

Pemodelan Peramalan Jumlah Pernikahan Menggunakan ARIMA Berbasis Data Historis pada KUA Galur

Hasan Ibrahim Sansyah¹, Eko Riswanto^{*2}

^{1,2} Program Studi Informatika, STMIK El Rahma Yogyakarta
e-mail: ¹ibrahimsansyah01@gmail.com, ²riswantoeko@stmikelrahma.ac.id
^{*}Correspondence author

Abstrak

Kantor Urusan Agama (KUA) Galur rutin mencatat data pernikahan, namun belum memanfaatkannya secara optimal sebagai dasar perencanaan operasional. Ketidadaan analisis prediktif ini menyulitkan alokasi tenaga penghulu dan logistik administrasi, terutama saat terjadi fluktuasi permohonan. Penelitian ini bertujuan membangun model peramalan jumlah pernikahan menggunakan metode Autoregressive Integrated Moving Average (ARIMA) guna mendukung pengambilan keputusan berbasis data. Data historis berjumlah 120 bulan (Januari 2016–Desember 2025) dipartisi menjadi 80% data latih dan 20% data uji. Uji stasioneritas Augmented Dickey-Fuller (ADF) menunjukkan bahwa data telah stasioner pada tingkat level, sehingga first-order differencing tidak wajib dilakukan namun tetap diikutsertakan sebagai salah satu kandidat model yang dibandingkan. Berdasarkan evaluasi diagnostik residual dan nilai AIC/BIC terendah, ARIMA(0,1,1) dipilih sebagai model terbaik. Pengujian pada data uji menghasilkan nilai Mean Absolute Error (MAE) 6,84 dan Root Mean Squared Error (RMSE) 8,37. Model final memproyeksikan angka konstan sebesar 13 pernikahan per bulan untuk sepanjang tahun 2026. Walaupun akurasi titiknya tidak secara konsisten unggul dari baseline sederhana, nilai tambah ARIMA terletak pada kerangka inferensi statistiknya. Sebagai kesimpulan, hasil proyeksi ini sangat penting untuk digunakan sebagai informasi pendukung bagi KUA Galur dalam merencanakan penjadwalan tenaga penghulu dan pengadaan logistik secara proaktif dan terarah.

Kata kunci: ARIMA, peramalan, time series, KUA Galur, data historis.

1. PENDAHULUAN

Kantor Urusan Agama (KUA) merupakan institusi pemerintah tingkat kecamatan yang berperan vital dalam pencatatan dan administrasi pernikahan, sebagaimana diamanatkan Peraturan Menteri Agama (PMA) RI Nomor 34 Tahun 2016. KUA Galur secara rutin mencatat data historis jumlah pernikahan, namun berdasarkan observasi dan wawancara dengan pegawai administrasi, data tersebut baru dimanfaatkan sebagai laporan administratif dan belum digunakan sebagai dasar analisis prediktif untuk perencanaan pelayanan.

Jumlah pernikahan menunjukkan fluktuasi bulanan yang dipengaruhi faktor sosiokultural, terutama kecenderungan peningkatan permohonan pada bulan Zulhijjah (“Bulan Besar”). Analisis data KUA Galur 2016–2025 mengonfirmasi hal ini: pernikahan pada Zulhijjah mencapai 310 peristiwa, 119,5% lebih tinggi dari rata-rata bulan Hijriah lainnya (141 peristiwa), didukung uji Chi-Square ($\chi^2 = 473,56$; $p < 0,001$). Sebaliknya, dugaan peningkatan menjelang Ramadhan tidak terkonfirmasi (Syakban: 100 peristiwa, -29,2% dari rata-rata) sehingga tidak dijadikan argumen penelitian. Ketidadaan analisis sistematis atas fluktuasi ini menyulitkan KUA Galur mengantisipasi lonjakan permohonan, sehingga berdampak pada penjadwalan tenaga penghulu dan ketersediaan logistik dokumen.

Untuk mengatasi hal tersebut, diperlukan pendekatan data-driven melalui pemodelan Time Series, khususnya Autoregressive Integrated Moving Average (ARIMA), yang memanfaatkan nilai masa lalu dan sekarang dari data itu sendiri (komponen Autoregressive, Differencing, dan Moving Average) tanpa variabel eksternal untuk menghasilkan prediksi jangka pendek yang memadai[1]. Pemeriksaan pola musiman melalui dekomposisi dan analisis ACF pada lag 12 menunjukkan indikasi musiman yang lemah pada kalender Masehi (ACF lag 12 = 0,2042, tepat pada ambang signifikansi 5%), sementara pola yang jauh lebih kuat justru muncul pada kalender Hijriah (Zulhijjah) yang secara struktural tidak dapat ditangkap SARIMA

konvensional berperiode tetap 12 bulan Masehi. Oleh karena itu, penelitian ini menetapkan ARIMA nonmusiman sebagai model utama, dengan pola Zulhijjah dibahas terpisah sebagai faktor kontekstual pada bagian Pembahasan. Hingga saat ini belum ada penerapan pemodelan dan prediksi kuantitatif jumlah pernikahan di KUA Galur.


Keandalan ARIMA telah dibuktikan luas lintas disiplin ilmu, antara lain dalam peramalan pengajuan dokumen KTP-el[2], permintaan penumpang bus[3], penyebaran COVID-19[4], kasus diare[5], serta permintaan energi[6]. Pada level metodologis, ARIMA juga terus dikembangkan menjadi varian yang lebih kompleks, seperti clustered ARIMA untuk deret waktu respirasi tanah[7], self-paced ARIMA untuk meningkatkan ketahanan (robustness) terhadap data bernoise tinggi[8], serta model hibrida ARIMA–Prophet untuk optimasi akurasi[9]. Varian-varian tersebut umumnya dikembangkan untuk menangani karakteristik data yang lebih kompleks (multi-klastr, noise tinggi, atau pola nonlinear) dan menuntut volume data serta sumber daya komputasi yang lebih besar. Mengingat data KUA Galur relatif terbatas (120 observasi bulanan) dan tujuan penelitian ini menitikberatkan pada kerangka inferensi statistik yang sederhana serta mudah diinterpretasikan oleh pengguna nonteknis di instansi pemerintah, penelitian ini memilih ARIMA standar sebagai model dasar (baseline) yang representatif, sekaligus membuka peluang eksplorasi varian-varian tersebut pada penelitian lanjutan. Sintesis tinjauan ini menegaskan bahwa penentuan parameter, jenis model, dan horizon prediksi harus disesuaikan dengan karakteristik objek penelitian; deret waktu jumlah pernikahan di KUA Galur memiliki fluktuasi ekstrem berbasis kultural yang berbeda dari pola tren linear pada domain lain.

Berbagai studi tersebut menegaskan bahwa ARIMA adalah model prediktif yang valid dan adaptif, namun akurasinya tetap bergantung pada sifat data, pemilihan parameter, dan hasil uji diagnostik residual. Indikator kesalahan standar seperti MAE, MSE, dan RMSE diperlukan untuk mengevaluasi kapabilitas model dan seberapa dekat hasil peramalan dengan kondisi aktual, mengingat pemodelan maupun evaluasi akurasi prediksi belum pernah dilakukan di KUA Galur.

Berdasarkan paparan tersebut, terlihat jelas adanya celah berupa ketiadaan model prediktif yang dapat mendukung perencanaan sumber daya di KUA Galur. Oleh karena itu, penelitian ini dilakukan untuk memodelkan deret waktu pernikahan menggunakan algoritma ARIMA guna mendorong perumusan kebijakan alokasi sumber daya serta peningkatan efektivitas pelayanan administrasi publik yang responsif, terukur, dan berbasis data.

