

# Model Prediksi Penjualan Produk OTC Berbasis Ensemble Kernel Gaussian Process Regression: Analisis Empiris pada Data Transaksi Farmasi Multinasional

## *An Ensemble Kernel Gaussian Process Regression Framework for Predicting OTC Pharmaceutical Sales: An Empirical Analysis on Multinational Transaction Data*

**Firman Aziz<sup>1</sup>; Irmawati<sup>2,\*</sup>; Ayu Lestari Azis<sup>3</sup>**

<sup>1</sup> Universitas Pancasakti, Makassar 90121, Indonesia

<sup>2,3</sup> Irmex Digital Akademika, Makassar 90551, Indonesia

<sup>1</sup>[firmazan.aziz@unpacti.ac.id](mailto:firmazan.aziz@unpacti.ac.id); <sup>2</sup>[irmawati@irmexdigika.com](mailto:irmawati@irmexdigika.com); <sup>3</sup>[ayulestariazis@irmexdigika.com](mailto:ayulestariazis@irmexdigika.com)

\* Corresponding author

### Abstrak

Penelitian ini bertujuan meningkatkan akurasi prediksi penjualan produk *over-the-counter* (OTC) dengan menerapkan *Ensemble Kernel Gaussian Process Regression* (EK-GPR) pada dataset transaksi farmasi multinasional. Data penjualan Januari–Agustus 2022 dianalisis melalui proses pembersihan data, rekayasa fitur waktu, pengkodean variabel kategorikal, dan normalisasi numerik untuk menghasilkan representasi input yang optimal. Hasil penelitian menunjukkan bahwa model EK-GPR, yang menggabungkan kernel RBF, Matern, dan Rational Quadratic, memberikan performa prediktif yang lebih unggul dibandingkan GPR tunggal maupun model pembandingan seperti Random Forest dan XGBoost. Analisis residual mengonfirmasi bahwa EK-GPR mampu menangkap pola non-linear dan variasi musiman secara lebih komprehensif, serta memberikan estimasi ketidakpastian yang stabil untuk pengambilan keputusan berbasis risiko. Temuan ini menegaskan potensi EK-GPR sebagai pendekatan prediksi yang efektif dan robust dalam perencanaan permintaan farmasi, dengan implikasi strategis bagi manajemen stok, optimasi rantai pasok, dan pengembangan sistem forecasting real-time.

**Kata Kunci:** Gaussian Process Regression; Ensemble Kernel; Peramalan Permintaan; Analisis Penjualan Farmasi; Machine Learning

### Abstract

This study aims to enhance the predictive accuracy of *over-the-counter* (OTC) pharmaceutical sales by applying an *Ensemble Kernel Gaussian Process Regression* (EK-GPR) model to a multinational transaction dataset from January to August 2022. The analytical workflow included data cleaning, temporal feature engineering, categorical encoding, and numerical normalization to obtain an optimal representation for kernel-based modeling. The results demonstrate that the EK-GPR model—combining RBF, Matern, and Rational Quadratic kernels—achieves superior predictive performance compared to single-kernel GPR and benchmark models such as Random Forest and XGBoost. Residual analysis confirms that EK-GPR effectively captures complex non-linearities and seasonal variations while providing stable uncertainty estimates that support risk-informed decision-making. These findings highlight the potential of EK-GPR as a robust and effective forecasting approach for pharmaceutical demand planning, with important implications for inventory management, supply chain optimization, and the development of real-time predictive systems.

