Perhitungan Iuran Jaminan Kesehatan Nasional (JKN) Berbasis *Dynamic*

Agus Setiawan[1*], Udjianna Sekteria Pasaribu[2] dan Adilan Widyawan Mahdiyasa[3]
[1,2,3] Actuarial Science, Institut Teknologi Bandung, Kota Bandung, Indonesia
[*]Corresponding Author: ase.aktuaris@gmail.com

Abstrak

Penetapan iuran Jaminan Kesehatan Nasional (JKN) merupakan komponen kunci bagi keberlanjutan sistem pembiayaan kesehatan di Indonesia. Namun, pendekatan yang digunakan saat ini bersifat statis, sehingga tidak mampu menangkap dinamika endogenitas antarvariabel. Penelitian ini mengembangkan kerangka estimasi iuran yang lebih adaptif menggunakan model panel dinamis. Struktur data panel tahun 2016–2019 sangat heterogen secara spasial dan memiliki horizon waktu cukup pendek menyebabkan singularitas matriks momen. Difference Generalized Method of Moments (GMM) dipilih sebagai pendekatan yang stabil dan konsisten. Hasil estimasi menunjukkan koefisien dinamis $\hat{\alpha} = 0.60497$, menandakan adanya persistensi moderat dalam evolusi biaya kesehatan per peserta, namun tetap stabil karena $|\hat{\alpha}| < 1$. Uji Arellano–Bond mengonfirmasi autokorelasi orde pertama sebagai konsekuensi transformasi differencing, sementara AR (2) tidak teridentifikasi karena keterbatasan panjang data (T = 4). Kalibrasi skala prediksi digunakan untuk menyesuaikan nilai estimasi dengan standar iuran nasional sebesar Rp100.000 per peserta per bulan. Hasil akhir memperlihatkan variasi spasial yang sangat kuat: Pulau Jawa memiliki kebutuhan iuran tertinggi (mendekati Rp3 juta per tahun), disusul Bali, sedangkan Papua dan Maluku menunjukkan nilai paling rendah (sekitar Rp80.000–100.000 per tahun). Temuan ini menegaskan bahwa biaya kesehatan di Indonesia sangat sensitif terhadap konteks geografis, densitas fasilitas, serta pola pemanfaatan layanan kesehatan.

***Kata kunci**: Dana Jaminan Sosial Kesehatan (DJS); Dynamic; Jaminan Kesehatan Nasional; Generalized Method of Moments (GMM).*

Abstract

Determining National Health Insurance (JKN) contributions is a key component for the sustainability of the health financing system in Indonesia. However, the current approach is static, thus unable to capture the endogenous dynamics between variables. This study develops a more adaptive contribution estimation framework using a dynamic panel model. The panel data structure for 2016–2019 is highly spatially heterogeneous and has a relatively short time horizon, causing singularity in the moment matrix. The Difference Generalized Method of Moments (GMM) was chosen as a stable and consistent approach. The estimation results show a dynamic coefficient of $\hat{\alpha} = 0.60497$, indicating moderate persistence in the evolution of health costs per participant, but remains stable because $|\hat{\alpha}| < 1$. The Arellano–Bond test confirms first-order autocorrelation as a consequence of the differencing transformation, while AR(2) is not identified due to the limited data length (T = 4). Prediction scale calibration is used to adjust the estimated value to the national contribution standard of IDR 100,000 per participant per month. The final results show strong spatial variation: Java has the highest contribution requirement (approaching Rp 3 million per year), followed by Bali, while Papua and Maluku have the lowest (around Rp 80,000–100,000 per year). These findings confirm that healthcare costs in Indonesia are highly sensitive to geographic context, facility density, and patterns of healthcare utilization.