2. METODE PENELITIAN

Pendekatan ini mengacu pada penelitian kuantitatif yang dilakukan secara sistematis, terencana, dan terstruktur sejak tahap perancangan hingga analisis data untuk menghasilkan temuan yang valid[10]. Metodologi yang diterapkan menggunakan pendekatan statistika deret waktu untuk memodelkan pola pernikahan di KUA Galur. Alur tahapan penelitian disajikan secara berurutan pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian

Berdasarkan Gambar 1, penelitian diawali dengan identifikasi permasalahan, pengumpulan data historis, *preprocessing* data, dilanjutkan dengan identifikasi, estimasi, serta evaluasi pada model ARIMA. Proses diakhiri dengan prediksi dan penyusunan rekomendasi manajerial.

Identifikasi Permasalahan

Tahap awal penelitian dilakukan melalui observasi lapangan di Kantor Urusan Agama (KUA) Galur. Permasalahan utama yang diangkat adalah data historis jumlah pernikahan yang selama ini hanya berstatus sebagai arsip pasif dan belum dioptimalkan menjadi dasar peramalan, sehingga instansi kesulitan mengantisipasi fluktuasi kebutuhan penjadwalan penghulu maupun ketersediaan buku nikah. Oleh karena itu, tahap ini menetapkan urgensi penelitian, yaitu membangun kerangka pengambilan keputusan berbasis data (*data-driven decision making*) melalui pemodelan pola deret waktu[11].

Pengumpulan Data

Penelitian ini menggunakan data sekunder historis. Kuantitatif dicetuskan sebagai sebuah pendekatan yang memiliki data bersifat angka, persentase, hingga frekuensi dalam rangka pengujian sebuah hipotesis penelitian[12]. Data bersumber dari ekstraksi langsung sistem arsip buku pendaftaran dan pelaksanaan administrasi nikah di KUA Galur. Data mentah bersumber dari catatan harian akad nikah yang kemudian diagregasi menjadi deret waktu bulanan, mencakup periode Januari 2016 hingga Desember 2025, menghasilkan 120 observasi bulanan setelah tahap *preprocessing* (lihat bagian *Preprocessing Data*). Setiap observasi dalam penelitian ini didefinisikan secara spesifik sebagai jumlah akad nikah yang secara sah telah dilaksanakan dan dicatat oleh KUA pada bulan yang bersangkutan.

Preprocessing Data

Sebelum tahap pemodelan, data mentah melalui proses prapemrosesan (*preprocessing*) untuk menghasilkan deret waktu yang lengkap dan sesuai dengan kebutuhan pemodelan ARIMA. Tahap awal dilakukan melalui agregasi waktu (*time aggregation*), yaitu data historis yang semula berupa rekaman harian berdasarkan tanggal pelaksanaan akad nikah diekstraksi dan diagregasi menjadi deret waktu dengan frekuensi bulanan. Dengan demikian, setiap observasi merepresentasikan jumlah peristiwa pernikahan yang tercatat dalam satu bulan kalender.

Tahap berikutnya adalah pembersihan dan imputasi data (*data cleaning and imputation*) untuk mengevaluasi kualitas rekaman historis serta menangani data yang hilang (*missing values*). Berdasarkan verifikasi terhadap rentang waktu Januari 2016 hingga Desember 2025 yang mencakup 120 bulan, ditemukan 13 bulan tanpa catatan pernikahan, yaitu Oktober–Desember 2017 sebanyak 3 bulan, Januari–September 2018 sebanyak 9 bulan, dan Mei 2020 sebanyak 1 bulan. Dengan demikian, sebelum proses imputasi terdapat 107 bulan yang memiliki pencatatan aktual dari keseluruhan 120 bulan pengamatan. Karena pemodelan ARIMA membutuhkan deret waktu dengan interval yang teratur dan tanpa periode yang hilang, kekosongan data tersebut ditangani menggunakan interpolasi linear (*linear interpolation*). Metode ini mengestimasi nilai yang hilang berdasarkan perubahan linear antara titik data sebelum dan sesudah periode yang kosong. Nilai hasil interpolasi selanjutnya dibulatkan menjadi bilangan bulat karena data merepresentasikan jumlah peristiwa pernikahan. Pada tahap pembersihan juga dilakukan pemeriksaan terhadap kemungkinan pencatatan ganda dan nilai pencilan (*outlier*) ekstrem pada dataset.

Data yang telah melalui proses pembersihan dan imputasi selanjutnya diuji stasioneritasnya menggunakan *Augmented Dickey-Fuller* (ADF) pada taraf signifikansi $\alpha = 0,05$. Pengujian stasioneritas diperlukan karena pemodelan ARIMA mengasumsikan deret yang digunakan dalam komponen autoregresif dan *moving average* telah stasioner [2]. Hipotesis nol (H_0) pada uji ADF menyatakan bahwa deret waktu memiliki akar unit (*unit root*) sehingga dikategorikan tidak stasioner, sedangkan hipotesis alternatif (H_1) menyatakan bahwa deret tidak memiliki akar unit. Data dinyatakan stasioner apabila nilai *p-value* $< 0,05$ sehingga H_0 ditolak.

Pengujian awal dilakukan pada data tingkat *level* untuk menentukan apakah deret telah memenuhi kondisi stasioneritas atau masih memerlukan proses pembedaan (*differencing*).

Apabila hasil uji ADF pada data tingkat *level* menunjukkan *p-value* $\geq 0,05$, maka H_0 tidak dapat ditolak sehingga deret diperlakukan sebagai belum stasioner. Untuk mengurangi perubahan level atau tren dan mencapai stasioneritas, dilakukan proses *first-order differencing*. Pada proses ini, nilai observasi pada periode tertentu dikurangi dengan nilai observasi pada periode sebelumnya sebagaimana dirumuskan pada Persamaan (1).

$$Y'_t = Y_t - Y_{t-1} \quad (1)$$

dengan Y'_t merupakan nilai hasil *differencing* pada periode ke- t , Y_t merupakan nilai observasi pada periode ke- t , dan Y_{t-1} merupakan nilai observasi pada periode sebelumnya. Proses *first-order differencing* menghasilkan parameter integrasi $d = 1$ pada model ARIMA apabila proses tersebut telah menghasilkan deret yang stasioner [13]. Setelah *differencing* diterapkan, uji ADF dilakukan kembali untuk memastikan bahwa deret telah mencapai kondisi stasioner, yang ditunjukkan oleh *p-value* $< 0,05$. Deret yang telah stasioner selanjutnya digunakan dalam proses identifikasi dan pembentukan model ARIMA.

Identifikasi Model ARIMA

Fase ini merupakan inti dari proses identifikasi model, yaitu menentukan struktur ARIMA berdasarkan tiga parameter utama: *Autoregressive* (p), *Integrated* (d), dan *Moving Average* (q) [14]. Parameter p menunjukkan jumlah *lag* pada komponen autoregresif, parameter d menunjukkan orde *differencing* yang diperlukan untuk mencapai stasioneritas, sedangkan parameter q menunjukkan jumlah *lag* pada komponen *moving average*. Karena data observasi memiliki frekuensi bulanan, indikasi pola musiman (*seasonality*) juga diperiksa melalui visualisasi deret waktu, dekomposisi musiman (*seasonal decomposition*), serta pola autokorelasi pada *lag* ke-12 dalam plot *Autocorrelation Function* (ACF).

Penentuan orde integrasi (d) disesuaikan dengan jumlah proses *differencing* yang diperlukan hingga data mencapai kondisi stasioner berdasarkan hasil uji ADF. Apabila data telah mencapai stasioneritas setelah *first-order differencing*, maka parameter integrasi ditetapkan sebesar $d = 1$. Selanjutnya, plot ACF dan *Partial Autocorrelation Function* (PACF) pada data yang telah stasioner dianalisis sebagai pedoman awal dalam menentukan kandidat parameter p dan q . Pola *cut-off* maupun peluruhan (*tailing off*) yang terlihat pada kedua korelogram digunakan untuk membatasi ruang pencarian kandidat model sehingga pemilihan kombinasi parameter tidak dilakukan secara arbitrer.