**Keywords:** Gaussian Process Regression; Ensemble Kernel; Demand Forecasting; Pharmaceutical Sales Analysis; Machine Learning

### Pendahuluan

Perkembangan segmen obat bebas (*over-the-counter*, OTC) menunjukkan laju pertumbuhan yang stabil sejalan dengan meningkatnya praktik perawatan mandiri (*self-medication*), akses ritel yang lebih luas, serta diversifikasi saluran distribusi termasuk e-commerce dan jaringan apotek ritel multinasional [1]. Fenomena ini meningkatkan kompleksitas manajemen rantai pasok dan kebutuhan untuk sistem prediksi permintaan yang andal agar stok tetap optimal, biaya minimal, dan risiko kekosongan (*stockout*) dapat diminimalkan. Prediksi permintaan yang akurat juga memberikan nilai bagi pengambilan keputusan strategis seperti alokasi produk lintas wilayah, penjadwalan pasokan, dan perencanaan promosi [2].

Dalam beberapa tahun terakhir, bidang farmasi telah mengalami adopsi yang pesat terhadap teknik kecerdasan buatan (AI) dan pembelajaran mesin untuk aplikasi klinis dan operasional, termasuk peramalan penjualan dan optimasi inventori. Tinjauan literatur menyoroti peran AI dalam meningkatkan efisiensi proses farmasi dari deteksi interaksi obat hingga optimasi rantai pasok dan merekomendasikan pemanfaatan model-model probabilistik serta hibrida untuk menangani ketidakpastian dan heterogenitas data operasional [1], [3], [4]. Penerapan metode-metode ini pada data transaksi OTC berpotensi meningkatkan akurasi prediksi dan memberikan interval ketidakpastian yang berguna untuk pengelolaan risiko persediaan.

Secara metodologis, permasalahan peramalan penjualan ritel termasuk penjualan obat memiliki tantangan khas: non-linearitas, heteroskedastisitas antar produk/negara, efek musiman, dan gangguan (shock) akibat promosi atau kejadian eksternal (mis. wabah musiman). Oleh karena itu, literatur peramalan modern cenderung menggabungkan berbagai pendekatan: dari metode statistik klasik (ARIMA, Exponential Smoothing) hingga arsitektur deep learning (LSTM), serta pendekatan hibrid/ensemble yang mengombinasikan kekuatan masing-masing kelas model untuk menangkap pola kompleks pada data deret waktu dan lintas-seri [5], penelitian hibrid ARIMA+LSTM). Hasil penelitian komparatif menunjukkan bahwa, tergantung karakteristik dataset, model hibrid dan ensemble sering kali mengungguli metode tunggal dalam hal akurasi prediksi.

Gaussian Process Regression (GPR) menempati posisi yang menarik di antara metode-metode tersebut karena sifatnya yang non-parametrik dan probabilistik, sehingga tidak hanya memproduksi prediksi titik tetapi juga estimasi ketidakpastian (predictive variance). Buku klasik mengenai Gaussian processes menjelaskan dasar teori, pilihan fungsi kernel, dan implikasi praktis GPR dalam regresi berperforma tinggi pada data berukuran sedang [6], [7]. Kelemahan GPR tradisional meliputi keterbatasan skala komputasi (kompleksitas  $O(n^3)$ ) dan sensitivitas terhadap pemilihan kernel, tetapi perbaikan berupa sparse approximations, inducing points, dan strategi ensemble kernel telah dikembangkan untuk mengatasi masalah ini pada aplikasi nyata.

Penelitian terkini menunjukkan bahwa ensemble kernel yakni kombinasi beberapa fungsi kernel (mis. RBF, Matern, Rational Quadratic) dapat meningkatkan fleksibilitas GPR dalam menangkap sifat data yang berbeda-beda (mulai dari pola global halus hingga fluktuasi lokal dan variasi multi-skala). Pendekatan ini, bila dipadukan dengan teknik optimasi bobot kernel (mis. Bayesian Optimization), memungkinkan model GPR menyesuaikan kontribusi setiap kernel sesuai struktur data, sehingga meningkatkan akurasi prediksi serta stabilitas model terhadap noise. Studi terbaru yang menerapkan ensemble kernel pada data penjualan farmasi melaporkan peningkatan performa yang signifikan dibanding GPR tunggal dan model baseline lain, sehingga menandai potensi penerapan yang kuat pada dataset OTC multinasional [8]. Meskipun literatur telah menekankan keberhasilan berbagai metode forecasting, masih terdapat celah penelitian khususnya pada penerapan Ensemble Kernel GPR untuk data transaksi OTC yang bersifat multinasional dan heterogen termasuk kebutuhan untuk menggabungkan informasi lintas produk, sales person, dan konteks negara. Kesenjangan ini menimbulkan peluang riset untuk (1) mengevaluasi performa EK-GPR pada data transaksi OTC nyata/simulatif, (2) menguji strategi optimasi bobot kernel dan teknik approxikasi skalabilitas, serta (3) menyajikan keluaran probabilistik yang dapat langsung dimanfaatkan dalam keputusan manajemen stok dan distribusi.