***Keywords**: Social Health Security Fund (DJS); Dynamic; National Health Insurance; Generalized Method of Moments (GMM).*

Citation: Setiawan, A., dkk., (2025). Perhitungan Iuran Jaminan Kesehatan Nasional (JKN) Berbasis Dynamic. *Prodising Seminar Nasional Jurusan Matematika 2025*. 126 - 134

PENDAHULUAN

Program Jaminan Kesehatan Nasional (JKN) menjadi salah satu pilar dalam perlindungan sosial di Indonesia. Program ini merupakan program jaminan sosial terbesar yang pengelolaannya dilakukan melalui BPJS Kesehatan. Sejak didirikan pada tahun 2014, JKN telah berkembang menjadi tulang punggung perlindungan kesehatan masyarakat dengan jumlah peserta yang terus meningkat. Namun, dalam perjalanannya, program ini menghadapi tantangan yang semakin kompleks, baik dari sisi pembiayaan maupun utilisasi layanan kesehatan. Penetapan besaran iuran merupakan aspek fundamental dalam menjamin keberlanjutan program. Selama ini, metode perhitungan iuran yang digunakan cenderung bersifat statis, yaitu berbasis *experience rating*, yang memperhitungkan eksposur biaya dan frekuensi pemanfaatan historis. Metode ini relatif sederhana dan mudah diaplikasikan, namun memiliki keterbatasan karena tidak mampu menangkap perubahan dinamika waktu, sifat persisten dalam pemanfaatan layanan, serta adanya potensi endogenitas antarvariabel. Akibatnya, model ini berisiko menghasilkan perhitungan iuran yang kurang adaptif terhadap perubahan struktural dalam sistem kesehatan.

Di sisi lain, terdapat perkembangan demografi berupa peningkatan usia harapan hidup, pergeseran struktur populasi, serta peningkatan prevalensi penyakit kronis dan katastropik yang berdampak signifikan terhadap biaya layanan kesehatan. Selain itu, perubahan perilaku peserta dalam memanfaatkan layanan kesehatan, fragmentasi sistem layanan,

© Jurusan Matematika - Universitas Negeri Medan

serta kondisi makroekonomi seperti inflasi medis turut menambah kompleksitas perhitungan iuran JKN. Dalam kerangka aktuaria sosial, kebutuhan untuk mengembangkan model yang lebih dinamis menjadi semakin mendesak. Salah satu pendekatan yang relevan adalah penggunaan *Generalized Method of Moments* (GMM) pada data panel. Metode ini memiliki keunggulan dalam menghasilkan estimasi yang konsisten meskipun terdapat heteroskedastisitas, autokorelasi, serta endogenitas, yang sering muncul pada analisis pemanfaatan layanan kesehatan.

Kerangka penelitian ini mengacu pada *Behavioral Model of Health Services Use* dari Andersen (1995), yang mengidentifikasi tiga kelompok faktor penentu pemanfaatan layanan kesehatan, yaitu: (1) Predisposing factors, seperti usia dan jenis kelamin peserta; (2) Enabling factors, seperti unit cost layanan, tipe fasilitas kesehatan, fragmentasi layanan, dan kondisi sosial-ekonomi; serta (3) Need factors, berupa kebutuhan medis yang tercermin dari prevalensi penyakit kronis berbiaya tinggi. Berdasarkan latar belakang tersebut, penelitian ini penting dilakukan untuk mengusulkan kerangka perhitungan iuran JKN yang lebih dinamis dan adaptif terhadap perubahan lingkungan demografi, epidemiologi, dan ekonomi. Secara akademis, penelitian ini diharapkan memperkaya literatur di bidang aktuaria sosial dan ekonometrika kesehatan. Secara praktis, penelitian ini memberikan alternatif kerangka perhitungan iuran yang dapat mendukung BPJS Kesehatan dalam menjaga keberlanjutan Dana Jaminan Sosial Kesehatan (DJS).