Berdasarkan hasil identifikasi tersebut, ditetapkan rentang kandidat parameter p dan q yang selanjutnya dikombinasikan dengan nilai d yang telah diperoleh dari proses pengujian stasioneritas. Dari kombinasi parameter tersebut dibentuk sejumlah kandidat model ARIMA nonmusiman, antara lain ARIMA(1,1,0), ARIMA(0,1,1), dan ARIMA(1,1,1), serta kombinasi lain yang masih berada dalam rentang parameter yang telah ditentukan. Setiap kandidat selanjutnya dibandingkan untuk menentukan model yang paling sesuai berdasarkan kriteria evaluasi yang digunakan dalam penelitian.

Selain model ARIMA nonmusiman, hasil pemeriksaan pola musiman digunakan untuk menentukan kebutuhan pengembangan model musiman. Apabila ditemukan indikasi pola berulang yang konsisten pada periode 12 bulan, kandidat *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dengan periode musiman $s = 12$ turut dibentuk dan dievaluasi sebagai model pembanding. Model SARIMA memperluas struktur ARIMA dengan menambahkan komponen autoregresif, *differencing*, dan *moving average* pada pola musiman yang direpresentasikan melalui parameter (P, D, Q). Dengan periode $s = 12$, model diarahkan untuk menangkap pola yang berulang setiap 12 bulan pada data pernikahan bulanan. Kinerja kandidat SARIMA kemudian dibandingkan dengan model ARIMA nonmusiman untuk mengevaluasi apakah penambahan komponen musiman memberikan peningkatan kemampuan

model dalam merepresentasikan pola deret waktu. Dengan demikian, pemilihan model tidak hanya mempertimbangkan pola nonmusiman pada data, tetapi juga kemungkinan adanya struktur musiman tahunan pada deret waktu pernikahan.

Estimasi dan Pembentukan Model

Setelah kandidat model tentatif terbentuk, estimasi koefisien parameter dilakukan menggunakan metode *Maximum Likelihood Estimation* (MLE) [15]. Pemilihan model peramalan dilakukan dengan mempertimbangkan beberapa kriteria, yaitu nilai kriteria informasi, signifikansi parameter, dan hasil diagnostik residual. Kriteria informasi dievaluasi menggunakan *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC), dengan nilai yang lebih rendah menunjukkan keseimbangan yang lebih baik antara kecocokan model dan kompleksitas parameter dibandingkan kandidat lainnya. Selain itu, signifikansi koefisien parameter hasil estimasi diperiksa berdasarkan nilai *p-value*, dengan parameter dinyatakan signifikan secara statistik apabila *p-value* < 0,05.

Evaluasi selanjutnya dilakukan melalui diagnostik residual untuk memastikan bahwa pola utama dalam deret waktu telah terakomodasi oleh model. Pemeriksaan autokorelasi residual dilakukan menggunakan uji Ljung–Box [16]. Hipotesis nol (H_0) pada uji ini menyatakan bahwa tidak terdapat autokorelasi yang signifikan pada residual hingga *lag* yang diuji. Oleh karena itu, nilai *p-value* > 0,05 menunjukkan bahwa H_0 tidak ditolak sehingga tidak terdapat bukti autokorelasi residual yang signifikan pada *lag* tersebut. Residual yang tidak menunjukkan pola autokorelasi diharapkan mendekati karakteristik *white noise*, sehingga mengindikasikan bahwa struktur temporal utama pada data telah cukup direpresentasikan oleh model [17]. Hasil evaluasi dari kriteria informasi, signifikansi parameter, dan diagnostik residual selanjutnya digunakan secara bersama-sama dalam menentukan kandidat model yang layak untuk tahap evaluasi peramalan.

Untuk mendukung replikasi penelitian, seluruh tahapan pengolahan data dan pemodelan diimplementasikan menggunakan bahasa pemrograman Python pada lingkungan Google Colaboratory. Pustaka Pandas dan NumPy digunakan untuk manipulasi dan pengolahan data, sedangkan Statsmodels digunakan untuk estimasi model serta berbagai pengujian statistik melalui modul *tsa.arima.model.ARIMA*, *tsa.stattools.adfuller*, *tsa.seasonal.seasonal_decompose*, dan *stats.diagnostic.acorr_ljungbox*. Scikit-learn melalui modul *sklearn.metrics* digunakan untuk menghitung metrik kesalahan peramalan, sedangkan Matplotlib dan Seaborn digunakan untuk visualisasi data dan hasil analisis. Estimasi parameter ARIMA dilakukan menggunakan MLE dengan konfigurasi bawaan (*default*) dari Statsmodels tanpa penyesuaian khusus.

Versi perangkat lunak dan pustaka yang digunakan pada eksekusi akhir didokumentasikan pada *notebook* analisis, yaitu Python 3.12.13, Pandas 2.2.2, NumPy 2.0.2, Statsmodels 0.14.6, Scikit-learn 1.6.1, Matplotlib 3.10.0, dan Seaborn 0.13.2. Pencantuman informasi versi tersebut bertujuan meningkatkan transparansi dan reproduktibilitas eksperimen, sehingga konfigurasi lingkungan komputasi yang digunakan dalam penelitian dapat direkonstruksi oleh peneliti lain.

Evaluasi Model

Kinerja setiap kandidat model dievaluasi secara kuantitatif untuk mengetahui tingkat kesalahan antara nilai hasil peramalan dan nilai aktual pada data uji. Evaluasi dilakukan menggunakan tiga metrik kesalahan, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE). Ketiga metrik tersebut digunakan secara bersama-sama karena memberikan karakteristik pengukuran kesalahan yang berbeda dalam mengevaluasi hasil peramalan.

Mean Absolute Error (MAE) mengukur rata-rata nilai absolut selisih antara nilai aktual dan nilai hasil peramalan tanpa mempertimbangkan arah kesalahan. Metrik ini memberikan gambaran mengenai besarnya kesalahan prediksi secara rata-rata dan memiliki satuan yang sama dengan data asli. Nilai MAE yang semakin kecil menunjukkan bahwa hasil peramalan semakin mendekati nilai aktual. MAE dirumuskan sebagaimana ditunjukkan pada Persamaan (2).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

Mean Squared Error (MSE) mengukur rata-rata kuadrat selisih antara nilai aktual dan nilai hasil peramalan. Proses pengkuadratan menyebabkan kesalahan dengan deviasi yang besar memperoleh penalti lebih tinggi dibandingkan kesalahan dengan deviasi kecil. Oleh karena itu, MSE dapat digunakan untuk mengidentifikasi model yang menghasilkan kesalahan prediksi besar secara lebih sensitif. MSE dirumuskan sebagaimana ditunjukkan pada Persamaan (3).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

Sementara itu, *Root Mean Squared Error* (RMSE) merupakan akar kuadrat dari MSE sehingga nilai kesalahan dikembalikan ke satuan yang sama dengan data asli. Karakteristik tersebut membuat RMSE lebih mudah diinterpretasikan dibandingkan MSE, sekaligus tetap memberikan penalti yang lebih besar terhadap kesalahan prediksi dengan deviasi tinggi. Semakin kecil nilai RMSE, semakin kecil pula deviasi hasil peramalan terhadap nilai aktual. RMSE dirumuskan sebagaimana ditunjukkan pada Persamaan (4).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Pada Persamaan (2)–(4), n merupakan jumlah observasi pada data uji, y_i merupakan nilai aktual pada observasi ke- i , sedangkan $\hat{y}_i$ merupakan nilai hasil peramalan pada observasi ke- i . Nilai MAE, MSE, dan RMSE yang lebih rendah menunjukkan tingkat kesalahan peramalan yang lebih kecil. Penentuan model terpilih dilakukan dengan mempertimbangkan kinerja pada data uji berdasarkan ketiga metrik tersebut bersama dengan hasil diagnostik residual, signifikansi parameter, dan kriteria informasi model. Dengan demikian, pemilihan model tidak hanya didasarkan pada tingkat kesalahan peramalan yang rendah, tetapi juga mempertimbangkan kelayakan statistik model.