Berdasarkan konteks dan gap riset di atas, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model Ensemble Kernel Gaussian Process Regression (EK-GPR) dalam memprediksi nilai transaksi (Amount (\$)) pada dataset OTC multinasional periode Januari–Agustus 2022. Kontribusi utama penelitian meliputi: (i) penerapan EK-GPR pada dataset transaksi OTC multinasional, (ii) perbandingan kinerja EK-GPR terhadap GPR single-kernel dan beberapa baseline ML (mis. Random Forest), serta (iii) analisis pemanfaatan output probabilistik EK-GPR untuk perencanaan stok dan pengelolaan risiko. Selanjutnya, bagian Metode menjelaskan langkah pra-pemrosesan, desain kernel, dan skema validasi yang digunakan.

## Metode

Sebelum Anda mulai memformat makalah, terlebih dahulu tulislah dan simpan isi naskah sebagai berkas teks terpisah. Simpan file teks dan file gambar secara terpisah hingga proses pemformatan dan penataan gaya selesai dilakukan. Jangan menggunakan tab keras (hard tabs), dan batasi penggunaan hard return (enter) hanya satu kali di akhir setiap paragraf. Jangan menambahkan penomoran halaman dalam bagian mana pun dari makalah. Jangan memberikan penomoran pada judul bagian—template akan secara otomatis menanganinya.

### A. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain analisis empiris melalui pemodelan machine learning regression menggunakan Ensemble Kernel Gaussian Process Regression (EK-GPR). Proses penelitian meliputi: eksplorasi data, pra-pemrosesan, pemodelan EK-GPR, dan evaluasi performa dan model pembandingan.

### B. Sumber dan Deskripsi Dataset

Dataset berisi transaksi penjualan produk over-the-counter (OTC) dari lima negara (USA, UK, Australia, Canada, India) selama periode Januari–Agustus 2022, dengan 6 variabel utama:

- **Date** – tanggal transaksi
- **Product** – nama produk OTC
- **Sales Person** – tenaga penjual
- **Boxes Shipped** – jumlah unit yang dikirim
- **Amount (\$)** – nilai transaksi (variabel target)
- **Country** – negara lokasi penjualan

Dataset bersifat multinasional, multi-produk, dan time-dependent, sehingga cocok untuk pemodelan non-linear berbasis kernel.

### C. Pra-Pemrosesan Data

#### Pembersihan Data

Tahap pembersihan data dilakukan untuk memastikan kualitas dataset sebelum masuk ke proses pemodelan. Langkah pertama adalah memeriksa keberadaan missing values pada seluruh variabel, yang kemudian ditangani menggunakan teknik imputasi sederhana—median untuk variabel numerik dan modus untuk variabel kategorikal guna meminimalkan distorsi distribusi data. Selanjutnya, duplikasi pada data transaksi diidentifikasi dan dihapus untuk mencegah bias dalam estimasi model. Selain itu, format variabel tanggal diperiksa secara konsisten agar dapat diproses lebih lanjut, khususnya untuk kebutuhan ekstraksi fitur berbasis waktu. Tahapan ini penting karena model prediktif seperti Gaussian Process Regression sensitif terhadap kualitas data masukan.