METODE PENELITIAN

Metode Generalized Method of Moments (GMM) berasal dari konsep fundamental Method of Moments (MoM), namun kemudian dikembangkan oleh Hansen pada tahun 1982. Pada intinya, GMM berupaya menentukan nilai parameter sehingga momen teoritis dari suatu model sesuai dengan momen empiris yang diperoleh dari data. Berbeda dengan MoM klasik yang mengharuskan jumlah kondisi momen sama dengan jumlah parameter, GMM menawarkan fleksibilitas lebih karena kondisi momen dapat lebih banyak, sebuah situasi yang disebut over-identification. Fleksibilitas ini membuat GMM sangat relevan digunakan dalam penelitian yang datanya sarat heteroskedastisitas, autokorelasi, atau endogenitas, seperti pada analisis biaya layanan kesehatan.

Penelitian ini menerapkan GMM dalam kerangka data panel dinamis untuk memperkirakan kebutuhan iuran JKN secara lebih akurat dan adaptif antarwilayah dan antarwaktu. Data yang digunakan merupakan panel kabupaten/kota di Indonesia untuk periode 2016–2019, dengan variasi geografis dan karakteristik epidemiologis yang cukup beragam. Seluruh proses pengolahan dan analisis dilakukan menggunakan R Studio, memanfaatkan paket plm untuk pemodelan panel dan dplyr untuk pemrosesan data. Langkah pertama dalam penelitian meliputi pembersihan data, pengecekan adanya duplikasi, verifikasi kode wilayah, dan penyesuaian definisi variabel supaya semua unit bisa dibandingkan secara konsisten. Setelah dataset terverifikasi, struktur panel dibuat dengan memakai kode kabupaten/kota sebagai indeks individu dan tahun sebagai indeks waktu, memungkinkan analisis perubahan biaya kesehatan di tiap wilayah sepanjang waktu. Variabel dependen dalam penelitian ini adalah estimasi iuran per peserta yang dihitung berdasarkan ekspektasi biaya kesehatan. Untuk tiap wilayah ipada tahun t, ekspektasi biaya diperoleh dengan mengalikan frekuensi kunjungan layanan dengan unit cost masing-masing jenis layanan, sehingga secara matematis dirumuskan sebagai:

$$EC_{it} = r_{it}^{RJTL} \cdot c_{it}^{RJTL} + r_{it}^{RITL} \cdot c_{it}^{RITL} \quad (1)$$

Dimana r_{it}^{RJTL}: kunjungan rawat jalan tingkat lanjutan (rate RJTL); r_{it}^{RITL}: kunjungan rawat inap tingkat lanjutan (rate RITL); c_{it}^{RJTL}: biaya rata-rata rawat jalan tingkat lanjutan (unit cost RJTL); dan c_{it}^{RITL}: biaya rata-rata rawat inap tingkat lanjutan (unit cost RITL). Kemudian, iuran per peserta ($iuran_pc_{it}$) diberikan *loading* teknis sebagai asumsi besaran biaya operasional sebesar 5% sehingga diperoleh *expected contribution per capita* (persamaan 2).

$$y_{it} = iuran_pc_{it} = 1.05 \times EC_{it} \quad (2)$$

Dalam konteks sistem pembiayaan JKN, nilai y_{it} menggambarkan kebutuhan iuran berdasarkan struktur risiko dan biaya di suatu kabupaten/kota. Besaran ini tidak hanya ditentukan oleh kondisi biaya dan utilisasi pada periode berjalan, tetapi juga oleh perilaku historis karena pengeluaran kesehatan bersifat persisten dari waktu ke waktu. Oleh karena itu, hubungan dinamis dimodelkan melalui persamaan panel berikut:

$$y_{it} = \alpha . y_{i,t-1} + \beta . x_{it} + \mu_i + \varepsilon_{it} \quad (3)$$

© Jurusan Matematika - Universitas Negeri Medan

Dimana; y_{it}: variabel endogen atau dependen (rate RJTL, rate RITL); $y_{i,t-1}$: lag variabel endogen yang menyebabkan endogenitas; x_{it}: kovariat predetermined atau variabel penjelas; *predisposing*, *enabling, need*; μ_i: efek tetap individu, menangkap heterogenitas tetap antarwilayah; ε_{it} galat idiosinkratik; $i = 1,2, \dots, N$; dan $t = 1,2, \dots, T$.