MAE, MSE, dan RMSE dilaporkan pada penelitian ini, meskipun MSE dan RMSE pada dasarnya membawa informasi yang beririsan karena RMSE adalah akar kuadrat dari MSE. Agar akurasi model dapat dinilai secara relatif dan lebih mudah diinterpretasikan lintas konteks, kesalahan prediksi juga dilaporkan dalam bentuk *Mean Absolute Percentage Error* (MAPE) dan *Mean Absolute Scaled Error* (MASE). Penggunaan MAPE perlu dilakukan secara hati-hati karena metrik ini tidak terdefinisi (pembagian dengan nol) apabila terdapat bulan dengan jumlah pernikahan aktual sebesar nol; pada dataset penelitian ini, setelah tahap imputasi, nilai minimum observasi bulanan adalah 1 (tidak terdapat bulan bernilai nol), sehingga MAPE dapat dihitung secara valid pada seluruh data uji. Sebagai pelengkap yang lebih andal terhadap nilai kecil dan bebas dari masalah pembagian dengan nol, MASE turut dilaporkan dengan membandingkan galat absolut model terhadap galat absolut *naive forecast* satu langkah pada data latih sebagai penyebut skala.

Nilai MAE dan RMSE ARIMA(0,1,1) semata belum cukup untuk menyatakan model tersebut optimal tanpa pembandingan. Oleh karena itu, performa ARIMA(0,1,1) juga dibandingkan terhadap tiga model *baseline* sederhana pada data uji yang sama, yaitu (1) *naive forecast* (nilai prediksi sama dengan observasi terakhir pada data latih), (2) *seasonal naive* (nilai prediksi sama

Pemodelan Peramalan Jumlah Pernikahan Menggunakan ARIMA Berbasis Data Historis pada KUA Galur (Hasan Ibrahim Sansyah, Eko Riswanto / Eko Riswanto)

dengan observasi pada periode yang sama 12 bulan sebelumnya), dan (3) *moving average* (rata-rata bergerak 12 bulan terakhir dari data latih). Model ARIMA(0,1,1) dinyatakan memberikan nilai tambah dibandingkan pendekatan naif hanya apabila metrik kesalahannya secara konsisten lebih rendah daripada seluruh baseline tersebut.

Prediksi dan Analisis Hasil

Model ARIMA terpilih diimplementasikan untuk melakukan prediksi jumlah pernikahan (*out-of-sample forecasting*) untuk horizon 12 bulan ke depan (Januari–Desember 2026). Prediksi ini menyertakan interval kepercayaan 95% yang memberikan batas atas dan batas bawah estimasi. Karena jumlah pernikahan merupakan data cacah (count data) yang tidak mungkin bernilai negatif atau pecahan, seluruh nilai hasil prediksi dibulatkan ke bilangan bulat terdekat dan nilai negatif yang mungkin muncul pada batas bawah interval kepercayaan dipotong (truncated) menjadi nol sebelum diinterpretasikan. Hasil peramalan kemudian dianalisis untuk melihat kemampuan model dalam merespons fluktuasi tren.

Penyusunan Kesimpulan


Tahap akhir ini menyimpulkan hasil pemodelan untuk menjawab permasalahan penelitian, serta merumuskan implikasi praktisnya sebagai salah satu informasi pendukung keputusan (bukan dasar tunggal yang bersifat pasti) bagi KUA Galur dalam perencanaan penjadwalan tenaga penghulu dan pengadaan logistik buku administrasi.

3. HASIL DAN PEMBAHASAN

Hasil Pengumpulan Data

Penelitian menggunakan data jumlah pernikahan yang diperoleh dari arsip administrasi KUA Galur periode Januari 2016–Desember 2025. Data awal terdiri atas 1.695 catatan harian akad nikah dari 10 berkas tahunan. Tahap pembersihan meliputi pemeriksaan format tanggal, identifikasi duplikasi, dan pemeriksaan kelengkapan periode pencatatan. Satu data duplikat ditemukan dan dihapus, kemudian data harian diagregasi menjadi deret waktu bulanan sesuai dengan kebutuhan pemodelan.

Visualisasi jumlah pernikahan selama periode penelitian disajikan pada Gambar 2. Data menunjukkan fluktuasi antarbulan dengan rata-rata 16,53 pernikahan dan simpangan baku 8,98. Pemeriksaan pola musiman melalui dekomposisi periode 12 bulan dan ACF menunjukkan komponen musiman tertinggi pada Juli (+6,81) dan terendah pada April (−3,77). Nilai ACF pada *lag* 12 sebesar 0,2042 berada di sekitar batas signifikansi 5%, sedangkan pada *lag* 24 hanya sebesar 0,0341. Hasil tersebut menunjukkan bahwa pola musiman berdasarkan kalender Masehi relatif lemah dan tidak konsisten.



Gambar 2. Historis Fluktuasi Jumlah Pernikahan Bulanan di KUA Galur (2016-2025)

Hasil Preprocessing Data dan Eksplorasi Data Deret Waktu

Hasil agregasi data bulanan ditunjukkan pada Tabel 1. Dari rentang Januari 2016–Desember 2025 seharusnya diperoleh 120 observasi, tetapi hanya 107 bulan yang memiliki data aktual. Sebanyak 13 bulan tidak memiliki catatan, yaitu Oktober–Desember 2017, Januari–September 2018, dan Mei 2020. Data yang hilang diimputasi menggunakan interpolasi linear dan dibulatkan ke bilangan bulat terdekat sehingga diperoleh deret waktu kontinu sebanyak 120 observasi. Dataset akhir memiliki nilai minimum 1, maksimum 48, rata-rata 16,53, median 16, dan simpangan baku 8,98.

Tabel 1. Agregasi Bulanan Jumlah Pernikahan (Sebagian Data)

Bulan	Jumlah Pernikahan
Januari 2016	21
Februari 2016	17
Maret 2016	9
April 2016	23
Mei 2016	18

Hasil Uji Stasioneritas Data dan Penentuan Orde Integrasi


Pengujian stasioneritas dilakukan menggunakan *Augmented Dickey-Fuller* (ADF) pada data latih sebanyak 96 observasi periode Januari 2016–Desember 2023. Hasil pengujian disajikan pada Tabel 2. Hasil ADF menunjukkan bahwa data telah stasioner pada tingkat *level* dengan ADF Statistic $-8,7541$ dan $p\text{-value} < 0,05$. *First-order differencing* tetap diikutsertakan dalam pembentukan kandidat model dan menghasilkan ADF Statistic $-10,8297$ dengan $p\text{-value} < 0,05$. Identifikasi awal parameter *Autoregressive* (p) dan *Moving Average* (q) selanjutnya dilakukan melalui plot ACF dan PACF menggunakan data latih untuk mencegah *data leakage*.

Tabel 2. Hasil Uji Augmented Dickey-Fuller (ADF) pada Data Latih, Sebelum dan Sesudah Differencing

Keterangan	Data Level (d = 0)	Setelah First-Order Differencing (d = 1)
ADF Statistic	-8,7541	-10,8297
p-value	0,0000	0,0000
Jumlah lag digunakan	0	2
Jumlah observasi efektif	95	92
Nilai kritis 1%	-3,5011	-3,5035
Nilai kritis 5%	-2,8925	-2,8935
Nilai kritis 10%	-2,5833	-2,5838
Kesimpulan ($\alpha = 0,05$)	Stasioner	Stasioner

Hasil Spesifikasi dan Pemodelan ARIMA

Identifikasi awal parameter *Autoregressive* (p) dan *Moving Average* (q) dilakukan melalui pendekatan heuristik dengan menganalisis visual korelogram pada plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Plot ACF digunakan untuk mengukur korelasi linier antara observasi saat ini dengan observasi pada *lag* sebelumnya, sementara PACF mengukur korelasi yang sama namun dengan menghilangkan pengaruh linier dari *lag-lag* perantara. Plot ACF dan PACF dari data historis pernikahan disajikan pada Gambar 3.