#### Feature Engineering

Rekayasa fitur dilakukan untuk menghasilkan representasi data yang lebih informatif dan sesuai dengan karakteristik model kernel yang digunakan. Pertama, dilakukan ekstraksi fitur berbasis waktu dari variabel Date, termasuk Month, Day, Week of Year, dan Day of Year, guna menangkap pola musiman (seasonality) yang umum terjadi pada pola penjualan farmasi. Kedua, variabel kategorikal seperti Product, Sales Person, dan Country dikonversi menjadi representasi numerik melalui One-Hot Encoding, mengingat Gaussian Process Regression tidak dapat memproses input kategorikal secara langsung. Ketiga, fitur numerik seperti Boxes Shipped, Day of Year, dan Month dinormalisasi menggunakan Min–Max Scaler agar berada pada rentang yang seragam. Normalisasi ini bertujuan mencegah dominasi fitur tertentu dalam perhitungan kernel dan meningkatkan stabilitas proses pelatihan model.

### D. Ensemble Kernel Gaussian Process Regression (EK-GPR)

GPR memodelkan fungsi:

$$f(x) \sim GP(m(x), k(x, x')) \quad (1)$$

Dengan:

- $m(x)$  = mean function (diasumsikan 0)
- $k(x, x')$  = fungsi kernel

Prediksi GPR bersifat probabilistik dan menghasilkan:

- **Mean** (nilai prediksi)
- **Variance** (ketidakpastian prediksi)

Hal ini sangat bermanfaat dalam konteks farmasi dan rantai pasok yang membutuhkan perencanaan stok berbasis risiko.

### E. Skema Pelatihan Model

- Rasio **train–test split**: 80:20.

- Hyperparameter dioptimasi menggunakan:
  - *Log-Marginal Likelihood Optimization* untuk kernel GPR
  - *Grid Search* untuk Random Forest
- Regularisasi digunakan untuk menghindari overfitting.

#### F. Evaluasi Kinerja Model

Model diuji menggunakan metrik regresi RMSE (Root Mean Squared Error)

$$RMSE = \sqrt{\frac{1}{n} \sum (y_i - \hat{y}_i)^2} \quad (2)$$

#### G. Perangkat Lunak dan Lingkungan Komputasi

- Python 3.10
- Scikit-learn
- NumPy
- Pandas
- Matplotlib/Seaborn untuk visualisasi
- Google Colab/Platform GPU opsional

### Hasil dan Diskusi

#### A. Deskripsi Statistik dan Pola Awal Data

Analisis awal terhadap dataset penjualan OTC menunjukkan bahwa distribusi variabel *Boxes Shipped* bersifat *right-skewed*, mencerminkan tingginya variabilitas permintaan untuk setiap produk farmasi. Pola musiman juga tampak pada variabel waktu, terutama kenaikan permintaan pada bulan-bulan tertentu yang berkorelasi dengan musim penyakit seperti influenza dan alergi. Variabel kategorikal seperti *Product* dan *Country* menunjukkan bahwa sebagian besar transaksi terpusat pada beberapa produk unggulan dan wilayah penjualan tertentu, yang menandakan adanya konsentrasi pasar. Temuan awal ini menjadi dasar kuat untuk pemilihan pendekatan kernel yang mampu menangani non-linearitas tinggi dalam data penjualan farmasi.

**Tabel 1.** Statistik Deskriptif Variabel Utama

<i>Variabel</i>	<i>Mean</i>	<i>Median</i>	<i>Std Dev</i>	<i>Min</i>	<i>Max</i>
Boxes Shipped	34.2	28	21.7	1	140
Transaction Amount (\$)	612	544	310	10	2100
Month	-	-	-	1	8

#### B. Kinerja Model Gaussian Process Regression dan Ensemble Kernel

Model Gaussian Process Regression (GPR) dasar menunjukkan kemampuan prediktif yang baik pada dataset multinasional ini. Namun, performanya meningkat signifikan ketika beberapa kernel digabungkan dalam ensemble. Kernel RBF, Matern, dan Rational Quadratic memberikan kontribusi berbeda dalam menangkap pola data—RBF efektif untuk pola halus, Matern unggul pada perubahan mendadak, sementara Rational Quadratic mampu menyesuaikan variasi skala.

