

Pengembangan Model Prediksi Penjualan dan Persediaan dengan Klasifikasi Produk untuk Efisiensi Manajemen Stok Toko Berkat Plastik

Evelyn Agustin*, M. Ferdy Setiawan, Andri Wijaya

Univesitas Katolik Musi Charitas

Abstrak: Penelitian ini bertujuan untuk mengembangkan model prediksi penjualan dan persediaan pada Toko Berkat Plastik guna meningkatkan efisiensi manajemen stok dan mengurangi risiko *overstock* maupun *stockout*. Metode yang digunakan adalah analisis berbasis *data mining* dengan pendekatan *Knowledge Discovery in Database (KDD)*, meliputi tahap seleksi data, *pre-processing*, transformasi, pemodelan, dan evaluasi. Algoritma *Naïve Bayes* digunakan untuk mengklasifikasikan tingkat penjualan dan kondisi stok ke dalam kategori Rendah, Sedang, Tinggi serta Aman, Menipis, dan Kritis. Hasil penelitian menunjukkan bahwa model prediksi stok mencapai akurasi 75%, sementara model penjualan memperoleh akurasi 68,42%. Model menunjukkan performa terbaik pada kategori stok Aman dan penjualan Tinggi, sedangkan kategori lain memiliki akurasi lebih rendah akibat karakteristik data yang fluktuatif. Kesimpulan penelitian ini menyatakan bahwa model *Naïve Bayes* efektif digunakan dalam memprediksi permintaan dan kondisi persediaan, serta dapat dimanfaatkan sebagai alat pendukung keputusan untuk mengoptimalkan perencanaan pembelian dan pengendalian inventori pada usaha retail skala menengah.

Kata kunci: *Data Mining, Naïve Bayes, Prediksi Penjualan, Prediksi Persediaan, Klasifikasi.*

DOI:

<https://doi.org/10.47134/jtsi.v3i1.5191>

*Correspondence: Evelyn Agustin

Email: evelynputri87@gmail.com

Received: 22-11-2025

Accepted: 22-12-2025

Published: 22-01-2026



Copyright: © 2026 by the authors. Submitted for open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license

(<http://creativecommons.org/licenses/by/4.0/>).

Abstract: *This study aims to develop a predictive model for sales and inventory levels at Toko Berkat Plastik in order to improve stock management efficiency and reduce the risk of overstock and stockout. The research employs a data mining approach using the Knowledge Discovery in Database (KDD) framework, consisting of data selection, pre-processing, transformation, modeling, and evaluation. The Naïve Bayes algorithm is applied to classify sales levels and inventory conditions into Low, Medium, High as well as Safe, Depleting, and Critical categories. The results indicate that the inventory prediction model achieved 75% accuracy, while the sales prediction model reached 68.42% accuracy. The model performed best in identifying Safe inventory and High sales categories, whereas other categories showed lower performance due to data variability and overlapping patterns. The study concludes that the Naïve Bayes algorithm is effective for predicting sales demand and inventory status and can serve as a reliable decision-support tool to optimize purchasing planning and inventory control in medium-scale retail businesses.*

Keywords: *Data Mining, Naïve Bayes, Sales Prediction, Inventory Prediction, Classification.*

Pendahuluan

Pertumbuhan sektor ritel berbasis kebutuhan rumah tangga, termasuk penjualan produk plastik seperti wadah, kemasan, dan perlengkapan rumah tangga, mengalami peningkatan signifikan dalam beberapa tahun terakhir. Berdasarkan laporan Badan Pusat Statistik (BPS) tahun 2024, konsumsi rumah tangga untuk kategori produk plastik meningkat sebesar 21,7% dibandingkan tahun 2022, yang menunjukkan peningkatan

preferensi terhadap produk bernilai guna tinggi dan kemasan multi-fungsi di pasar domestik. Kondisi ini berdampak pada meningkatnya kebutuhan pengelolaan inventori dan penyediaan stok yang lebih terkendali untuk memenuhi permintaan pasar. Menurut (Ayuningtyas et al, 2022), ketidaktepatan perencanaan stok dapat menyebabkan kerugian hingga 28–35% akibat kelebihan persediaan dan biaya penyimpanan. Sementara itu, penelitian (Hartawan, 2024) menunjukkan bahwa penerapan model prediksi dapat meningkatkan akurasi pengelolaan persediaan hingga mencapai 82,9%, dan (Sabilla et al., 2025) menegaskan bahwa penggunaan pendekatan berbasis data dapat membantu UMKM mengurangi risiko kekurangan stok (*stockout*) hingga 40% dalam periode operasional tahunan.

Di Indonesia, sebagian besar pelaku UMKM masih mengelola data penjualan secara manual, menggunakan pembukuan konvensional atau spreadsheet tanpa analisis lanjutan sehingga sulit dalam mengidentifikasi pola permintaan pelanggan dari waktu ke waktu. Menurut survei Kementerian Koperasi dan UMKM tahun 2023, sebanyak 67% UMKM belum menerapkan sistem prediksi penjualan berbasis data, sehingga keputusan pengadaan barang masih mengandalkan asumsi dan pengalaman subjektif. Penelitian oleh (Pradhana et al, 2025) menunjukkan bahwa pengolahan data menggunakan metode machine learning seperti *Naïve Bayes* mampu meningkatkan keandalan prediksi penjualan dan persediaan pada data penjualan dengan klasifikasi kategori produk. Temuan tersebut diperkuat oleh (Hidayat et al, 2023) yang menyatakan bahwa metode klasifikasi dapat memetakan produk berdasarkan tingkat penjualan sehingga mempermudah pengambilan keputusan pengadaan stok. Selain itu, (Liu et al, 2025) menjelaskan bahwa penggunaan model prediksi berbasis klasifikasi dapat menurunkan biaya pengelolaan inventori antara 18–26%, terutama pada ritel dengan variasi produk besar seperti toko plastik.

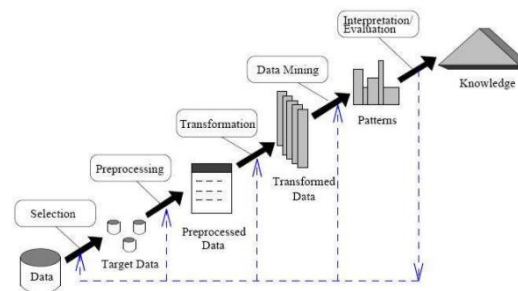
Strategi pengelolaan stok yang mengintegrasikan prediksi penjualan dan klasifikasi produk menjadi sangat relevan karena dapat membantu menetapkan prioritas inventori berdasarkan tingkat permintaan dan rotasi barang. Sistem klasifikasi seperti kategori rendah, sedang, dan tinggi memungkinkan pelaku usaha mengalokasikan anggaran pembelian secara proporsional. Menurut (Munoz, 2024), segmentasi inventori mampu meningkatkan akurasi pengendalian stok hingga 89% pada usaha dengan pola penjualan musiman. Selain itu, (Aldahmani et al, 2024) menemukan bahwa penggunaan pembelajaran mesin berbasis regresi prediktif meningkatkan ketepatan permintaan jangka pendek hingga 94%, terutama untuk produk dengan pola pembelian fluktuatif. Hal ini diperkuat oleh (Sabilla et al, 2025) yang menekankan bahwa pengendalian inventori berbasis klasifikasi memungkinkan UMKM melakukan optimasi proses pembelian, penyimpanan, dan rotasi stok secara lebih efisien.