Gambar 3. Plot ACF dan PACF Data Pernikahan KUA Galur

Plot PACF menunjukkan *spike* pada lag 1 yang memberikan indikasi adanya komponen autoregresif orde pertama. Namun, penentuan model tidak hanya didasarkan pada korelogram sehingga beberapa kandidat ARIMA tetap dibandingkan berdasarkan AIC/BIC, signifikansi parameter, dan diagnostik residual Ljung-Box. Hasil perbandingan kandidat ditunjukkan pada Tabel 3.

Tabel 3. Perbandingan Kandidat Model

Model	AIC	BIC	Semua koef. signifikan	Ljung-Box, lag 10 (p)	MAE (uji)	RMSE (uji)	Keterangan
ARIMA (1,1,0)	722,699	727,806	Ya	0,0000	6,16	7,77	Ditolak-residual masih berautokorelasi
Model	AIC	BIC	Semua koef. signifikan	Ljung-Box, lag 10 (p)	MAE (uji)	RMSE (uji)	Keterangan
ARIMA (0,1,1)	694,408	699,516	Ya	0,2007	6,84	8,37	Dipilih-lolos ketiga kriteria
ARIMA (1,1,1)	695,819	703,480	Tidak (AR(1) p=0,339)	0,1858	6,96	8,50	Ditolak-koefisien AR tidak signifikan

Pada Tabel 3, tiga kandidat model dibandingkan pada data latih menggunakan tiga kriteria: nilai AIC/BIC, signifikansi statistik koefisien, dan hasil uji diagnostik residual Ljung-Box. ARIMA(1,1,0) memiliki metrik kesalahan terkecil pada data uji, namun ditolak karena gagal pada uji diagnostik residual (Ljung-Box $p = 0,0000$, mengindikasikan residual masih mengandung autokorelasi). ARIMA(1,1,1) memiliki AIC kedua terendah namun koefisien AR(1)-nya tidak signifikan secara statistik ($p = 0,339$). ARIMA(0,1,1) memenuhi ketiga kriteria sekaligus AIC dan BIC terendah di antara kandidat yang lolos diagnostik, seluruh koefisien signifikan, dan residual lolos uji Ljung-Box pada lag 10 ($p=0,2007$) sehingga dipilih sebagai model terbaik dari kandidat yang diperbandingkan. Pengujian lanjutan pada lag 1 terhadap model terpilih juga menunjukkan hasil yang konsisten, tidak terdapat autokorelasi residual yang signifikan ($p=0,51$).

Sebelum tahap komputasi dan estimasi parameter, dataset historis yang berjumlah 120 observasi bulanan dipartisi menjadi dua himpunan bagian yang saling lepas, yakni data latih (*training data*) dan data uji (*testing data*). Pembagian data (*data splitting*) ini merupakan prosedur esensial dalam pemodelan prediktif guna mencegah bias evaluasi. Berdasarkan pendekatan kronologis, observasi tersebut dibagi dengan rasio 80:20, sebagaimana dirinci pada Tabel 4. Data latih digunakan secara eksklusif untuk mengekstraksi pola historis, yang mencakup tahapan uji stasioneritas, identifikasi ACF/PACF, estimasi parameter, hingga pemilihan model. Sebagai langkah kontrol validitas, data uji sama sekali tidak dilibatkan dalam proses estimasi maupun pemilihan model, melainkan hanya diimplementasikan pada tahap evaluasi akhir untuk mengukur tingkat kemampuan generalisasi model terhadap data baru (*out-of-sample*). Untuk rincian pembagian dataset ditunjukkan pada Tabel 4.

Tabel 4. Rincian Pembagian Dataset untuk Skenario Pemodelan ARIMA

Jenis Data	Periode	Jumlah Observasi	Proporsi ($\pm$)
Data Latih (<i>Training</i>)	Januari 2016 – Desember 2023	96 Bulan	80%
Data Uji (<i>Testing</i>)	Januari 2024 – Desember 2025	24 Bulan	20%
Total Dataset		120 Bulan	100%

Pada Tabel 4, terlihat secara jelas bahwa keseluruhan dataset yang berjumlah 120 observasi dipisahkan menjadi dua himpunan bagian. Porsi utama sebesar 80% (96 bulan) dialokasikan murni sebagai data latih untuk pencocokan model (*model fitting*), sedangkan sisa 20% (24 bulan) dikhususkan sebagai data uji untuk memvalidasi performa algoritma secara *out-of-sample*. Melalui serangkaian eksperimen estimasi parameter menggunakan porsi 96 observasi data latih, tiga kandidat model dibandingkan secara komprehensif berdasarkan tiga kriteria utama: nilai AIC/BIC, signifikansi statistik koefisien, dan hasil uji diagnostik sisaan Ljung-Box.

Berdasarkan hasil perbandingan kandidat model, ARIMA(0,1,1) dipilih sebagai model yang digunakan untuk tahap peramalan. Pemilihan tersebut mempertimbangkan nilai kriteria informasi, signifikansi parameter, dan hasil diagnostik residual. Model ARIMA(0,1,1) menghasilkan nilai AIC sebesar 694,408 dan BIC sebesar 699,516, yang merupakan nilai terendah di antara kandidat model yang memenuhi persyaratan diagnostik. Selain itu, parameter *moving average* orde pertama atau MA(1) menunjukkan hasil yang signifikan secara statistik. Estimasi parameter model dilakukan menggunakan metode *Maximum Likelihood Estimation* (MLE) melalui pustaka *statsmodels*. Ringkasan hasil estimasi parameter ARIMA(0,1,1) berdasarkan 96 observasi data latih periode Januari 2016–Desember 2023 disajikan pada Tabel 5.

Tabel 5. Koefisien ARIMA(0,1,1), dilatih pada data latih (96 observasi, Jan 2016-Des 2023)

Parameter	Coef.	Std. Err.	z	P> z	[0,025	0,975]
MA(1)	-0,9538	0,0511	-18,681	0,000	-1,0539	-0,8537
σ^2	81,7985	11,0721	7,388	0,000	60,0977	103,4994

Hasil estimasi menunjukkan bahwa koefisien MA(1) sebesar $-0,9538$ dengan *standard error* 0,0511 dan nilai z sebesar $-18,681$. Nilai $p\text{-value} < 0,001$ menunjukkan bahwa parameter MA(1) signifikan secara statistik pada taraf signifikansi 5%. Interval kepercayaan 95% berada pada rentang $-1,0539$ hingga $-0,8537$ dan tidak mencakup nilai nol, sehingga semakin mendukung signifikansi parameter tersebut. Koefisien MA(1) yang bernilai negatif menunjukkan bahwa komponen kesalahan pada periode sebelumnya memiliki hubungan berlawanan arah dengan perubahan nilai deret pada periode berjalan. Sementara itu, estimasi varians residual (σ^2) sebesar 81,7985 menggambarkan besarnya variasi kesalahan yang belum dapat dijelaskan oleh model.

Hasil diagnostik residual menunjukkan nilai statistik Ljung-Box pada *lag* 1 sebesar $Q = 0,42$ dengan $p\text{-value} = 0,51$. Karena nilai $p\text{-value} > 0,05$, hipotesis nol tidak ditolak sehingga tidak terdapat bukti autokorelasi residual yang signifikan pada *lag* yang diuji. Uji Jarque-Bera menghasilkan nilai 5,65 dengan $p\text{-value} = 0,06$, yang menunjukkan bahwa pada taraf signifikansi 5% tidak terdapat bukti yang cukup untuk menolak asumsi normalitas residual. Selain itu, pengujian heteroskedastisitas menghasilkan $H = 1,07$ dengan $p\text{-value} = 0,85$, sehingga tidak terdapat bukti yang cukup mengenai adanya perubahan varians residual yang signifikan. Model juga menghasilkan *Log-Likelihood* sebesar $-345,204$. Secara keseluruhan, hasil estimasi dan diagnostik tersebut menunjukkan bahwa ARIMA(0,1,1) memenuhi kriteria statistik yang ditetapkan dan selanjutnya digunakan untuk melakukan evaluasi peramalan pada data uji.