Dalam model panel dinamis, keberadaan variabel lag dari iuran, yaitu $y_{i,t-1}$, hampir selalu menimbulkan persoalan metodologis yang tidak dapat diabaikan. Secara alamiah, nilai iuran pada tahun sebelumnya memiliki hubungan dengan komponen error pada tahun berjalan, karena keduanya sama-sama dipengaruhi oleh faktor permanen yang melekat pada setiap wilayah. Akibatnya, pendekatan estimasi yang paling sederhana seperti *Ordinary Least Squares* (OLS) tidak dapat lagi diandalkan. OLS secara otomatis menganggap tidak ada korelasi antara variabel penjelas dengan error, sehingga ketika asumsi ini dilanggar, estimator menjadi bias dan tidak konsisten.

Pendekatan *Fixed Effects* (FE) yang sering diandalkan untuk mengatasi heterogenitas lintas individu pun tidak mampu menyelesaikan masalah ini. Meskipun FE mampu menghilangkan efek tetap melalui transformasi *within*, transformasi tersebut tetap meninggalkan korelasi antara $y_{i,t-1}$yang sudah ditransformasi dan error yang juga mengalami transformasi serupa. Dengan kata lain, meskipun FE menghilangkan karakteristik tetap antarwilayah, ia tidak memutus hubungan langsung antara variabel lag dan error. Inilah yang menyebabkan endogenitas tetap melekat dalam model, sehingga FE tidak memberikan solusi terhadap bias yang muncul. Karena keterbatasan tersebut, diperlukan sebuah pendekatan yang secara eksplisit didesain untuk menghadapi struktur endogenitas pada model dinamis. Dalam konteks ini, Generalized Method of Moments (GMM) menjadi pilihan yang sangat relevan. GMM tidak hanya fleksibel dalam menghadapi berbagai bentuk pelanggaran asumsi klasik, tetapi juga memiliki kemampuan untuk menghasilkan estimator yang konsisten meskipun terdapat korelasi antara variabel penjelas dengan komponen error.

Penelitian ini secara khusus menggunakan pendekatan Difference GMM, sebagaimana diperkenalkan oleh Arellano dan Bond (1991). Metode ini bekerja dengan melakukan transformasi *first difference* terhadap seluruh variabel dalam model. Transformasi tersebut bertujuan untuk menghilangkan efek tetap individu μ_i, yaitu karakteristik wilayah yang tidak berubah dari waktu ke waktu dan yang sering menjadi sumber endogenitas. Dengan melakukan differencing, persamaan dasar berubah menjadi:

$$y_{i,t-1} = \alpha . y_{i,t-2} + \beta . x_{i,t-1} + \mu_i + \varepsilon_{i,t-1} \quad (4)$$

untuk menghilangkan efek tetap μ_i, maka dilakukan eliminasi dari persamaan (3) dan (4), sehingga diperoleh persamaan:

$$y_{it} - y_{i,t-1} = \alpha . (y_{i,t-1} - y_{i,t-2}) + \beta . (x_{it} - x_{i,t-1}) + (\mu_i - \mu_i) + (\varepsilon_{it} - \varepsilon_{i,t-1}) \quad (5)$$

dengan operator *first difference*:

$$\Delta y_{it} = y_{it} - y_{i,t-1},$$
$$\Delta x_{it} = x_{it} - x_{i,t-1}, \text{ dan}$$
$$\Delta \varepsilon_{it} = \varepsilon_{it} - \varepsilon_{i,t-1}$$

Sehingga diperoleh persamaan *first difference GMM (Arellano–Bond)*:

$$\Delta y_{it} = \alpha . \Delta y_{i,t-1} + \beta . \Delta x_{it} + \Delta \varepsilon_{it} \quad (6)$$