Berdasarkan uraian tersebut, penelitian ini dikembangkan sebagai upaya mengoptimalkan manajemen stok pada Toko Berkat Plastik melalui pengembangan model prediksi penjualan dan persediaan yang dilengkapi klasifikasi produk. Diharapkan model ini dapat menjadi solusi dalam meningkatkan efisiensi, mengurangi biaya penyimpanan, serta memastikan stok tersedia sesuai kebutuhan konsumen. Dengan penerapan pendekatan berbasis data, UMKM dapat bertransformasi dari pengelolaan operasional

tradisional menuju sistem manajemen inventori yang adaptif, sistematis, dan terukur dalam menghadapi dinamika permintaan pasar ritel modern (Munoz, 2024; Pradhana et al., 2025; Ayuningtyas et al, 2022).

Metodologi

Penelitian ini menggunakan pendekatan kuantitatif dengan metode prediktif berbasis machine learning untuk menganalisis pola penjualan dan persediaan produk pada Toko Berkat Plastik. Pendekatan kuantitatif dipilih karena mampu memberikan hasil berbasis angka yang objektif serta dapat diolah menggunakan model statistik dan kecerdasan buatan untuk menghasilkan prediksi yang terukur (Putra & Hidayat, 2022). Tahapan penelitian disusun berdasarkan model Knowledge Discovery in Database (KDD) yang terdiri dari proses seleksi data, pembersihan data, transformasi data, pemodelan, evaluasi, dan interpretasi hasil. Model KDD dipilih karena telah banyak digunakan dalam penelitian prediksi penjualan dan terbukti mampu meningkatkan akurasi model melalui proses sistematis pengolahan dataset (Mulyani et al., 2023). Selain itu, (Widiyanto & Firdaus, 2024) menyatakan bahwa KDD memberikan struktur tahapan analitis yang stabil untuk penelitian berbasis dataset retail dengan variabel kategori.



Gambar 1. Konsep Data Mining (KDD)

Data yang digunakan dalam penelitian ini merupakan data historis penjualan bulanan selama 12 bulan yang berisi informasi jumlah penjualan, jumlah stok, kategori produk, dan waktu transaksi. Data historis diperlukan karena prediksi penjualan hanya dapat dilakukan melalui pola permintaan masa lalu yang kemudian dibandingkan dengan tren konsumsi pelanggan (Rahmawati & Samudra, 2023). Pada tahap awal, dilakukan proses data preprocessing yang meliputi penghapusan duplikasi data, normalisasi nilai, dan penanganan data kosong untuk memastikan kualitas dataset berada pada kondisi optimal. Proses normalisasi data dilakukan menggunakan metode skala min-max agar distribusi nilai berada pada rentang yang seragam sehingga algoritma dapat membaca pola dengan lebih baik (Firmansyah & Hanifa, 2024). Selanjutnya, atribut numerik diklasifikasikan menjadi kategori *rendah*, *sedang*, dan *tinggi* menggunakan metode *equal-width discretization* sesuai rekomendasi penelitian (Khairunnisa & Yusuf, 2022) yang menyebutkan bahwa klasifikasi tingkat persediaan membantu meningkatkan stabilitas prediksi.

Tahap pemodelan menggunakan perangkat lunak *RapidMiner Studio* karena aplikasi ini mendukung integrasi algoritma klasifikasi, *forecasting*, dan evaluasi model dalam satu *workflow* tanpa memerlukan coding kompleks (Zulfiqar & Rahmat, 2024). Model yang digunakan dalam penelitian ini adalah algoritma *Naïve Bayes*, yang dipilih karena sederhana, tidak membutuhkan dataset besar, serta memiliki performa unggul pada data kategorikal (Wijaya et al., 2021). Dataset dibagi menjadi 80% data pelatihan dan 20% data pengujian menggunakan teknik *holdout validation*, agar model dapat diuji secara objektif pada data yang belum pernah dipelajari sebelumnya (Safitri & Kurniawan, 2025). Selanjutnya dilakukan evaluasi model menggunakan metrik akurasi, presisi, recall, serta confusion matrix untuk menilai performa prediksi berdasarkan kategori produk.

Tahap terakhir adalah interpretasi hasil model untuk menentukan akurasi prediksi penjualan dan persediaan serta kesesuaian klasifikasi kategori produk. Hasil interpretasi digunakan untuk menghasilkan rekomendasi strategi pengelolaan inventori seperti estimasi reorder point, prioritas pembelian barang, dan pengaturan rotasi stok berdasarkan kategori *fast-moving*, *medium-moving*, maupun *slow-moving*. Menurut (Aulia & Fathurrahman, 2024), model prediksi berbasis klasifikasi mampu meningkatkan efisiensi operasional gudang dan mengurangi pemborosan inventori. Dengan demikian, metodologi ini tidak hanya membangun model prediksi, tetapi juga memberikan kerangka implementasi nyata pada operasional manajemen stok toko retail.

Pengumpulan dan Pengolahan Data

Data penelitian ini diperoleh melalui metode dokumentasi dari catatan transaksi penjualan dan persediaan Toko Berkat Plastik selama 2 tahun dengan jumlah data sebanyak 96 minggu. Data yang dikumpulkan mencakup jumlah penjualan per kategori produk, stok akhir per bulan, serta waktu transaksi. Penggunaan data transaksi riil dipilih karena lebih akurat dalam menggambarkan pola permintaan pelanggan dibandingkan data estimasi (Rahmawati & Idris, 2022). Selain itu, data historis umum digunakan dalam penelitian prediksi permintaan karena mampu mencerminkan tren konsumsi aktual pelanggan (Anggraini & Kurniawan, 2024).

Dataset yang diperoleh tidak mengandung data duplikat maupun nilai kosong sehingga dapat langsung digunakan untuk proses pemodelan. Data hanya melalui tahap penyesuaian format, seperti penyesuaian format angka dan penamaan kategori agar sesuai dengan kebutuhan pemodelan. Selanjutnya, dilakukan pembagian dataset menggunakan metode holdout 80:20, yaitu 80% data digunakan sebagai data pelatihan dan 20% sebagai data pengujian, sesuai standar validasi model prediksi (Salsabila & Nurdiansyah, 2024).

Dataset akhir kemudian digunakan langsung pada proses pemodelan machine learning di *RapidMiner* dan diringkas dalam tabel berikut.

Tabel 1. Dataset Penjualan dan Persediaan

Minggu Ke	Tople s	Ember	Kantong Plastik	Botol Minum	Total Penjualan	Stok Akhir	Kategori Penjualan	Kategori Stok
Minggu 1	145	213	784	333	662	939	Sedang	Aman
Minggu 2	761	583	131	521	319	693	Sedang	Aman
Minggu 3	884	614	235	451	931	764	Sedang	Aman
Minggu 4	674	497	379	629	655	486	Sedang	Aman
Minggu 5	454	641	529	853	537	479	Sedang	Aman
Minggu 6	694	834	423	725	679	222	Sedang	Aman
Minggu 7	135	881	423	257	516	864	Sedang	Aman
Minggu 8	892	175	938	396	674	448	Sedang	Aman
Minggu 9	626	899	394	128	529	211	Sedang	Aman
Minggu 10	363	276	432	213	531	349	Sedang	Aman
Minggu 11	376	162	767	295	985	466	Sedang	Aman
Minggu 12	348	378	314	214	737	461	Sedang	Aman
Minggu 13	529	439	129	628	692	999	Sedang	Aman
Minggu 14	381	275	646	496	352	686	Sedang	Aman
Minggu 15	695	265	884	494	423	427	Sedang	Aman
Minggu 16	246	311	592	927	832	122	Sedang	Aman
Minggu 17	188	794	994	196	235	563	Tinggi	Aman
Minggu 18	451	423	345	433	944	646	Tinggi	Aman
Minggu 19	237	834	992	349	362	624	Tinggi	Aman
Minggu 20	284	519	251	728	571	224	Tinggi	Aman
Minggu 21	112	833	576	918	298	223	Tinggi	Aman
Minggu 22	681	457	638	255	641	683	Tinggi	Aman
Minggu 23	929	834	169	676	963	156	Tinggi	Aman
Minggu 24	876	115	314	356	456	625	Tinggi	Aman
Minggu 25	953	834	859	242	316	271	Sedang	Aman
Minggu 26	581	424	527	197	736	644	Sedang	Aman
Minggu 27	826	346	252	315	319	656	Sedang	Aman

