</i>	<i>Importance</i>	<i>Feature</i>	<i>Importance</i>
<i>lag_3</i>	22,1%	<i>lag_3</i>	26,8%	<i>lag_3</i>	20,8%	<i>lag_3</i>	25,4%
<i>lag_6</i>	17,4%	<i>lag_6</i>	21,3%	<i>lag_6</i>	16,9%	<i>lag_6</i>	20,1%
<i>rolling_mean_6</i>	14,2%	<i>trend</i>	17,2%	<i>trend</i>	13,5%	<i>trend</i>	16,8%
<i>trend</i>	12,1%	<i>lag_1</i>	13,4%	<i>rolling_mean_6</i>	12,7%	<i>lag_1</i>	13,2%
<i>lag_1</i>	10,3%	<i>rolling_mean_6</i>	11,1%	<i>lag_1</i>	11,2%	<i>rolling_mean_6</i>	10,7%
<i>rolling_mean_3</i>	9,8%	<i>lag_2</i>	5,6%	<i>rolling_mean_3</i>	9,1%	<i>lag_2</i>	7,2%
<i>lag_2</i>	7,2%	<i>rolling_mean_3</i>	3,1%	<i>lag_2</i>	8,4%	<i>rolling_mean_3</i>	4,4%
<i>month_sin</i>	6,9%	<i>month_sin</i>	1,5%	<i>month_sin</i>	7,4%	<i>month_sin</i>	2,2%

Fitur keempat adalah tren, dengan kontribusi sebesar 12.1%. Tren menunjukkan apakah permintaan naik, tetap, atau turun dalam jangka waktu yang panjang. Produk Sei Ayam, memiliki tren pertumbuhan kecil, akan tetapi penjualan perlahan-lahan meningkat dari waktu ke waktu. Model harus mengetahui informasi ini, sehingga produk tidak terus diprediksi dengan angka yang sama, karena faktanya permintaan sedang berkembang. Fitur-fitur selanjutnya seperti permintaan bulan lalu (*lag_1*), rata-rata 3 bulan (*rolling_mean_3*), dan lainnya memiliki kontribusi yang lebih kecil (kurang dari 10%), dengan kata lain fitur lainnya kurang berkontribusi jika dibanding keempat fitur utama di atas.

Feature importance untuk Sei Sapi sangat mirip dengan Sei Ayam. *Lag_3* tetap paling dominan dengan kontribusi sebesar 20.8% lebih rendah jika dibandingkan dengan Sei Ayam sebesar 22.1%. *Lag_6* masih penting dengan kontribusi sebesar 16.9%, dan *rolling_mean_6* tetap kontributor utama dengan 12.7%. Pola ini hampir identik mengindikasikan bahwa kedua produk benar-benar memiliki karakteristik demand yang serupa. Namun terdapat satu perbedaan, yaitu trend untuk Sei Sapi adalah 13.5%, sedikit lebih tinggi dari Sei Ayam yaitu sebesar 12.1%, dan trend-nya saling berlawanan antara Sei Ayam dan Sei Sapi. Hal ini menunjukkan bahwa Sei Sapi adalah produk yang permintaannya sedang menurun perlahan-lahan atau tidak berkembang seperti Sei Ayam.

3.3.2 Feature Importance untuk Permintaan Sangat Fluktuatif

Berdasarkan pada Tabel 7 dapat dilihat *feature importance* untuk masing-masing produk dan masing-masing metode. Baked Grill Chicken adalah produk yang sangat sulit diprediksi karena memiliki permintaan yang tidak mengikuti pola, melainkan akibat karena produk terjual ketika *event-event* tertentu seperti: *catering* untuk acara pernikahan atau tiba-tiba produk viral di *social media*. Bukti bahwa Baked Grill Chicken ini sulit diprediksi dapat terlihat dari hasil *feature importance* tidak terdapat fitur yang dominan, hampir semua fitur terdapat pada range 10-20%. *Error* prediksi sebesar 1,170 unit pada mean sebesar 1,070 unit ini bukan hanya angka statistic, artinya hasil peramalan sebesar 1.000 unit dan realitasnya hanya 100 unit makanya *waste* sebesar 90%, sehingga dilakukan peramalan saja tidak cukup untuk menangani *inventory* Baked Grill Chicken.