Berdasarkan Tabel 5, dapat dilihat bahwa model ARIMA(0,1,1) yang dilatih pada data latih. Koefisien MA(1) sebesar $-0,9538$ signifikan secara statistik ($p < 0,001$), menunjukkan bahwa galat prediksi pada periode sebelumnya berkontribusi kuat dan berlawanan arah terhadap nilai saat ini. Uji Ljung-Box pada *lag* 1 menghasilkan $p\text{-value} = 0,51$ ($> 0,05$), menunjukkan residual tidak menunjukkan autokorelasi signifikan; uji Jarque-Bera ($p = 0,06$) menunjukkan residual

mendekati distribusi normal. Signifikansi statistik ini menunjukkan kecocokan model terhadap data latih, namun kemampuan prediksi pada data baru tetap dinilai secara terpisah melalui MAE dan RMSE pada data uji.

Hasil Evaluasi Performa dan Analisis Akurasi Prediksi

Evaluasi dilakukan untuk membandingkan tingkat kesalahan prediksi model terhadap data uji aktual periode 2024-2025. Metrik kesalahan yang digunakan adalah *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE). Hasil evaluasi visual dan metrik komprehensif disajikan pada Tabel 6.

Tabel 6. Hasil Evaluasi Tingkat Kesalahan Model ARIMA (0,1,1)

Metrik Evaluasi	Definisi Metrik	Nilai Galat (Error Value)
Mean Absolute Error (MAE)	Rata-rata absolut deviasi prediksi	6,84
Mean Squared Error (MSE)	Rata-rata kuadrat kesalahan	70,03
Root Mean Squared Error (RMSE)	Akar rata-rata kuadrat kesalahan	8,37
Mean Absolute Percentage Error (MAPE)	Rata-rata persentase kesalahan absolut	159,93%
Mean Absolute Scaled Error (MASE)	Rasio galat absolut terhadap galat naive forecast	0,7398

Pada Tabel 6, evaluasi model ARIMA(0,1,1) pada data uji (24 observasi, Januari 2024–Desember 2025) menghasilkan Mean Absolute Error (MAE) sebesar 6,84, Mean Squared Error (MSE) sebesar 70,03, dan Root Mean Squared Error (RMSE) sebesar 8,37. Nilai MAE tersebut menunjukkan bahwa rata-rata prediksi model menyimpang sekitar tujuh pernikahan per bulan dari jumlah aktual, tergolong wajar mengingat simpangan baku data historis sebesar 8,98.

Sebagai ukuran kesalahan relatif yang melengkapi MAE dan RMSE, MAPE tercatat sebesar 159,93%. Karena tidak terdapat bulan dengan jumlah pernikahan aktual nol pada data uji, nilai ini valid dihitung tanpa risiko pembagian dengan nol; meskipun demikian, nilai MAPE yang tinggi ini terutama disebabkan oleh sensitivitas metrik persentase terhadap bulan-bulan dengan jumlah pernikahan aktual yang kecil (mendekati batas bawah rentang data), di mana galat absolut yang relatif kecil dapat menghasilkan persentase kesalahan yang sangat besar. Oleh karena itu, MAPE pada data ini kurang representatif untuk interpretasi akurasi secara keseluruhan dan sebaiknya tidak dijadikan acuan tunggal. Sebagai pembanding yang tidak sensitif terhadap skala data, MASE tercatat sebesar 0,7398; nilai MASE di bawah 1 mengindikasikan bahwa ARIMA(0,1,1) memberikan kesalahan prediksi yang lebih kecil dibandingkan *naive forecast* satu langkah yang dihitung secara in-sample pada data latih.

Perbandingan lebih lanjut terhadap tiga model *baseline* sederhana pada data uji yang sama menunjukkan bahwa ARIMA(0,1,1) menghasilkan MAE dan RMSE sebesar 6,84 dan 8,37, dibandingkan *naive forecast* (MAE=6,21; RMSE=7,90), *seasonal naive* (MAE=6,71; RMSE=8,30), dan *moving average* 12 bulan (MAE=6,42; RMSE=7,99). Hasil ini menunjukkan bahwa pada horizon data uji ini, ketiga baseline sederhana justru mencatatkan MAE dan RMSE yang sedikit lebih rendah dibandingkan ARIMA(0,1,1); dengan kata lain, ARIMA(0,1,1) tidak terbukti unggul secara konsisten dari sisi akurasi titik prediksi murni terhadap pendekatan naif. Temuan ini konsisten dengan karakteristik ARIMA(0,1,1) yang cenderung memuluskan (smoothing) proyeksinya menuju nilai yang relatif konstan setelah langkah pertama (lihat bagian Hasil Forecasting Jangka Menengah), sehingga pada rentang uji yang relatif stabil, selisihnya terhadap baseline konstan seperti *naive forecast* dan *moving average* menjadi tipis. Nilai tambah ARIMA(0,1,1) dibandingkan baseline naif dengan demikian tidak terletak pada superioritas akurasi titik semata, melainkan pada kerangka inferensi statistik yang menyertainya: signifikansi koefisien, interval kepercayaan prediksi, serta diagnostik residual (Ljung-Box, Jarque-Bera) yang


tidak tersedia pada pendekatan naif. Keterbatasan ini secara eksplisit diakui sebagai bagian dari batasan penelitian dan menjadi salah satu arah penyempurnaan pada penelitian lanjutan.

Hasil Peramalan Tahun 2026

Model ARIMA(0,1,1) selanjutnya dilatih ulang menggunakan seluruh 120 observasi untuk menghasilkan proyeksi Januari–Desember 2026. Model final menghasilkan koefisien MA(1) sebesar $-0,9428$ ($p < 0,001$), AIC 863,552, dan BIC 869,110. Uji Ljung–Box menunjukkan tidak terdapat autokorelasi residual yang signifikan ($p = 0,65$), sedangkan uji Jarque–Bera ($p = 0,02$) menunjukkan residual model final tidak sepenuhnya berdistribusi normal.

Tabel 7. Koefisien ARIMA(0,1,1), model final (120 observasi, Jan 2016–Des 2025)

Parameter	Coef.	Std. Err.	z	P> z	[0,025	0,975]
MA(1)	-0,9428	0,044	-21,310	0,000	-1,030	-0,856
σ^2	78,7954	9,689	8,132	0,000	59,805	97,786



Gambar 4. Proyeksi Jumlah Pernikahan 12 Bulan ke Depan dan Grafik Forecasting Jangka Pendek

Berdasarkan Gambar 4, plot peramalan (garis dan titik hijau di ujung kanan grafik), model final memproyeksikan jumlah pernikahan sebesar 13 peristiwa per bulan secara konstan sepanjang Januari hingga Desember 2026. Nilai proyeksi yang datar ini merupakan karakteristik umum model ARIMA(0,1,1) tanpa komponen *autoregressive*, di mana pengaruh nilai historis terhadap prediksi hanya bertahan pada langkah pertama peramalan melalui komponen MA(1), sehingga proyeksi untuk bulan-bulan berikutnya langsung berkonvergen ke nilai konstan. Hal ini menjadi keterbatasan model dalam menangkap fluktuasi musiman atau lonjakan insidental (misalnya pada bulan Zulhijjah) pada horizon peramalan menengah, yang secara eksplisit menjadi keterbatasan dalam penelitian ini. Meskipun proyeksi tersebut tidak menampilkan puncak fluktuasi pada grafiknya, informasi nilai dasar (*baseline*) ini dapat digunakan sebagai salah satu informasi pendukung perencanaan tenaga penghulu dan kebutuhan administrasi di KUA Galur, meskipun dampaknya terhadap pengelolaan KUA belum diuji secara langsung. Melalui pendekatan berbasis data (*data-driven*), instansi dapat mempertimbangkan angka estimasi dasar ini sebagai salah satu masukan awal dalam menetapkan standar minimal alokasi tenaga penghulu dan memperkirakan kebutuhan dokumen pendukung, tanpa menjadikannya sebagai satu-satunya acuan. Dengan mengombinasikan proyeksi dasar dari model ini beserta antisipasi manual pada bulan-bulan puncak kultural, KUA Galur berpotensi mengurangi risiko penumpukan akad nikah yang tidak terantisipasi, sehingga proyeksi ini dapat menjadi salah satu masukan bagi upaya peningkatan efisiensi pelayanan administrasi kepada masyarakat.