Minggu Ke	Tops	Ember	Kantong Plastik	Botol Minum	Total Penjualan	Stok Akhir	Kategori Penjualan	Kategori Stok
Minggu 28	481	613	788	647	776	952	Sedang	Aman
Minggu 29	617	957	812	441	275	667	Sedang	Aman
Minggu 30	194	146	953	977	446	533	Sedang	Aman
Minggu 31	647	563	632	512	739	247	Sedang	Aman
Minggu 32	192	427	512	651	379	852	Sedang	Aman
Minggu 33	256	623	723	312	345	662	Rendah	Aman
Minggu 34	669	451	624	495	778	655	Rendah	Aman
Minggu 35	821	367	673	383	987	856	Rendah	Aman
Minggu 36	882	439	646	311	962	279	Rendah	Aman
Minggu 37	877	854	279	393	366	968	Rendah	Aman
Minggu 38	361	476	114	687	999	536	Rendah	Aman
Minggu 39	725	613	192	971	768	847	Rendah	Aman
Minggu 40	517	377	632	491	258	414	Rendah	Aman
Minggu 41	186	966	519	819	594	695	Sedang	Aman
Minggu 42	481	181	929	476	518	718	Sedang	Aman
Minggu 43	412	524	143	294	571	647	Sedang	Aman
Minggu 44	872	613	388	765	934	349	Sedang	Aman
Minggu 45	356	349	755	943	497	349	Sedang	Aman
Minggu 46	253	187	579	369	795	275	Sedang	Aman
Minggu 47	485	296	471	727	538	815	Sedang	Aman
Minggu 48	113	111	361	363	174	844	Sedang	Aman
Minggu 49	814	691	455	767	282	431	Tinggi	Menipis
Minggu 50	365	423	383	217	369	413	Tinggi	Menipis


Minggu Ke	Tople s	Ember	Kantong Plastik	Botol Minum	Total Penjualan	Stok Akhir	Kategori Penjualan	Kategori Stok
Minggu 51	241	284	768	866	319	879	Tinggi	Menipis
Minggu 52	427	547	782	295	271	155	Tinggi	Menipis
Minggu 53	389	117	784	779	211	645	Tinggi	Menipis
Minggu 54	117	395	221	288	616	348	Tinggi	Menipis
Minggu 55	515	111	216	814	555	895	Tinggi	Menipis
Minggu 56	198	887	214	913	274	646	Tinggi	Menipis
Minggu 57	165	938	396	447	697	222	Tinggi	Menipis
Minggu 58	527	283	471	922	255	964	Tinggi	Menipis
Minggu 59	144	348	518	617	111	631	Tinggi	Menipis
Minggu 60	296	826	584	418	854	777	Tinggi	Menipis
Minggu 61	364	773	463	571	852	612	Tinggi	Menipis
Minggu 62	195	139	223	271	459	414	Tinggi	Menipis
Minggu 63	767	888	687	497	225	341	Tinggi	Menipis
Minggu 64	557	441	989	763	939	414	Tinggi	Menipis
Minggu 65	526	576	241	565	438	826	Tinggi	Menipis
Minggu 66	545	235	441	321	774	459	Tinggi	Menipis
Minggu 67	522	881	381	513	195	167	Tinggi	Menipis
Minggu 68	878	852	382	275	693	645	Tinggi	Menipis
Minggu 69	372	431	163	722	917	799	Tinggi	Menipis
Minggu 70	571	554	551	194	159	596	Tinggi	Menipis
Minggu 71	943	651	325	234	275	746	Tinggi	Menipis
Minggu 72	464	661	861	628	878	184	Tinggi	Menipis
Minggu 73	154	221	121	852	733	129	Sedang	Aman

Minggu Ke	Tople s	Ember	Kantong Plastik	Botol Minum	Total Penjualan	Stok Akhir	Kategori Penjualan	Kategori Stok
Minggu 74	221	848	445	539	113	996	Sedang	Aman
Minggu 75	549	576	597	951	445	196	Sedang	Aman
Minggu 76	727	397	919	587	757	821	Sedang	Aman
Minggu 77	871	256	281	165	832	811	Sedang	Aman
Minggu 78	195	863	628	155	136	815	Sedang	Aman
Minggu 79	687	536	521	481	244	861	Sedang	Aman
Minggu 80	315	596	293	624	185	476	Sedang	Aman
Minggu 81	871	667	735	926	558	642	Rendah	Aman
Minggu 82	878	196	985	269	316	945	Rendah	Aman
Minggu 83	799	743	832	815	619	791	Rendah	Aman
Minggu 84	976	354	365	386	749	325	Rendah	Aman
Minggu 85	137	696	625	162	581	147	Rendah	Aman
Minggu 86	392	974	659	447	584	224	Rendah	Aman
Minggu 87	289	251	815	961	175	849	Rendah	Aman
Minggu 88	916	333	783	983	862	493	Rendah	Aman
Minggu 89	138	134	439	298	919	814	Tinggi	Kritis
Minggu 90	154	576	577	473	727	871	Tinggi	Kritis
Minggu 91	943	545	455	286	811	321	Tinggi	Kritis
Minggu 92	933	666	168	941	115	752	Tinggi	Kritis
Minggu 93	545	476	375	419	626	119	Tinggi	Kritis
Minggu 94	642	457	933	854	425	194	Tinggi	Kritis
Minggu 95	166	952	194	221	781	926	Tinggi	Kritis
Minggu 96	145	588	796	999	845	931	Tinggi	Kritis

Tahap pengolahan data dilakukan setelah seluruh data penjualan dan persediaan terkumpul. Langkah pertama adalah data *cleaning*, yaitu memastikan dataset bebas dari data ganda, data hilang, dan ketidaksesuaian format. Proses ini dilakukan untuk meningkatkan kualitas dataset karena kesalahan pencatatan dapat memengaruhi hasil prediksi (Sutarman & Ridwan, 2023). Pada tahap ini, nilai kosong diselesaikan menggunakan metode imputasi rata-rata (*mean imputation*), sesuai rekomendasi penelitian yang menyebutkan metode tersebut efektif untuk dataset retail dengan skala numerik (Herman & Putri, 2024).

Setelah proses pembersihan, data dilanjutkan ke tahap normalisasi, untuk menyeragamkan rentang angka agar mempermudah algoritma membaca pola data. Teknik normalisasi digunakan karena model prediksi lebih optimal saat skala variabel berada dalam rentang yang seragam (Kartika & Syahputra, 2025). Nilai penjualan dan persediaan kemudian ditransformasi menggunakan metode *equal-width discretization* menjadi tiga kategori: Rendah, Sedang, dan Tinggi, agar model dapat melakukan klasifikasi lebih terstruktur. Pendekatan kategorisasi ini dinilai efektif karena mempermudah model machine learning dalam mengenali pola tingkat permintaan (Yuliana & Hidayat, 2022).