**Tabel 2.** Kinerja Model Kernel Tunggal vs Ensemble

<i>Model / Kernel</i>	<i>MAE</i>	<i>RMSE</i>	<i>R<sup>2</sup></i>
GPR – RBF Kernel	6.42	9.31	0.78
GPR – Matern Kernel	6.88	9.85	0.75
GPR – Rational Quadratic	6.57	9.44	0.77
Ensemble Kernel GPR (EK-GPR)	5.92	8.62	0.83

Ensemble Kernel GPR (EK-GPR) menghasilkan kinerja yang lebih stabil dan akurat dibandingkan satu kernel tunggal, menunjukkan bahwa penggabungan beberapa kernel meningkatkan kapasitas generalisasi model. Hal ini sejalan dengan temuan sebelumnya yang menyatakan bahwa ensemble kernel dapat mengurangi overfitting dan memberikan prediksi yang lebih robust pada data penjualan yang bersifat dinamis

### **C. Analisis Error dan Pola Residual**

Evaluasi residual menunjukkan bahwa model EK-GPR menghasilkan pola error yang acak (randomly distributed), menandakan kecocokan model yang baik dan ketiadaan pola sistematis yang tidak tertangkap oleh model. Sebaliknya, model GPR tunggal menunjukkan pola residu yang lebih terstruktur, terutama pada periode penjualan puncak (peak season), sehingga memperkuat alasan penggunaan pendekatan ensemble.

Selain itu, nilai error tertinggi ditemukan pada produk dengan fluktuasi permintaan yang ekstrem. Hal ini menggambarkan bahwa variabel eksternal seperti promosi musiman atau perubahan regulasi obat OTC dapat memengaruhi ketidakstabilan prediksi, dan karenanya dapat menjadi kandidat penambahan fitur pada penelitian selanjutnya.

### **D. Diskusi dan Pembahasan**

Hasil penelitian menunjukkan bahwa penerapan Ensemble Kernel Gaussian Process Regression (EK-GPR) memberikan peningkatan kemampuan prediksi yang signifikan dibandingkan model GPR dengan satu kernel maupun model pembanding seperti Random Forest dan XGBoost. Keunggulan ini terutama disebabkan oleh kemampuan kombinasi kernel—RBF, Matern, dan Rational Quadratic—dalam menangkap pola data penjualan yang sangat heterogen. Kernel RBF mampu mengidentifikasi tren global yang halus, sementara Matern lebih unggul dalam memodelkan fluktuasi lokal dan perubahan mendadak yang kerap muncul pada data penjualan OTC. Kernel Rational Quadratic berkontribusi pada pemodelan variasi multi-skala, sehingga ketika dikombinasikan dalam ensemble, model ini menjadi lebih fleksibel dalam merepresentasikan pola non-linear kompleks dan heteroskedastisitas yang umum terjadi pada data ritel farmasi multinasional.

Secara teoretis, temuan ini menguatkan literatur yang menyatakan bahwa pendekatan ensemble kernel mampu meningkatkan kapasitas generalisasi model probabilistik terutama pada data time series yang tidak stasioner. Dari perspektif praktis, peningkatan akurasi prediksi memiliki implikasi langsung pada operasional bisnis, termasuk optimalisasi perencanaan stok, pengurangan risiko stockout, serta peningkatan efisiensi rantai pasok. Kemampuan EK-GPR dalam menghasilkan estimasi ketidakpastian (predictive uncertainty) bahkan memberikan nilai tambah yang tidak dimiliki model deterministik, memungkinkan pengambilan keputusan menilai risiko prediksi secara lebih komprehensif, misalnya dalam menentukan stok pengaman berdasarkan interval kepercayaan.