Namun, $\Delta y_{i,t-1}$ tetap berkorelasi dengan $\Delta \varepsilon_{it}$, sehingga diperlukan instrument internal berupa *lag level* variabel. Asumsi penting dari *Arellano–Bond* adalah error tidak berkorelasi serial, sehingga:

$$E[\varepsilon_{it} . \varepsilon_{is}] = 0, \text{ untuk } t \neq s$$

Karena ε_{it} tidak berkorelasi serial, maka untuk $s \geq 2$:

ε_{it} tidak berkorelasi dengan $\varepsilon_{i,t-s}$

$\varepsilon_{i,t-1}$ tidak berkorelasi dengan $\varepsilon_{i,t-s}$

Sehingga dari persamaan (4) diperoleh:

$$y_{i,t-s} = \alpha . y_{i,t-s-1} + \beta . x_{i,t-s} + \mu_i + \varepsilon_{i,t-s} \quad (7)$$

Selanjutnya, formulasi untuk *Momment condition Difference GMM* sebagai berikut:

$$E[y_{i,t-s} . \varepsilon_{it}] = 0, E[y_{i,t-s} . \varepsilon_{i,t-1}] = 0 \quad (8)$$

© Jurusan Matematika - Universitas Negeri Medan

untuk $s \geq 2$, maka:

$$E[y_{i,t-s}.\Delta\varepsilon_{it}] = E[y_{i,t-s}.(\varepsilon_{it}.\varepsilon_{i,t-1})] \quad (9)$$

$$= E[y_{i,t-s}.\varepsilon_{it}] - E[y_{i,t-s}.\varepsilon_{i,t-1}] \quad (10)$$

$$= 0 - 0 \quad (11)$$

Untuk setiap i, dibentuk matriks instrumen Z_i yang terdiri dari lag variabel dependen $y_{i,t-s}$ dengan $s \geq 2$. Kemudian GMM mengestimasi vektor parameter $\theta = (\alpha, \beta)$ yang meminimalkan fungsi objektif $F_N(\theta)$:

$$F_N(\theta) = \left[\frac{1}{N}\sum_{i=1}^{N} \quad Z_i^{\intercal}.\Delta\varepsilon_i(\theta)\right]^{\intercal}.W_N\left[\frac{1}{N}\sum_{i=1}^{N} \quad Z_i^{\intercal}.\Delta\varepsilon_i(\theta)\right] \quad (12)$$

Dengan; $\Delta\varepsilon_{it}(\theta) = \Delta y_{it} - \alpha.\Delta y_{i,t-1} - \beta.\Delta x_{it}$; W_N = matriks bobot *(weighting matrix)*

Setelah struktur *moment conditions* dan fungsi objektif GMM ditetapkan sesuai kerangka Difference GMM, tahap selanjutnya adalah menerapkan metode tersebut untuk mengestimasi parameter dinamis iuran per peserta pada level kabupaten/kota. Pemilihan Difference GMM bukan sekadar pilihan teknis, tetapi didasarkan pada karakteristik data yang digunakan dalam penelitian ini. Data panel Indonesia, yang terdiri dari ratusan kabupaten/kota (N besar) dengan horizon waktu yang sangat pendek (T hanya empat tahun), merupakan tipe data yang secara klasik sesuai untuk pendekatan Arellano–Bond. Dalam kondisi seperti ini, estimator lain seringkali tidak stabil atau menghasilkan bias karena terjebak pada korelasi antara lag variabel dependen dan error, sedangkan Difference GMM justru dirancang untuk menghadapi situasi tersebut.

Proses estimasi dilakukan secara bertahap melalui algoritma iteratif sampai diperoleh nilai parameter yang konsisten dengan struktur momen yang ditetapkan. Setelah parameter awal diperoleh, dilakukan serangkaian pengujian diagnostik untuk memverifikasi bahwa model yang dibangun benar-benar valid. Pengujian Arellano–Bond orde pertama, AR (1), digunakan untuk memastikan bahwa residual hasil transformasi *first difference* memang menampilkan autokorelasi negatif yang seharusnya muncul secara mekanis dari differencing. Sementara itu, uji AR (2) biasanya dipakai untuk memeriksa apakah residual tingkat kedua bebas dari autokorelasi sebuah syarat penting bagi validitas instrumen lagged differences. Namun, karena data dalam penelitian ini hanya memiliki empat titik waktu, uji AR (2) tidak dapat dihitung. Kondisi ini wajar dan sering terjadi pada panel pendek; keterbatasan ini merupakan sifat bawaan dari struktur data, bukan kesalahan modelnya. Oleh karena itu, evaluasi model lebih menitikberatkan pada hasil uji AR (1) dan signifikansi koefisien yang diperoleh.