Tahap terakhir pengolahan data adalah pembagian dataset menggunakan metode *holdout validation*, dengan komposisi 80% sebagai data training dan 20% sebagai data testing. Pembagian ini bertujuan mengevaluasi kemampuan model dalam memprediksi data baru yang belum dipelajari sebelumnya (Alvaro & Nainggolan, 2024). Dataset yang telah melewati seluruh tahap pengolahan kemudian siap digunakan dalam proses pemodelan prediksi menggunakan algoritma machine learning.



Gambar 2. Pre Processing

Gambar 2 menunjukkan tahapan *pre-processing* data yang dilakukan sebelum data digunakan untuk proses pelatihan model klasifikasi. Tahapan ini berfungsi untuk memastikan bahwa dataset berada dalam format yang sesuai dengan kebutuhan algoritma machine learning sehingga dapat menghasilkan prediksi yang lebih akurat dan stabil. Proses dimulai dengan operator *Retrieve*, yang digunakan untuk memanggil dataset dari repository RapidMiner. Selanjutnya, operator *Select Attributes* digunakan untuk memilih atribut yang relevan dan menghapus atribut yang tidak diperlukan, seperti kolom identitas atau atribut yang tidak memberikan kontribusi terhadap prediksi (Audita, Damanik, & Irawan, 2024).

Tahap berikutnya adalah proses *Discretize*, yaitu mengubah atribut numerik seperti total penjualan dan stok akhir menjadi interval kategori menggunakan metode *equal-width discretization*. Proses ini dilakukan untuk mendukung algoritma klasifikasi yang lebih

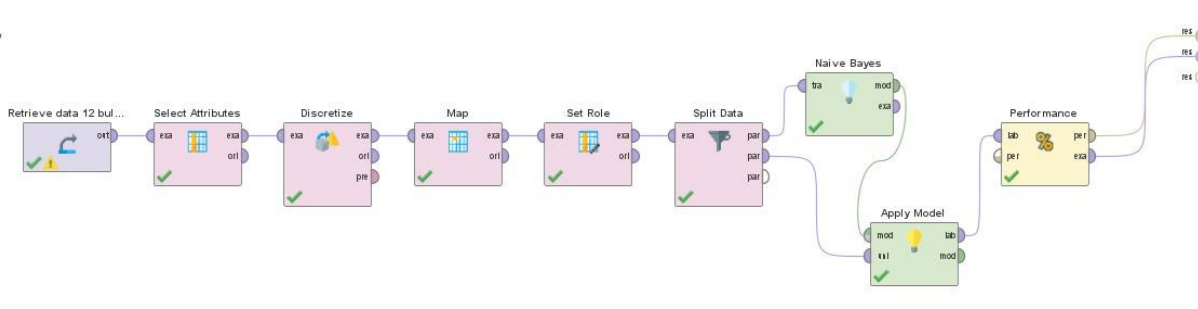
optimal ketika menggunakan data kategorikal, terutama pada dataset dengan ukuran kecil. Setelah itu, operator *Map* digunakan untuk menyeragamkan format penamaan kategori agar tidak terjadi perbedaan penulisan yang dapat memengaruhi proses klasifikasi, seperti perbedaan huruf kapital pada label (Kawilarang & Fitriana, 2024). Operator terakhir pada tahap preprocessing adalah *Set Role*, yang berfungsi menentukan atribut target (label), yaitu kolom Kategori Stok, sehingga sistem dapat mengenali variabel mana yang akan diprediksi oleh model. Secara keseluruhan, proses ini memastikan dataset berada dalam kondisi bersih, terstruktur, dan siap digunakan dalam tahap pemodelan (Saputro, Syaharani, Septaria, & Shofa, 2025).