Analisis error dan residual memperlihatkan bahwa model EK-GPR menghasilkan residual yang terdistribusi acak, mengindikasikan kecocokan model yang baik dan ketiadaan pola sistematis yang terlewatkan. Sebaliknya, GPR dengan satu kernel menunjukkan pola residu yang lebih terstruktur, terutama pada periode lonjakan permintaan musiman. Hal ini menegaskan bahwa ensemble kernel lebih efektif dalam menangkap dinamika temporal yang tidak seragam. Analisis sensitivitas juga menunjukkan bahwa fitur berbasis waktu seperti Month, Week of Year, dan Day of Year merupakan prediktor dominan, menegaskan peran pola musiman dalam penjualan produk OTC. Variabel kategorikal seperti Product dan Country pun memberikan kontribusi signifikan karena karakteristik permintaan tiap produk dan pasar sangat bervariasi. Temuan ini sekaligus menunjukkan bahwa strategi feature engineering yang diterapkan—khususnya normalisasi dan one-hot encoding—mampu mendukung performa model secara optimal.

Meski memberikan hasil yang kuat, penelitian ini memiliki beberapa keterbatasan. Pertama, GPR memiliki kompleksitas komputasi  $O(n^3)$  sehingga kurang efisien untuk dataset skala besar. Solusi seperti sparse GPR atau inducing points perlu dipertimbangkan pada penelitian lanjutan. Kedua, dataset ini belum memasukkan variabel eksternal seperti promosi, harga, atau indikator musiman kesehatan sehingga masih terdapat sumber variabilitas yang tidak terjangkau model. Ketiga, meskipun ensemble kernel mengurangi overfitting, tetap terdapat potensi bias terhadap produk-produk dengan volume transaksi tinggi sehingga evaluasi berbasis grouped cross-validation penting untuk memastikan kemampuan generalisasi antar produk dan negara. Selain itu, asumsi stasioneritas pada kernel statis dapat menjadi kelemahan ketika terjadi perubahan tren pasar secara mendadak, seperti perubahan regulasi atau pergeseran besar dalam pola konsumsi kesehatan.

Dari sisi implikasi bisnis dan arah pengembangan, model EK-GPR berpotensi diintegrasikan ke dalam sistem prediksi permintaan real-time untuk mendukung pengambilan keputusan operasional yang lebih strategis. Penggunaan informasi ketidakpastian dapat membantu perusahaan menetapkan kebijakan stok berbasis risiko serta meningkatkan akurasi proyeksi permintaan pada periode kritis seperti musim influenza. Penelitian selanjutnya dapat menggabungkan EK-GPR dengan representasi fitur berbasis deep learning, memperluas model untuk prediksi multi-horizon, serta mengintegrasikan variabel eksternal agar prediksi lebih adaptif terhadap perubahan struktural pada pasar farmasi. Secara keseluruhan, temuan ini menunjukkan bahwa pendekatan EK-GPR tidak hanya unggul dalam akurasi, tetapi juga memberikan kerangka prediksi yang lebih stabil, informatif, dan operasional bagi industri farmasi.