Sambal Bawang adalah produk yang memiliki permintaan sangat fluktuatif hanya saja terstruktur yang artinya permintaan naik turun hanya saja fluktuasi-nya memiliki pola, berbeda dengan Baked Grill Chicken yang murni sangat berfluktuatif. *Gradient Boosting* lebih akurat dari *Random Forest* untuk Sambal Bawang karena *Gradient Boosting* lebih menitik-beratkan pada permintaan bulan lalu (*lag_3*) yaitu sebesar 24.7% sebagai signal terpenting, hal ini menunjukkan bahwa untuk produk volatile, momentum recent sangat penting dan harus direspon cepat dengan monitoring secara perminggu bukan perbulan, sedangkan *Random Forest* lebih berhati-hati dengan *lag_3* (16.4%) dan lebih mempertimbangkan volatilitas magnitude dilihat pada nilai *rolling_std_6* yaitu sebesar 12.1%.

Tabel 7. *Feature Importance* Baked Grill Chicken dan Sambal Bawang

Baked Grill Chicken				Sambal Bawang			
<i>Random Forest</i>		<i>Gradient Boosting</i>		<i>Random Forest</i>		<i>Gradient Boosting</i>	
<i>Feature</i>	<i>Importance</i>	<i>Feature</i>	<i>Importance</i>	<i>Feature</i>	<i>Importance</i>	<i>Feature</i>	<i>Importance</i>
trend	17,3%	lag_3	22,1%	lag_3	16,4%	lag_3	24,7%
lag_3	15,8%	trend	18,6%	trend	15,2%	trend	19,3%
rolling_std_6	12,4%	lag_6	16,3%	lag_6	13,8%	lag_6	17,2%
lag_6	11,9%	lag_1	14,2%	rolling_std_6	12,1%	lag_1	14,1%
rolling_mean_6	10,2%	lag_1	11,4%	rolling_mean_6	11,3%	rolling_mean_6	10,8%
lag_1	9,7%	rolling_std_6	9,1%	lag_1	10,6%	rolling_std_6	6,4%
rolling_mean_3	8,8%	rolling_mean_3	5,3%	rolling_mean_3	9,8%	rolling_mean_3	4,2%
month_sin	7,9%	month_sin	3,0%	month_sin	8,3%	month_sin	3,3%

3.3.3 Feature Importance untuk Permintaan Intermittent

Berdasarkan Tabel 8 dapat dilihat lima *feature importance* yang paling berkontribusi untuk masing-masing produk dengan masing-masing metode. Pada produk Sei Domba terdapat *twist* pada lag_6 sebesar 20,3% lebih penting daripada lag_3 yaitu sebesar 11,7%. Ini berlawanan dengan produk stabil dimana lag_3 selalu dominan. Hal ini terjadi karena produk dengan penjualan *intermittent*, data bulan lalu bisa *misleading* karena bulan lalu mungkin tidak terdapat permintaan. Jika model terlalu fokus pada lag_1, maka akan diprediksi 0 terus-menerus, padahal pada realisasinya tidak selalu begitu. Oleh karena itu, model perlu melihat lebih jauh ke belakang yaitu ke lag_6 untuk menemukan *true baseline demand* yang sebenarnya. *Rolling mean_6* (rata-rata 6 bulan) menjadi sangat penting dengan kontribusi sebesar 16,4%. Ini adalah angka paling reliable karena fluktuasi random dan zero-demand periods ter-average out selama 6 bulan, sehingga muncul angka permintaan normal yang sebenarnya untuk produk ini.

Pattern untuk Beef Slice menyerupai *pattern* Sei Domba, yaitu lag_6 yang berkontribusi sebesar 19,2% lebih penting daripada lag_3 yang berkontribusi sebesar 12,9%. Sama halnya dengan Sei Domba untuk produk dengan permintaan *intermittent*, perlu melihat lebih jauh ke belakang. *Rolling mean_6* sebesar 15,8% juga penting sebagai *baseline estimator*. Namun, terdapat perbedaan antara Beef Slice trend yang sebesar 13,7%, berkontribusi lebih rendah daripada Sei Domba yaitu sebesar 14,1%. Hal ini menunjukkan bahwa Beef Slice memungkinkan sedang dalam fase bertumbuh atau fase *decline*. Selain itu, volatilitas 6 bulan (*rolling_std_6*) berkontribusi sebesar 8,7% yang mengindikasikan bahwa besaran fluktuasi juga memberikan informasi yang penting.