Row No.	Kategori Pe...	Topies	Ember	Kantong Pla...	Botol Minum	Total Penju...	Stok Akhir	Minggu Ke	Kategori Stok	Row No.	Kategori Pe...	Topies	Ember	Kantong Pla...	Botol Minum	Total Penju...	Stok Akhir	Minggu Ke	Kategori Stok
1	Sedang	Rendah	Rendah	Sedang	Rendah	Sedang	Sedang	Minggu 1	Aman	19	Tinggi	Sedang	Rendah	Rendah	Rendah	Rendah	Sedang	Minggu 24	Aman
2	Sedang	Sedang	Sedang	Rendah	Rendah	Rendah	Sedang	Minggu 2	Aman	20	Sedang	Sedang	Sedang	Sedang	Rendah	Rendah	Rendah	Minggu 25	Aman
3	Sedang	Sedang	Sedang	Rendah	Rendah	Rendah	Sedang	Minggu 3	Aman	21	Sedang	Sedang	Rendah	Rendah	Rendah	Sedang	Sedang	Minggu 26	Aman
4	Sedang	Sedang	Rendah	Rendah	Sedang	Sedang	Rendah	Minggu 4	Aman	22	Sedang	Sedang	Rendah	Rendah	Rendah	Rendah	Sedang	Minggu 27	Aman
5	Sedang	Rendah	Rendah	Sedang	Rendah	Rendah	Rendah	Minggu 8	Aman	23	Sedang	Sedang	Sedang	Sedang	Rendah	Rendah	Sedang	Minggu 29	Aman
6	Sedang	Sedang	Sedang	Rendah	Rendah	Rendah	Rendah	Minggu 9	Aman	24	Sedang	Rendah	Rendah	Sedang	Sedang	Rendah	Rendah	Minggu 30	Aman
7	Sedang	Rendah	Rendah	Rendah	Rendah	Rendah	Rendah	Minggu 10	Aman	25	Sedang	Sedang	Sedang	Sedang	Rendah	Sedang	Rendah	Minggu 31	Aman
8	Sedang	Rendah	Rendah	Sedang	Rendah	Sedang	Rendah	Minggu 11	Aman	26	Sedang	Rendah	Rendah	Rendah	Sedang	Rendah	Sedang	Minggu 32	Aman
9	Sedang	Rendah	Rendah	Rendah	Rendah	Sedang	Rendah	Minggu 12	Aman	27	Rendah	Rendah	Sedang	Sedang	Rendah	Rendah	Sedang	Minggu 33	Aman
10	Sedang	Rendah	Rendah	Sedang	Sedang	Sedang	Sedang	Minggu 13	Aman	28	Rendah	Sedang	Rendah	Sedang	Rendah	Sedang	Sedang	Minggu 35	Aman
11	Sedang	Rendah	Rendah	Sedang	Rendah	Rendah	Sedang	Minggu 14	Aman	29	Rendah	Sedang	Rendah	Sedang	Rendah	Sedang	Rendah	Minggu 36	Aman
12	Sedang	Sedang	Rendah	Sedang	Rendah	Rendah	Rendah	Minggu 15	Aman	30	Rendah	Sedang	Sedang	Rendah	Rendah	Rendah	Sedang	Minggu 37	Aman
13	Sedang	Rendah	Rendah	Sedang	Sedang	Sedang	Rendah	Minggu 16	Aman	31	Rendah	Sedang	Sedang	Rendah	Sedang	Sedang	Sedang	Minggu 39	Aman
14	Tinggi	Rendah	Sedang	Sedang	Rendah	Rendah	Sedang	Minggu 17	Aman	32	Rendah	Rendah	Rendah	Sedang	Rendah	Rendah	Rendah	Minggu 40	Aman
15	Tinggi	Rendah	Rendah	Rendah	Rendah	Sedang	Sedang	Minggu 18	Aman	33	Sedang	Rendah	Rendah	Sedang	Rendah	Rendah	Sedang	Minggu 42	Aman
16	Tinggi	Rendah	Sedang	Sedang	Rendah	Rendah	Sedang	Minggu 19	Aman	34	Sedang	Rendah	Rendah	Rendah	Rendah	Sedang	Sedang	Minggu 43	Aman
17	Tinggi	Rendah	Rendah	Rendah	Sedang	Sedang	Rendah	Minggu 20	Aman	35	Sedang	Sedang	Sedang	Rendah	Sedang	Sedang	Rendah	Minggu 44	Aman
18	Tinggi	Sedang	Rendah	Sedang	Rendah	Sedang	Sedang	Minggu 22	Aman	36	Sedang	Rendah	Rendah	Sedang	Rendah	Rendah	Rendah	Minggu 45	Aman
37	Sedang	Rendah	Rendah	Sedang	Rendah	Sedang	Rendah	Minggu 46	Aman	55	Tinggi	Sedang	Rendah	Rendah	Rendah	Sedang	Rendah	Minggu 66	Menipis
38	Sedang	Rendah	Rendah	Rendah	Sedang	Rendah	Sedang	Minggu 47	Aman	56	Tinggi	Sedang	Sedang	Rendah	Rendah	Sedang	Sedang	Minggu 68	Menipis
39	Sedang	Rendah	Rendah	Rendah	Rendah	Rendah	Rendah	Minggu 48	Aman	57	Tinggi	Sedang	Sedang	Rendah	Rendah	Sedang	Sedang	Minggu 70	Menipis
40	Tinggi	Sedang	Sedang	Rendah	Sedang	Rendah	Rendah	Minggu 49	Menipis	58	Tinggi	Sedang	Sedang	Rendah	Rendah	Rendah	Sedang	Minggu 71	Menipis
41	Tinggi	Rendah	Rendah	Sedang	Sedang	Rendah	Sedang	Minggu 51	Menipis	59	Tinggi	Rendah	Sedang	Sedang	Sedang	Sedang	Rendah	Minggu 72	Menipis
42	Tinggi	Rendah	Sedang	Sedang	Rendah	Rendah	Rendah	Minggu 52	Menipis	60	Sedang	Rendah	Rendah	Rendah	Sedang	Sedang	Sedang	Minggu 73	Aman
43	Tinggi	Rendah	Rendah	Sedang	Sedang	Rendah	Sedang	Minggu 53	Menipis	61	Sedang	Rendah	Sedang	Rendah	Rendah	Rendah	Sedang	Minggu 74	Aman
44	Tinggi	Rendah	Rendah	Rendah	Rendah	Sedang	Rendah	Minggu 54	Menipis	62	Sedang	Sedang	Sedang	Sedang	Sedang	Rendah	Rendah	Minggu 75	Aman
45	Tinggi	Rendah	Rendah	Rendah	Sedang	Rendah	Sedang	Minggu 55	Menipis	63	Sedang	Sedang	Rendah	Sedang	Sedang	Sedang	Sedang	Minggu 76	Aman
46	Tinggi	Rendah	Sedang	Rendah	Sedang	Rendah	Sedang	Minggu 56	Menipis	64	Sedang	Sedang	Rendah	Rendah	Rendah	Sedang	Sedang	Minggu 77	Aman
47	Tinggi	Rendah	Sedang	Rendah	Rendah	Rendah	Rendah	Minggu 57	Menipis	65	Rendah	Sedang	Sedang	Sedang	Sedang	Sedang	Sedang	Minggu 81	Aman
48	Tinggi	Rendah	Rendah	Rendah	Sedang	Rendah	Sedang	Minggu 58	Menipis	66	Rendah	Sedang	Rendah	Sedang	Rendah	Rendah	Sedang	Minggu 82	Aman
49	Tinggi	Rendah	Rendah	Rendah	Sedang	Rendah	Sedang	Minggu 59	Menipis	67	Rendah	Sedang	Sedang	Sedang	Sedang	Sedang	Sedang	Minggu 83	Aman
50	Tinggi	Rendah	Sedang	Sedang	Rendah	Sedang	Sedang	Minggu 60	Menipis	68	Rendah	Sedang	Rendah	Rendah	Rendah	Sedang	Sedang	Minggu 84	Aman
51	Tinggi	Rendah	Sedang	Rendah	Sedang	Sedang	Sedang	Minggu 61	Menipis	69	Rendah	Rendah	Sedang	Sedang	Rendah	Sedang	Rendah	Minggu 85	Aman
52	Tinggi	Rendah	Rendah	Rendah	Rendah	Rendah	Rendah	Minggu 62	Menipis	70	Rendah	Rendah	Rendah	Sedang	Sedang	Rendah	Sedang	Minggu 87	Aman
53	Sedang	Sedang	Sedang	Sedang	Rendah	Rendah	Rendah	Minggu 63	Menipis	71	Rendah	Sedang	Rendah	Sedang	Sedang	Sedang	Rendah	Minggu 88	Aman
54	Tinggi	Sedang	Rendah	Sedang	Sedang	Sedang	Rendah	Minggu 64	Menipis	72	Tinggi	Sedang	Sedang	Rendah	Rendah	Sedang	Rendah	Minggu 91	Kritis

Gambar 3. Hasil Perubahan *Range* Menjadi Skala Menggunakan *Map*

Gambar 3 menunjukkan proses normalisasi data menggunakan operator *Map* untuk menyeragamkan kategori agar konsisten sebelum digunakan dalam pemodelan. Pada tahap ini, perbedaan penulisan seperti variasi huruf kapital atau format yang tidak seragam diperbaiki sehingga seluruh kategori memiliki format yang sama, seperti “Tinggi,” “Sedang,” dan “Rendah” pada kategori penjualan serta “Aman,” “Menipis,” dan “Kritis” pada kategori stok. Proses ini dilakukan untuk mencegah sistem menganggap label yang serupa sebagai kelas berbeda, sehingga membantu meningkatkan akurasi model pada tahap klasifikasi berikutnya.

Dari data di atas, *dataset* langsung diolah menggunakan RapidMiner untuk proses pembentukan model prediksi, yang meliputi penetapan label, pembagian data, pelatihan model *Naïve Bayes*, dan evaluasi kinerja seperti terlihat pada Gambar 4.