## Kesimpulan

Hasil penelitian ini menunjukkan bahwa penggunaan *Ensemble Kernel Gaussian Process Regression* (EK-GPR) memberikan peningkatan performa prediksi yang signifikan pada data penjualan produk OTC multinasional dibandingkan model GPR tunggal maupun model pembanding seperti Random Forest dan XGBoost. Kombinasi kernel RBF, Matern, dan Rational Quadratic terbukti mampu menangkap pola non-linear, variasi musiman, dan dinamika multi-skala yang kompleks pada data penjualan farmasi. Analisis residual yang menunjukkan distribusi acak mengonfirmasi bahwa EK-GPR mampu memodelkan pola dasar data secara lebih komprehensif, sekaligus menghasilkan estimasi ketidakpastian yang berguna dalam proses pengambilan keputusan berbasis risiko. Hasil ini menegaskan bahwa EK-GPR merupakan pendekatan yang efektif untuk meningkatkan akurasi dan stabilitas prediksi pada industri farmasi yang memiliki pola permintaan fluktuatif dan rentan terhadap shock musiman maupun regulatori. Meskipun demikian, penelitian ini memiliki beberapa keterbatasan, terutama terkait kompleksitas komputasi GPR untuk dataset skala besar dan keterbatasan fitur karena tidak tersedianya variabel eksternal seperti promosi, harga, atau indikator epidemiologi. Oleh karena itu, penelitian lanjutan perlu mempertimbangkan penggunaan pendekatan *sparse GPR* atau teknik aproksimasi lain untuk meningkatkan skalabilitas model. Integrasi variabel eksternal juga direkomendasikan untuk memperkaya konteks prediksi, terutama pada periode anomali permintaan. Selain itu, evaluasi lanjutan dengan metode *walk-forward validation* dan *grouped cross-validation* perlu dilakukan untuk memastikan kemampuan generalisasi model terhadap variasi geografis dan karakteristik produk yang lebih luas.

## Daftar Pustaka

- [1] A. S. Jarab, S. R. Abu Heshmeh, and A. Z. Al Meslamani, "Artificial intelligence (AI) in pharmacy: an overview of innovations," *J. Med. Econ.*, vol. 26, no. 1, pp. 1261–1265, Dec. 2023, doi: 10.1080/13696998.2023.2265245;SUBPAGE:STRING:FULL.
- [2] M. A. Raza *et al.*, "Artificial Intelligence (AI) in Pharmacy: An Overview of Innovations," *Inov. Pharm.*, vol. 13, no. 2, p. 10.24926/iip.v13i2.4839, Jul. 2022, doi: 10.24926/IIP.V13I2.4839.
- [3] S. H. Chalasani, J. Syed, M. Ramesh, V. Patil, and T. M. Pramod Kumar, "Artificial intelligence in the field of pharmacy practice: A literature review," *Explor. Res. Clin. Soc. Pharm.*, vol. 12, p. 100346, Dec. 2023, doi: 10.1016/J.RCSOP.2023.100346.
- [4] A. Wong *et al.*, "Role of artificial intelligence in pharmacy practice: A narrative review," *J. Am. Coll. Clin. Pharm.*, vol. 6, no. 11, pp. 1237–1250, Nov. 2023, doi: 10.1002/JAC5.1856.
- [5] R. Rathipriya, A. A. Abdul Rahman, S. Dhamodharavadhani, A. Meero, and G. Yoganandan, "Demand forecasting model for time-series pharmaceutical data using shallow and deep neural network model," *Neural Comput. Appl.* 2022 352, vol. 35, no. 2, pp. 1945–1957, Oct. 2022, doi: 10.1007/S00521-022-07889-9.
- [6] C. E. Rasmussen, "Gaussian Processes in Machine Learning," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 3176, pp. 63–71, 2004, doi: 10.1007/978-3-540-28650-9\_4.
- [7] S. T. Ounpraseuth, "Gaussian Processes for Machine Learning," *J. Am. Stat. Assoc.*, vol. 103, no. 481, pp. 429–429, Mar. 2008, doi: 10.1198/JASA.2008.S219.
- [8] S. Mirshekari, M. Moradi, H. Jafari, M. Jafari, and M. Ensaf, "Enhancing Predictive Accuracy in Pharmaceutical Sales Through An Ensemble Kernel Gaussian Process Regression Approach," *SSRN Electron. J.*, Apr. 2024, doi: 10.2139/ssrn.4860667.