Tabel 8. *Feature importance* Sei Domba dan Beef Slice

Sei Domba				Beef Slice			
<i>Random Forest</i>		<i>Gradient Boosting</i>		<i>Random Forest</i>		<i>Gradient Boosting</i>	
<i>Feature</i>	<i>Importance</i>	<i>Feature</i>	<i>Importance</i>	<i>Feature</i>	<i>Importance</i>	<i>Feature</i>	<i>Importance</i>
lag_6	20,3%	lag_6	25,1%	lag_6	19,2%	lag_6	23,4%
rolling_mean_6	16,4%	trend	20,4%	rolling_mean_6	15,8%	trend	18,9%
trend	14,1%	rolling_mean_6	15,3%	trend	13,7%	rolling_mean_6	14,2%
lag_3	11,7%	lag_3	13,2%	lag_3	12,9%	lag_3	13,1%
lag_1	10,2%	lag_1	12,7%	lag_1	10,4%	lag_1	11,6%
rolling_mean_3	9,8%	rolling_mean_3	6,8%	rolling_mean_3	9,3%	rolling_mean_3	7,4%
rolling_std_6	8,9%	rolling_std_6	4,2%	rolling_std_6	8,7%	rolling_std_6	4,8%
month_sin	5,6%	month_sin	2,3%	month_sin	6,0%	month_sin	2,6%

4. Simpulan

Penelitian ini bertujuan untuk membandingkan performa *Random Forest* dan *Gradient Boosting* dalam meramalkan permintaan produk kuliner dengan karakteristik yang beragam, serta mengembangkan panduan praktis untuk memilih metode *forecasting* yang tepat. Berdasarkan analisis terhadap enam produk kuliner selama 36 bulan (Januari 2022 - Desember 2024), penelitian ini dapat menyimpulkan bahwa *Random Forest* lebih unggul dari metode *Gradient Boosting* pada empat produk yaitu Sei Ayam, Sei Sapi, Sei Domba, dan Beef Slice, sementara *Gradient Boosting* hanya unggul pada satu produk yaitu Sambal Bawang. Secara rata-rata, *Random Forest* menghasilkan Mean Absolute Percentage Error (MAPE) yang lebih rendah dan menunjukkan konsistensi performa yang lebih baik. Untuk produk dengan permintaan stabil seperti Sei Ayam dan Sei Sapi, *Random Forest* mencapai MAPE sekitar 19-21%. Keunggulan *Random Forest* terletak pada mekanisme ensemble *averaging* yang menggabungkan prediksi dari banyak *decision trees* yang independent, sehingga lebih tahan terhadap *noise* dan *outliers* dalam data. Berbeda dengan *Gradient Boosting* yang bekerja secara *sequential* dan cenderung terlalu agresif dalam mengejar pola detail yang terkadang hanya merupakan fluktuasi acak, *Random Forest* memberikan prediksi yang lebih smooth dan stabil. Keunggulan pada *Random Forest* untuk penelitian ini memberikan hasil yang sebaliknya jika dengan dibandingkan dengan penelitian yang dilakukan

sebelumnya. Pradiptyo *et al.* (2024) menggunakan Rossmann dengan ribuan *outlet* dan histori panjang, menyatakan bahwa metode *Gradient Boosting* umumnya menunjukkan keunggulan karena memiliki data yang cukup untuk pembelajaran sekuensial yang mendalam, sebaliknya dengan penelitian ini membuktikan bahwa pada dataset 36 observasi (skenario UMKM) keunggulan *Gradient Boosting* tidak terbukti.