Pada Tabel 8, interval kepercayaan 95% dihitung secara analitis dari parameter model final ARIMA(0,1,1) yang dilaporkan pada Tabel 7 ($\sigma^2=78,7954$; koefisien MA(1)=-0,9428) menggunakan rumus varians galat kumulatif untuk model ARIMA(0,1,1): $\text{Var}(h) = \sigma^2[1+(h-1)(1+\theta)^2]$, dengan batas bawah yang bernilai negatif dipotong (*truncated*) menjadi nol karena jumlah pernikahan merupakan data cacah nonnegatif. Nilai pada tabel ini telah diverifikasi secara

independen: untuk model IMA(1,1) atau ekuivalen ARIMA(0,1,1), varians galat ramalan-h mengikuti bentuk tertutup $\text{Var}(h) = \sigma^2[1 + (h-1)(1+\theta)^2]$ berdasarkan representasi psi-weight MA tak hingga model tersebut, sehingga nilainya dapat dihitung langsung dari parameter model final pada Tabel 7 tanpa bergantung pada nilai observasi individual. Hasil verifikasi ini konsisten dan identik dengan nilai yang dilaporkan pada Tabel 8, sehingga tidak diperlukan revisi lebih lanjut pada tabel ini. Interval yang lebar ini (kira-kira 0 hingga 30-31 pernikahan per bulan) secara eksplisit menggarisbawahi bahwa proyeksi titik tunggal (13 pernikahan/bulan) tidak boleh dibaca sebagai kepastian, dan memperkuat rekomendasi agar hasil peramalan digunakan sebagai informasi pendukung, bukan dasar tunggal, dalam perencanaan operasional KUA Galur.

Tabel 8. Prediksi Jumlah Pernikahan 12 Bulan ke Depan Beserta Interval Kepercayaan 95%

Periode	Prediksi (titik)	Batas Bawah 95%	Batas Atas 95%
Januari 2026	13	0	30
Februari 2026	13	0	30
Maret 2026	13	0	30
April 2026	13	0	30
Mei 2026	13	0	31
Juni 2026	13	0	31
Juli 2026	13	0	31
Agustus 2026	13	0	31
September 2026	13	0	31
Oktober 2026	13	0	31
November 2026	13	0	31
Desember 2026	13	0	31

Pembahasan

Hasil penelitian menunjukkan bahwa ARIMA(0,1,1) memenuhi kriteria statistik yang digunakan dalam pemilihan model, yaitu kriteria informasi yang relatif rendah, parameter yang signifikan, serta residual yang tidak menunjukkan autokorelasi signifikan. Namun, evaluasi *out-of-sample* menunjukkan bahwa model belum mampu mengungguli pendekatan *baseline* sederhana secara konsisten. Kondisi tersebut menunjukkan bahwa kelayakan statistik model tidak selalu berbanding lurus dengan peningkatan akurasi prediksi pada data baru.

Salah satu penyebabnya adalah karakteristik data pernikahan yang memiliki fluktuasi dan lonjakan pada periode tertentu. Galat terbesar pada data uji terjadi pada Juni 2024, ketika jumlah aktual mencapai 31 pernikahan sedangkan prediksi model sebesar 15,7. Pola serupa terjadi pada Juni 2025 dengan 29 pernikahan. Kedua periode tersebut berdekatan dengan Zulhijjah, sehingga memberikan indikasi bahwa fluktuasi jumlah pernikahan kemungkinan tidak hanya mengikuti kalender Masehi, tetapi juga berkaitan dengan kalender Hijriah dan praktik sosiokultural masyarakat. Karena periode Hijriah bergeser terhadap kalender Masehi, pola tersebut sulit ditangkap oleh ARIMA nonmusiman yang hanya memanfaatkan struktur temporal historis.

Temuan tersebut sekaligus menjelaskan mengapa pola musiman 12 bulanan berdasarkan kalender Masehi relatif lemah dan mengapa model menghasilkan prediksi yang cenderung datar. Dibandingkan penelitian terdahulu, hasil penelitian ini menunjukkan bahwa kinerja ARIMA sangat dipengaruhi karakteristik deret waktu. Beberapa penelitian sebelumnya menunjukkan performa ARIMA yang baik pada pola yang lebih teratur, sedangkan pendekatan hibrida seperti ARIMA-MLP dan ARIMA-Ridge Regression dilaporkan mampu meningkatkan akurasi ketika terdapat komponen nonlinier atau variabel tambahan. Dengan demikian, integrasi informasi kalender Hijriah atau variabel eksternal relevan dapat menjadi arah pengembangan model peramalan jumlah pernikahan selanjutnya.

Dari sisi praktis, proyeksi model dapat digunakan sebagai informasi pendukung dalam perencanaan pelayanan KUA Galur, khususnya sebagai estimasi dasar kebutuhan tenaga penghulu dan administrasi. Namun, interval prediksi yang lebar serta keterbatasan model dalam

menangkap lonjakan menunjukkan bahwa hasil peramalan tidak sebaiknya digunakan sebagai satu-satunya dasar pengambilan keputusan. Informasi hasil model perlu dikombinasikan dengan pengetahuan operasional serta kalender sosial dan kultural masyarakat setempat.