Gambar 4. Proses Prediksi Persediaan Menggunakan RapidMiner

R...	Kategori Stok	prediction(K...	confidence(...	confidence(...	confidence(...	Toples	Ember	Kantong Pla...	Botol Minum	Total Penjual...	Stok Akhir	Minggu Ke	Kategori Pe...
1	Aman	Aman	0.992	0.001	0.007	Sedang	Sedang	Rendah	Rendah	Rendah	Rendah	Minggu 9	Sedang
2	Aman	Aman	0.997	0.002	0.001	Rendah	Rendah	Rendah	Rendah	Rendah	Rendah	Minggu 10	Sedang
3	Aman	Aman	0.999	0.000	0.001	Rendah	Rendah	Sedang	Rendah	Sedang	Rendah	Minggu 11	Sedang
4	Aman	Aman	0.998	0.000	0.001	Sedang	Rendah	Sedang	Rendah	Rendah	Rendah	Minggu 15	Sedang
5	Aman	Kritis	0.234	0.139	0.626	Sedang	Rendah	Sedang	Rendah	Sedang	Sedang	Minggu 22	Tinggi
6	Aman	Aman	0.996	0.001	0.003	Sedang	Sedang	Sedang	Rendah	Rendah	Rendah	Minggu 25	Sedang
7	Aman	Aman	0.995	0.004	0.001	Rendah	Rendah	Rendah	Rendah	Rendah	Sedang	Minggu 32	Sedang
8	Aman	Aman	0.997	0.002	0.001	Rendah	Rendah	Sedang	Rendah	Rendah	Rendah	Minggu 40	Rendah
9	Aman	Aman	0.992	0.003	0.005	Rendah	Sedang	Rendah	Sedang	Sedang	Sedang	Minggu 41	Sedang
10	Aman	Aman	0.998	0.001	0.001	Rendah	Rendah	Sedang	Sedang	Rendah	Rendah	Minggu 45	Sedang
11	Aman	Aman	0.997	0.002	0.001	Rendah	Rendah	Rendah	Rendah	Rendah	Sedang	Minggu 48	Sedang
12	Menipis	Menipis	0.100	0.768	0.132	Rendah	Rendah	Sedang	Sedang	Rendah	Sedang	Minggu 51	Tinggi
13	Menipis	Kritis	0.137	0.397	0.465	Rendah	Sedang	Sedang	Rendah	Sedang	Sedang	Minggu 60	Tinggi
14	Menipis	Menipis	0.059	0.793	0.148	Rendah	Rendah	Rendah	Rendah	Rendah	Rendah	Minggu 62	Tinggi
15	Menipis	Kritis	0.097	0.198	0.705	Sedang	Rendah	Rendah	Rendah	Sedang	Rendah	Minggu 66	Tinggi
16	Menipis	Kritis	0.052	0.401	0.546	Sedang	Sedang	Rendah	Rendah	Rendah	Sedang	Minggu 70	Tinggi
17	Aman	Aman	0.994	0.003	0.003	Rendah	Sedang	Rendah	Rendah	Rendah	Sedang	Minggu 74	Sedang
18	Aman	Aman	0.988	0.001	0.011	Sedang	Sedang	Sedang	Sedang	Sedang	Sedang	Minggu 81	Rendah
19	Kritis	Menipis	0.120	0.558	0.321	Rendah	Rendah	Rendah	Rendah	Sedang	Sedang	Minggu 89	Tinggi
20	Kritis	Kritis	0.137	0.397	0.465	Rendah	Sedang	Sedang	Rendah	Sedang	Sedang	Minggu 90	Tinggi

Gambar 5. Hasil Proses Menggunakan RapidMiner Pada Stok Persediaan

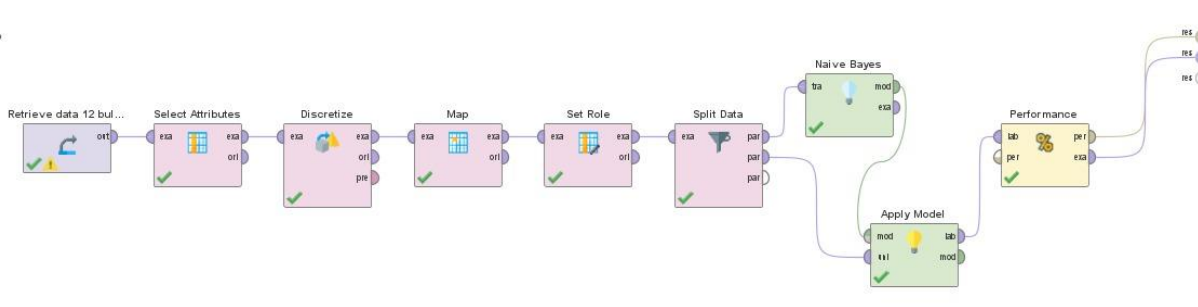
accuracy: 75.00%

	true Aman	true Menipis	true Kritis	class precision
pred. Aman	12	0	0	100.00%
pred. Menipis	0	2	1	66.67%
pred. Kritis	1	3	1	20.00%
class recall	92.31%	40.00%	50.00%	

Gambar 6. Hasil Nilai Akurasi Pada Stok Persediaan

Gambar 6 menampilkan hasil proses klasifikasi stok persediaan menggunakan *RapidMiner* dengan algoritma *Naïve Bayes*, di mana setiap data mingguan berhasil diprediksi ke dalam kategori Aman, Menipis, atau Kritis. Pada tampilan tersebut terlihat nilai *prediction* beserta *confidence* yang menunjukkan tingkat keyakinan model terhadap setiap hasil prediksi; sebagian besar data memiliki tingkat keyakinan tinggi, terutama pada kategori Aman. Hasil ini menunjukkan bahwa proses *pre-processing* seperti normalisasi, kategorisasi, dan penetapan label telah berjalan dengan baik sehingga model mampu membaca pola stok berdasarkan variabel penjualan dan stok akhir secara konsisten. Selanjutnya, Gambar 7 menggambarkan performa model melalui *confusion matrix* dengan akurasi sebesar 75%, yang berarti sebagian besar data uji dapat diprediksi dengan benar. Nilai *precision* dan *recall* yang ditampilkan juga memberikan gambaran kemampuan model dalam mengenali masing-masing kategori stok: kategori *Aman* menunjukkan performa

sangat baik dengan *precision* 100% dan *recall* 92,31%, sementara kategori Menipis dan Kritis memiliki nilai yang lebih rendah karena karakteristik datanya yang saling berdekatan. Secara keseluruhan, kombinasi hasil pada Gambar 6 dan Gambar 7 menunjukkan bahwa algoritma *Naïve Bayes* mampu memberikan prediksi stok yang cukup akurat dan dapat digunakan sebagai dasar pendukung keputusan dalam pengelolaan persediaan pada Toko Berkas Plastik.



Gambar 7. Proses Prediksi Penjualan Menggunakan RapidMiner

Ro...	Kategori Pe...	prediction[K...	confidence(...	confidence(...	confidence(...	Toples	Ember	Kantong Pla...	Botol Minum	Total Penjua...	Stok Akhir	Minggu Ke	Kategori Stok
1	Sedang	Sedang	0.565	0.289	0.146	Rendah	Sedang	Rendah	Sedang	Rendah	Rendah	Minggu 5	Aman
2	Sedang	Rendah	0.416	0.146	0.438	Sedang	Sedang	Rendah	Sedang	Sedang	Rendah	Minggu 6	Aman
3	Sedang	Sedang	0.540	0.272	0.187	Rendah	Sedang	Rendah	Rendah	Rendah	Sedang	Minggu 7	Aman
4	Tinggi	Sedang	0.430	0.150	0.420	Rendah	Sedang	Sedang	Sedang	Rendah	Rendah	Minggu 21	Aman
5	Tinggi	Rendah	0.416	0.146	0.438	Sedang	Sedang	Rendah	Sedang	Sedang	Rendah	Minggu 23	Aman
6	Sedang	Rendah	0.254	0.114	0.632	Rendah	Sedang	Sedang	Sedang	Sedang	Sedang	Minggu 28	Aman
7	Rendah	Rendah	0.285	0.023	0.692	Sedang	Rendah	Sedang	Rendah	Sedang	Sedang	Minggu 34	Aman
8	Rendah	Sedang	0.743	0.116	0.140	Rendah	Rendah	Rendah	Sedang	Sedang	Rendah	Minggu 38	Aman
9	Sedang	Sedang	0.431	0.284	0.285	Rendah	Sedang	Rendah	Sedang	Sedang	Sedang	Minggu 41	Aman
10	Tinggi	Tinggi	0.001	0.999	0.000	Rendah	Rendah	Rendah	Rendah	Rendah	Rendah	Minggu 50	Menipis
11	Tinggi	Tinggi	0.000	1.000	0.000	Rendah	Sedang	Rendah	Sedang	Rendah	Sedang	Minggu 65	Menipis
12	Tinggi	Tinggi	0.000	0.999	0.000	Rendah	Sedang	Rendah	Rendah	Rendah	Rendah	Minggu 67	Menipis
13	Tinggi	Tinggi	0.001	0.999	0.000	Rendah	Rendah	Rendah	Sedang	Sedang	Sedang	Minggu 69	Menipis
14	Sedang	Rendah	0.378	0.129	0.493	Rendah	Sedang	Sedang	Rendah	Rendah	Sedang	Minggu 78	Aman
15	Sedang	Sedang	0.650	0.088	0.262	Sedang	Rendah	Rendah	Rendah	Rendah	Sedang	Minggu 79	Aman
16	Sedang	Sedang	0.565	0.289	0.146	Rendah	Sedang	Sedang	Sedang	Rendah	Rendah	Minggu 80	Aman
17	Rendah	Rendah	0.398	0.082	0.520	Rendah	Sedang	Sedang	Rendah	Sedang	Rendah	Minggu 86	Aman
18	Tinggi	Tinggi	0.003	0.996	0.002	Rendah	Rendah	Rendah	Rendah	Sedang	Sedang	Minggu 89	Kritis
19	Tinggi	Tinggi	0.001	0.992	0.007	Rendah	Sedang	Sedang	Rendah	Sedang	Sedang	Minggu 90	Kritis