Baked Grill Chicken, untuk produk yang permintaannya sangat berfluktuatif, menunjukkan bahwa *Random Forest* maupun *Gradient Boosting* mengalami kesulitan signifikan dalam menghasilkan prediksi yang akurat. *Error forecasting* untuk produk ini sangat tinggi, bahkan metode terbaik seperti *Random Forest* menghasilkan *Mean Absolute Error* sebesar 1,170 unit pada *mean demand* 1,070 unit, yang berarti rata-rata kesalahan prediksi hampir setara dengan nilai permintaan itu sendiri. MAPE untuk kategori produk volatile umumnya berada di kisaran 32-40%, yang mengindikasikan bahwa masih terdapat ruang *improvement* yang sangat signifikan. Volatilitas ekstrem ini kemungkinan besar disebabkan oleh faktor-faktor external yang tidak tertangkap dalam *pure time series features* yang digunakan dalam penelitian ini, seperti promosi, *special events*, *viral effects* di *social media*, atau perubahan musiman yang tidak regular. Untuk produk-produk seperti ini, penelitian lanjutan perlu mengeksplorasi pendekatan hybrid yang menggabungkan *machine learning* dengan *business rules*, atau penggunaan metode *deep learning* seperti Long Short-Term Memory (LSTM) atau Gated Recurrent Units (GRU) yang memiliki kemampuan lebih baik dalam menangkap *complex temporal patterns*. Untuk produk dengan permintaan *intermittent* seperti Beef Slice dan Sei Domba memerlukan treatment khusus. Penelitian menunjukkan bahwa untuk produk seperti Beef Slice yang memiliki banyak periode *zero-demand*, sebaiknya menggunakan metode khusus yang *specifically designed* untuk *intermittent demand*, seperti Croston's method atau Syntetos-Boylan Approximation (SBA), atau bahkan zero-inflated models.

Penelitian memiliki beberapa keterbatasan yang perlu diperhatikan dalam menginterpretasikan hasilnya. Pertama, penelitian ini menggunakan data penjualan bulanan dari satu lokasi restoran di Indonesia periode Januari 2022 - Desember 2024 (36 observasi), sehingga hasilnya belum tentu dapat mewakili karakteristik UMKM yang lainnya. Kedua, *feature engineering* dibatasi pada *lag features*, *rolling statistics*, *time-based features*, dan *trend*. Faktor eksternal seperti promosi, hari libur, cuaca, dan persaingan harga tidak dimasukkan dalam model, sehingga kekurangan ini dapat digunakan untuk pengisian kekosongan pada penelitian selanjutnya. Ketiga, studi kasus terbatas pada 6 produk dengan karakteristik permintaan berbeda sehingga generalisasi hasil perlu mempertimbangkan konteks industri dan karakteristik produk yang serupa. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas cakupan responden, dengan melibatkan objek penelitian yang lebih banyak dari sebelumnya, serta mampu menambahkan faktor-faktor eksternal sebagai perhitungan *feature importance* selanjutnya.

Ucapan Terima Kasih

Puji syukur para penulis menyampaikan rasa terimakasih kepada CV Healfit Pangan Sehat (DietGo Kitchen) atas kerja sama dan dukungannya selama proses penelitian berlangsung. Kami menyampaikan apresiasi yang mendalam atas kesediaan perusahaan dalam memberikan akses, data, serta wawasan teknis yang telah sangat berkontribusi terhadap kedalaman dan kualitas penelitian ini. Ucapan terima kasih khusus kami sampaikan kepada jajaran manajemen dan staf atas kemudahan yang diberikan selama proses observasi lapangan dilakukan atas kesediaan mereka dalam berbagi ilmu dan pengalaman terkait proses peramalan produksi.

Daftar Pustaka

Amalia, R., Siregar, M.N. and Nasution, A.A. (2024) 'Comparative forecasting of Indonesian stock prices using ARIMA and SVR: a statistical learning approach', *Millennial: Journal of Management, Economics, Entrepreneurship, and Policy (MMEP)*, 4(7), pp.1-12. Available at: <https://doi.org/10.18280/mmep.120711>.