Penelitian ini memiliki beberapa keterbatasan. Dataset hanya terdiri atas 120 observasi bulanan dan 13 observasi di antaranya merupakan hasil interpolasi. Model belum memasukkan variabel eksternal, khususnya kalender Hijriah dan faktor sosial-ekonomi, serta belum divalidasi menggunakan *rolling* atau *walk-forward validation*. Data juga hanya berasal dari KUA Galur sehingga generalisasi ke wilayah lain perlu dilakukan secara hati-hati. Selain itu, residual model final tidak sepenuhnya memenuhi asumsi normalitas berdasarkan uji Jarque–Bera. Keterbatasan tersebut membuka peluang penelitian selanjutnya untuk mengembangkan model dengan variabel eksogen, kalender Hijriah, pendekatan musiman yang lebih sesuai, maupun metode hibrida.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, algoritma ARIMA dapat digunakan untuk memodelkan dan memprediksi jumlah pernikahan di KUA Galur berbasis 120 observasi data historis bulanan (Januari 2016–Desember 2025). Perbandingan terhadap tiga kandidat model nonmusiman menunjukkan bahwa ARIMA(0,1,1) merupakan model terpilih, karena memiliki AIC dan BIC terendah (694,408 dan 699,516) di antara kandidat yang lolos diagnostik, koefisien MA(1) yang signifikan secara statistik ($p < 0,001$), dan residual yang lolos uji Ljung–Box baik pada lag 10 ($p = 0,2007$) maupun lag 1 ($p = 0,51$). Evaluasi pada data uji menghasilkan MAE sebesar 6,84 dan RMSE sebesar 8,37 (MASE 0,74 terhadap naive forecast in-sample), tingkat kesalahan yang perlu dibaca berdampingan dengan temuan bahwa tiga baseline sederhana (naive forecast, seasonal naive, moving average) mencatatkan MAE dan RMSE yang sedikit lebih rendah pada data uji yang sama, sehingga ARIMA(0,1,1) tidak terbukti unggul secara konsisten dari sisi akurasi titik semata; keterbatasan lain penelitian ini dirangkum pada bagian Keterbatasan Penelitian. Model final, yang dilatih ulang pada seluruh observasi, memproyeksikan jumlah pernikahan sebesar 13 per bulan secara konstan sepanjang tahun 2026 sebuah keterbatasan yang mencerminkan sifat model ARIMA(0,1,1) yang cenderung memuluskan (smoothing) fluktuasi jangka menengah. Penelitian ini juga menemukan bahwa kecenderungan peningkatan pernikahan pada bulan Zulhijjah bersifat signifikan secara statistik (uji Chi-Square, $\chi^2 = 473,56$, $p < 0,001$, dengan jumlah pernikahan 119,5% di atas rata-rata bulan Hijriah lainnya), namun pola ini tidak tertangkap oleh struktur musiman tetap 12-bulan Masehi (ACF lag 12 = 0,2042, berada tepat pada ambang signifikansi) sehingga tidak dimodelkan melalui SARIMA. Penelitian lanjutan disarankan membandingkan ARIMA dengan model alternatif seperti SARIMA, Prophet, atau model berbasis variabel eksternal (misalnya kalender Hijriah/Jawa, hari libur nasional, atau faktor sosial-ekonomi lokal), mempertimbangkan pemodelan hibrida yang mengintegrasikan pengaruh kalender Hijriah/Jawa secara eksplisit untuk mengatasi keterbatasan proyeksi yang datar pada horizon menengah, serta menerapkan validasi bergulir (*walk-forward validation*) untuk menguji kestabilan performa model secara lebih ketat.

DAFTAR PUSTAKA

- [1] S. R. Catur Putri and L. Junaedi, “Penerapan Metode Peramalan Autoregressive Integrated Moving Average Pada Sistem Informasi Pengendalian Persediaan Bahan Baku,” *J. Ilmu Komput. dan Bisnis*, vol. 13, no. 1, pp. 164–173, 2022, doi: 10.47927/jikb.v13i1.293.
- [2] R. S. N. Frisca Octikay Prianisa, “PENERAPAN MODEL ARIMA UNTUK PERAMALAN JUMLAH PENGALUAN KTP- ELPADA PROGRAM SIPEDULI DINAS KEPENDUDUKAN DAN PENCATATAN SIPIL,” pp. 538–543, 2023,

Pemodelan Peramalan Jumlah Pernikahan Menggunakan ARIMA Berbasis Data Historis pada KUA Galur (Hasan Ibrahim Sansyah, Eko Riswanto / Eko Riswanto)

- [Online]. Available:
<https://conference.um.ac.id/index.php/LAS/article/download/8283/2598>
- [3] N. B. Moerrin, A. T. Damaliana, and I. G. S. M. Diyasa, "Bus Passenger Demand Forecasting Using A Hybrid ARIMA–MLP Model," *bit-Tech*, vol. 8, no. 3, pp. 3473–3484, 2026, doi: 10.32877/bt.v8i3.3549.
 - [4] H. Alabdulrazzaq, M. N. Alenezi, Y. Rawajfih, B. A. Alghannam, A. A. Al-Hassan, and F. S. Al-Anzi, "On the accuracy of ARIMA based prediction of COVID-19 spread," *Results Phys.*, vol. 27, p. 104509, 2021, doi: 10.1016/j.rinp.2021.104509.
 - [5] R. Tosepu and N. Y. Ningsi, "Forecasting of diarrhea disease using ARIMA model in Kendari City, Southeast Sulawesi Province, Indonesia," *Heliyon*, vol. 10, no. 22, p. e40247, 2024, doi: 10.1016/j.heliyon.2024.e40247.
 - [6] P. S. Parlinto and E. A. Setiawan, "Electricity Demand Forecasting Using a Hybrid ARIMA and Ridge Regression Model," *J. Energi Baru dan Terbarukan*, vol. 7, no. 2, pp. 22–28, 2026, doi: 10.14710/jebt.2026.31328.
 - [7] G. Wang, H. Su, L. Mo, X. Yi, and P. Wu, "Forecasting of soil respiration time series via clustered ARIMA," *Comput. Electron. Agric.*, vol. 225, p. 109315, 2024, doi: <https://doi.org/10.1016/j.compag.2024.109315>.
 - [8] Y. Li, K. Wu, and J. Liu, "Self-paced ARIMA for robust time series prediction," *Knowledge-Based Syst.*, vol. 269, p. 110489, 2023, doi: <https://doi.org/10.1016/j.knosys.2023.110489>.
 - [9] S. A. M. S. Christo, and J. V. Elizabeth, "A hybrid approach to time series forecasting: Integrating ARIMA and prophet for improved accuracy," *Results Eng.*, vol. 27, no. June, p. 105703, 2025, doi: 10.1016/j.rineng.2025.105703.
 - [10] M. I. Syahroni, "Prosedur Penelitian Kuantitatif (Quantitative Research Procedures)," *J. Al-Musthafa STIT Al-Aziziyah Lomb. Bara*, vol. 2, no. 3, pp. 211–213, 2022, [Online]. Available:
<https://scholar.archive.org/work/yxmnfakwpne4rnpbb2rrrognoe/access/wayback/https://ejurnal.stitaziziyah.ac.id/index.php/ejam/article/download/50/45>
 - [11] F. Petropoulos et al., "Operations & supply chain management: principles and practice," *Int. J. Prod. Res.*, vol. 64, no. 1, pp. 330–513, 2026, doi: 10.1080/00207543.2025.2555531.
 - [12] F. Fathoni, S. Hariza Marshella, A. Risyahputri, N. Raihana Putri, E. Therina Lakeisyah, and A. Ibrahim, "Implementasi Metode Arima Dalam Forecasting Jumlah Kasus Penderita Penyakit Hiv/Aids," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 4, pp. 6531–6538, 2025, doi: 10.36040/jati.v9i4.14136.
 - [13] W. A. Pratiwi, A. F. Rizki, K. A. Notodiputro, Y. Angraini, and L. N. A. Mualifah, "the Comparison of Arima and Rnn for Forecasting Gold Futures Closing Prices," *Barekeng*, vol. 19, no. 1, pp. 397–406, 2025, doi: 10.30598/barekengvol19iss1pp397-406.
 - [14] A. K. Rachmawati, "Peramalan Penyebaran Jumlah Kasus Covid19 Provinsi Jawa Tengah dengan Metode ARIMA," *Zeta - Math J.*, vol. 6, no. 1, pp. 11–16, 2020, doi: 10.31102/zeta.2021.6.1.11-16.
 - [15] W. J. Dlamini, S. F. Melesse, and H. G. Mwambi, "A Comparative Study of ARIMA, ARFIMA, and ARIMA-ARFIMA Models in Predicting Under-five Mortality Rate in Four East-African Nations," *Open Public Health J.*, vol. 19, no. 1, pp. 1–10, 2026, doi: 10.2174/0118749445420131260114041333.
 - [16] C. Shoko and P. Njuho, "Arima Model in Predicting of Covid-19 Epidemic for the Southern Africa Region," *African J. Infect. Dis.*, vol. 17, no. 1, pp. 1–9, 2023, doi: 10.21010/Ajidv17i1.1.
 - [17] O. Mphale, E. U. Okike, and N. Rafifing, "A Machine Learning Univariate Time series Model for Forecasting COVID-19 Confirmed Cases: A Pilot Study in Botswana," *IJCSNS Int. J. Comput. Sci. Netw. Secur.*, vol. 22, no. 1, 2022, [Online]. Available:
<https://doi.org/10.22937/IJCSNS.2022.22.1.31>