Gambar 8. Hasil Proses Menggunakan RapidMiner Pada Penjualan

accuracy: 68.42%

	true Sedang	true Tinggi	true Rendah	class precision
pred. Sedang	5	1	1	71.43%
pred. Tinggi	0	6	0	100.00%
pred. Rendah	3	1	2	33.33%
class recall	62.50%	75.00%	66.67%	

Gambar 9. Hasil Nilai Akurasi Pada Stok Penjualan

Gambar 9 menunjukkan hasil proses klasifikasi tingkat penjualan menggunakan *RapidMiner* dengan algoritma *Naïve Bayes*. Pada tampilan tersebut terlihat bahwa setiap data penjualan berhasil diprediksi ke dalam kategori Rendah, Sedang, dan Tinggi berdasarkan atribut input seperti jumlah penjualan pada masing-masing produk (Toples, Ember, Kantong Plastik, dan Botol Minum) serta total penjualan per minggu. Model menampilkan nilai *prediction* beserta *confidence* yang menggambarkan tingkat keyakinan algoritma terhadap keputusan klasifikasi yang diberikan. Terlihat bahwa sebagian besar nilai

confidence berada pada kisaran menengah hingga tinggi, menunjukkan bahwa model mampu mengenali pola penjualan dengan cukup baik. Gambar 10 kemudian menyajikan evaluasi performa model melalui *confusion matrix*, dengan akurasi sebesar 68,42%. Hasil ini menunjukkan bahwa mayoritas data uji dapat diklasifikasikan dengan benar. Nilai *class precision* memperlihatkan bahwa kategori Tinggi memiliki presisi 100%, menunjukkan kemampuan model yang sangat baik dalam mengenali pola penjualan tinggi. Sementara itu, kategori Sedang memiliki presisi 71,43% dan kategori Rendah sebesar 33,33%, yang mengindikasikan bahwa data dengan pola penjualan rendah masih cenderung tumpang tindih dengan kategori lain. Nilai *recall* juga memperlihatkan variasi performa antar kelas, dengan kategori Tinggi memiliki *recall* tertinggi sebesar 75%, disusul Rendah sebesar 66,67%, dan Sedang sebesar 62,50%. Secara keseluruhan, hasil pada Gambar 9 dan Gambar 10 menunjukkan bahwa model *Naïve Bayes* mampu memberikan prediksi yang cukup baik untuk mengidentifikasi tingkat penjualan mingguan, sehingga dapat digunakan sebagai dasar dalam analisis permintaan dan perencanaan stok pada Toko Berkat Plastik.

Hasil pemodelan prediksi yang dilakukan menggunakan *RapidMiner* dengan algoritma *Naïve Bayes* menunjukkan bahwa baik proses klasifikasi stok persediaan maupun tingkat penjualan mampu memberikan gambaran yang cukup akurat mengenai pola data pada Toko Berkat Plastik. Secara umum, kedua model menunjukkan kemampuan yang stabil dalam membaca hubungan antara variabel penjualan, stok akhir, dan kategori klasifikasi yang telah ditetapkan. Dari sisi stok persediaan, model berhasil mencapai akurasi sebesar 75%, yang mengindikasikan bahwa sebagian besar data uji dapat diprediksi dengan tepat. Model menunjukkan performa yang sangat baik dalam mengidentifikasi kategori *Aman*, ditandai dengan nilai *precision* 100% dan *recall* 92,31%. Hal ini menunjukkan bahwa stok yang berada pada kondisi stabil memiliki pola yang sangat jelas dan mudah dikenali oleh model. Namun, performa klasifikasi menurun pada kategori *Menipis* dan *Kritis*, yang terlihat dari nilai *precision* dan *recall* yang lebih rendah. Rendahnya akurasi pada kategori ini disebabkan oleh karakteristik data yang tumpang tindih, di mana nilai stok akhir yang menurun tidak selalu berbanding lurus dengan jumlah penjualan. Meskipun demikian, model tetap mampu memberikan indikasi awal mengenai kecenderungan stok memasuki kondisi kurang stabil, sehingga tetap relevan sebagai alat pendukung keputusan pengadaan (Budianto et al, 2024).

Pada sisi prediksi tingkat penjualan, hasil menunjukkan akurasi sebesar 68,42%, yang sedikit lebih rendah dibandingkan prediksi stok, namun tetap berada dalam kategori cukup baik untuk digunakan dalam sistem pendukung keputusan. Model menunjukkan performa terbaik pada kategori Tinggi dengan nilai *precision* 100% dan *recall* 75%, yang berarti pola penjualan tinggi memiliki ciri yang sangat mudah dikenali oleh algoritma. Sebaliknya, kategori Sedang dan Rendah menunjukkan variasi data yang lebih lebar, sehingga presisi model menurun, khususnya pada kelas *Rendah* yang hanya memiliki *precision* 33,33%. Hal ini mengindikasikan bahwa aktivitas penjualan di kategori menengah dan rendah memiliki pola fluktuatif yang membuat proses klasifikasi menjadi lebih menantang. Meskipun demikian, model masih mampu memberikan prediksi yang cukup

informatif terhadap kecenderungan penjualan mingguan, terutama pada kategori yang ekstrem seperti Tinggi.

Secara keseluruhan, hasil prediksi stok dan penjualan menunjukkan bahwa algoritma *Naïve Bayes* efektif digunakan pada dataset dengan struktur kategori dan data historis mingguan seperti pada Toko Berkas Plastik. Kombinasi kedua model ini memberikan gambaran menyeluruh bagi pemilik usaha dalam mengelola inventori: hasil prediksi penjualan dapat digunakan untuk memperkirakan permintaan, sedangkan prediksi stok memberikan informasi mengenai kondisi ketersediaan barang. Dengan demikian, kedua model saling melengkapi dalam membantu proses pengambilan keputusan, terutama dalam menentukan jumlah pembelian ulang (*reorder*), mengantisipasi risiko *overstock* maupun *stockout*, serta mengoptimalkan rotasi barang sesuai kategori permintaan. Implementasi model ini berpotensi meningkatkan efisiensi operasional, mempercepat proses perencanaan, serta mengurangi risiko kerugian akibat ketidakakuratan pengadaan barang.