- Bappenas (2021) *Study report: Food loss and waste in Indonesia. Supporting the implementation of circular economy and low carbon development*. Available at: <https://lcdi-indonesia.id/wp-content/uploads/2021/07/Report-Kajian-FLW-ENG.pdf> (Accessed: 8 July 2010).
- Breiman, L. (2001) 'Random Forests', *Machine Learning*, 45(1), pp.5–32.
- Breiman, L. and Cutler, A. (2003) *Manual on setting up, using, and understanding random forest V4.0*. Available at: http://oz.berkeley.edu/users/breiman/Using_random_forests_v4.0.pdf (Accessed: 8 July 2010).
- Creswell, J.W. and Creswell, J.D. (2018) *Qualitative, quantitative, and mixed methods approaches*. Los Angeles: Sage.
- Dora, M., Biswas, S., Choudhary, S., Nayak, R. and Irani, Z. (2021) 'A system-wide interdisciplinary conceptual framework for food loss and waste mitigation strategies in the supply chain', *Industrial Marketing Management*, 93, pp.492–508. Available at: <https://doi.org/10.1016/j.indmarman.2020.10.013>.
- FAO (2011) *Global food losses and food waste: extent, causes and prevention*. Rome: Food and Agriculture Organization of the United Nations.
- Fernández-Delgado, M. *et al.* (2014) 'Do we need hundreds of classifiers to solve real world classification problems?', *Journal of Machine Learning Research*, 15(1), pp.3133–3181.
- Friedman, J.H. (2001) 'Greedy function approximation: a Gradient Boosting machine', *The Annals of Statistics*, 29(5), pp.1189–1232.
- Hermawan, A. and Kusuma, P.D. (2023) 'Perbandingan Gradient Boosting dan Random Forest untuk demand forecasting retail', *Jurnal Teknik Industri Indonesia*, 9(2), pp.145–156.
- Hutasuhut, A.H., Anggraeni, W. and Tyasnurita, R. (2014) 'Pembuatan aplikasi pendukung keputusan untuk peramalan persediaan bahan baku produksi plastik blowing dan inject menggunakan metode ARIMA (Autoregressive Integrated Moving Average) di CV Asia', *Jurnal Teknik ITS*, 3(2), pp.A169–A174.
- Kementerian Pariwisata dan Ekonomi Kreatif Republik Indonesia (2023) *Statistik ekonomi kreatif Indonesia 2023*. Jakarta: Kemenparekraf RI.
- Kristanti, F.T., Febrianta, M.Y. and Salim, D.F. (2024) 'Predicting financial distress in Indonesian companies using machine learning', *Engineering, Technology & Applied Science Research*, 14(4), pp.15418–15423. Available at: <https://doi.org/10.48084/etasr.8520>.
- Makridakis, S., Spiliotis, E. and Assimakopoulos, V. (2022) 'M5 accuracy competition: results, findings, and conclusions', *International Journal of Forecasting*. Available at: <https://doi.org/10.1016/j.ijforecast.2021.11.013>.
- Maricar, M.A. (2019) 'Analisa perbandingan nilai akurasi moving average dan exponential smoothing untuk sistem peramalan pendapatan pada perusahaan XYZ', *Jurnal Sistem dan Informatika (JSI)*, 13(2), pp.36–45.
- Møller Christensen, F.M. *et al.* (2021) 'Developing new forecasting accuracy measure considering Product's shelf life: effect on availability and waste', *Journal of Cleaner Production*, 288, p. 125594. Available at: <https://doi.org/https://doi.org/10.1016/j.jclepro.2020.125594>.
- Poore, J. and Nemecek, T. (2018) 'Reducing food's environmental impacts through producers and consumers', *Science*, 360(6392), pp.987–992.
- Pradipto, D.R. *et al.* (2024) 'Incorporating stock prices and social media sentiment for stock market prediction: a case of Indonesian banking company', *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 13(1), pp.156–165. Available at: <https://doi.org/10.23887/janapati.v13i1.74486>.
- Smyl, S. (2020) 'A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting', *International Journal of Forecasting*, 36(1), pp.75–85. Available at: <https://doi.org/10.1016/j.ijforecast.2019.03.017>.
- Sudarman, Noviani and Nisa (2024) 'Analisis perbandingan metode forecasting demand untuk optimasi persediaan bahan baku di DietGo Kitchen', *Jurnal Industrial Galuh*, 7(2), pp.92–99.
- Subagyo, P. (1986) *Forecasting: Konsep dan aplikasi*. Yogyakarta: BPPE UGM.
- Syntetos, A.A. and Boylan, J.E. (2005) 'The accuracy of intermittent demand estimates', *International Journal of Forecasting*, 21(2), pp.303–314. Available at: <https://doi.org/10.1016/j.ijforecast.2004.10.001>.

Zulfia, A., Wibisono, M.A. and Setiawan, B. (2025) 'AI decision support system for demand forecasting and retail stock management using *Random Forest* algorithm', *Brilliance: Research of Artificial Intelligence*, 5(1), pp.45–58. Available at: <https://doi.org/10.47709/brilliance.v5i1.3456>.