Simpulan

Berdasarkan hasil penelitian, model prediksi yang dikembangkan menggunakan algoritma *Naïve Bayes* mampu memberikan gambaran yang cukup akurat terhadap pola penjualan dan kondisi persediaan pada Toko Berkas Plastik. Model prediksi stok menghasilkan akurasi sebesar 75% dengan performa terbaik pada kategori *Aman*, sedangkan model prediksi penjualan mencapai akurasi 68,42% dengan kemampuan paling kuat dalam mengenali kategori penjualan *Tinggi*. Temuan ini menunjukkan bahwa algoritma *Naïve Bayes* efektif digunakan untuk mengolah data historis berskala mingguan, meskipun masih terdapat tantangan pada kategori Menipis, Kritis, Sedang, dan Rendah yang memiliki pola data lebih fluktuatif. Oleh karena itu, pemilik usaha disarankan untuk mengintegrasikan model ini dalam operasional harian, terutama untuk memantau kategori stok yang berisiko serta menentukan waktu yang tepat untuk melakukan *reorder*. Produk dengan penjualan tinggi juga perlu diprioritaskan dalam perencanaan pembelian, sedangkan kategori risiko seperti Menipis dan Kritis memerlukan pemantauan intensif dan penambahan *safety stock*. Untuk meningkatkan akurasi model, data dapat diperkaya dengan variabel tambahan seperti tren bulanan, momen musiman, dan promosi. Penelitian lanjutan juga direkomendasikan untuk menguji algoritma lain seperti *Random Forest* atau *Decision Tree* sebagai pembanding. Selain itu, pembuatan dashboard monitoring berbasis *Power BI* atau *RapidMiner* akan membantu pemilik usaha memantau kondisi penjualan dan stok secara *real-time* sehingga proses pengambilan keputusan dapat dilakukan lebih cepat dan lebih tepat sasaran.

Daftar Pustaka

- Aldahmani, E., Alzubi, A., & Iyiola, K. (2024). Demand forecasting in supply chain using hybrid regression model. *Applied Sciences*, 14(18), 8110.
- Anggraini, S., & Kurniawan, R. (2024). Historical sales data as forecasting input for retail analysis. *Journal of Business Analytics*, 6(2), 51–60.
- Audita, I., Damanik, I. S., & Irawan, E. (2024). Pemetaan hasil produksi buah-buahan dengan teknik data mining K-Medoids. *Jurnal Teknik Mesin, Industri, Elektro dan Informatika*, 1(3). <https://doi.org/10.55606/jtmei.v1i3.535>
- Aulia, D., & Fathurrahman, M. (2024). Implementasi machine learning untuk optimasi inventori produk retail. *Jurnal Teknologi Informasi dan Data Mining*, 5(1), 33–44.
- Ayuningtyas, N., R., & Basysyar, F. (2022). Penerapan data mining pada penjualan produk menggunakan metode Naïve Bayes. *AIMS Journal*, 5(2), 157-166.
- Budianto, A. G., Eko Suryo, A. T., Zulkarnain, A. F., Cahyono, G. R., Rusilawati, & Az-Zahra, S. F. (2024). A text mining approach to analyzing the omnichannel retail business performance of the KlikIndomaret app. *Jurnal Teknik Industri: Jurnal Keilmuan dan Aplikasi Teknik Industri*, 26(2), 131–144. <https://doi.org/10.9744/jti.26.2.131-144>.
- Firmansyah, R., & Hanifa, L. (2024). Normalisasi data dalam model prediksi menggunakan skala min-max. *Journal of Artificial Intelligence Research*, 9(2), 115–124.
- Hartawan, I. (2024). Hyperparameter tuning in LSTM for product demand prediction. *JKDN Journal*, 8(1), 54-62.
- Hidayat, M., Suarna, N., & Rahaningsih, N. (2023). Implementasi klasifikasi untuk prediksi persediaan barang. *JATI Journal*, 7(1), 693-699.
- Kawilarang, R. D. A., & Fitriana, R. (2024). Data mining dan aplikasi Six Sigma dalam meningkatkan kualitas batubara pada pembangkit listrik. *JISI: Jurnal Integrasi Sistem Industri*, 11(2), 183–190. <https://doi.org/10.24853/jisi.11.2.183-190>.
- Khairunnisa, A., & Yusuf, M. (2022). Penerapan discretization pada data mining untuk peningkatan akurasi klasifikasi inventori. *Journal of Applied Data Science*, 6(3), 221–230.
- Liu, Y., Chen, X., & Wei, F. (2025). Machine learning-based inventory simulation for retail stock control. *Journal of Digital Economy*, 4(2), 112-126.
- Maulana, H., & Febrianti, S. (2023). Discretization techniques for classification models in retail datasets. *Journal of Data Science and Informatics*, 5(1), 77–88.
- Mulyani, S., Pratama, R., & Dewantara, Y. (2023). Framework KDD pada prediksi penjualan retail berbasis data mining. *Journal of Information Systems and Analytics*, 4(2), 89–102.
- Munoz, L. (2024). SKU-based forecasting strategy using classification clustering. *RSD Journal*, 13(6), 1151-1163.
- Pradhana, A., Firmansyah, A., & Islami, M. (2025). Prediksi penjualan dan klasifikasi kategori menggunakan RapidMiner. *JAMI Journal*, 6(1), 9-17.
- Putra, A., & Hidayat, R. (2022). Pendekatan kuantitatif pada prediksi sistem informasi penjualan retail. *Jurnal Sistem Informasi Indonesia*, 8(1), 71–82.

- Rahmawati, N., & Idris, F. (2022). Transaction-based documentation method for sales data collection. *Information Management Journal*, 4(3), 144–155.
- Rahmawati, N., & Samudra, H. (2023). Tren penjualan berbasis data historis untuk retail modern. *Jurnal Manajemen Industri & Rantai Pasok*, 12(4), 177–188.
- Sabilla, A., Irnanda, R., & Putri, N. (2025). Strategi e-SCM berbasis klasifikasi persediaan. *JTIKP Journal*, 5(3), 211-223.
- Safitri, L., & Kurniawan, A. (2025). Teknik pembagian dataset dalam validasi model machine learning. *Journal of Computational Intelligence*, 11(1), 58–70.
- Salsabila, D., & Nurdiansyah, B. (2024). Dataset split strategies for forecasting and classification models. *Machine Learning Applications Journal*, 11(1), 65–73.
- Saputra, A., & Aziz, M. (2025). The role of data cleansing in machine learning forecasting. *Journal of Artificial Intelligence Practice*, 9(1), 22–30.
- Saputro, M. R., Syaharani, A. D., Septaria, S. S., & Shofa, M. J. (2025). Penerapan teknik asosiasi data mining untuk menemukan pola penjualan di kantin kampus. *Jurnal Aplikasi Ilmu Teknik Industri (JAPTI)*, 6(1), 1–10. <https://doi.org/10.32585/japti.v6i1.6243>.
- Widiyanto, B., & Firdaus, D. (2024). Model prediksi penjualan menggunakan pendekatan KDD untuk UMKM. *Management Innovation Journal*, 7(1), 101–115.
- Wijaya, T., Sari, F., & Nugroho, P. (2021). Kinerja algoritma Naïve Bayes dalam klasifikasi dataset retail. *Journal of Information Technology and Computation*, 5(2), 142–150.
- Zulfiqar, M., & Rahmat, F. (2024). RapidMiner sebagai platform prediksi dan klasifikasi retail. *Jurnal Teknologi Komputasi dan Sistem Cerdas*, 6(1), 55–67.