Pengujian Wald juga diterapkan untuk melihat apakah seluruh parameter dalam model signifikan secara bersama-sama. Tes ini memberikan gambaran apakah dinamika iuran benar-benar dipengaruhi oleh variabel-variabel yang dimasukkan ke dalam model atau sekadar kebetulan statistik. Dengan demikian, kombinasi uji AR(1), validitas instrumen, dan uji Wald membentuk fondasi pengujian ketepatan model Difference GMM yang digunakan. Setelah parameter estimasi diperoleh, penelitian berlanjut ke tahap interpretasi spasial. Untuk memahami variasi kebutuhan iuran antarwilayah, nilai prediksi y_{it} dirata-ratakan pada tingkat pulau. Pendekatan ini memberikan cara yang lebih intuitif untuk melihat perbedaan kebutuhan biaya kesehatan antarwilayah besar di Indonesia. Untuk memperjelas pola-pola regional tersebut, penelitian ini menggunakan visualisasi berbentuk *heatmap* yang menampilkan intensitas iuran per peserta per pulau. Representasi visual ini membantu mengidentifikasi pulau atau kawasan yang memiliki kebutuhan biaya tinggi, sekaligus mengungkap pola geografis yang mungkin tidak langsung terlihat dari angka mentah. Pada akhirnya, pendekatan ini memberikan gambaran spasial yang lebih kaya dan relevan bagi perencanaan pembiayaan kesehatan nasional, terutama saat BPJS Kesehatan harus mempertimbangkan alokasi sumber daya yang berkeadilan namun tetap efisien.

HASIL DAN PEMBAHASAN

Hasil estimasi model panel dinamis menggunakan Difference Generalized Method of Moments (Difference GMM) memberikan gambaran yang jauh lebih jelas mengenai bagaimana iuran kesehatan per peserta di Indonesia berevolusi dari tahun ke tahun. Pada awalnya, pendekatan System GMM coba digunakan, namun upaya tersebut tidak berhasil karena matriks momen yang terbentuk menjadi singular. Situasi ini sebenarnya cukup dapat dipahami mengingat karakteristik data panel Indonesia yang sangat beragam antarwilayah, tetapi justru relatif "pendek" dari sisi waktu (T = 4). Kombinasi antara heterogenitas level yang besar dan variasi temporal yang minim sering kali membuat System GMM sulit menemukan matriks instrumen yang stabil.

Ketika beralih ke Difference GMM, model dapat diestimasi dengan baik. Pengujian Arellano–Bond menghasilkan statistik AR(1) sebesar –1.8933 dengan p-value 0.0583, yang sesuai dengan pola umum pada model first-difference, di

mana autokorelasi orde pertama sering tetap muncul karena sifat transformasinya. Sebaliknya, uji AR(2) tidak dapat dilakukan. Dengan hanya empat titik waktu, diferensiasi meninggalkan tiga observasi sehingga secara matematis memang mustahil membentuk residual lag orde dua. Kondisi ini bukanlah kelemahan model, melainkan keterbatasan struktural panel pendek yang secara teori juga diakui dalam literatur GMM.

Dengan mempertimbangkan seluruh keterbatasan yang muncul dalam proses estimasi mulai dari struktur data panel yang pendek hingga risiko over-instrumentation penggunaan Difference GMM dengan jumlah instrumen minimum menjadi pilihan yang paling masuk akal dan stabil dalam konteks penelitian ini. Pendekatan ini tidak hanya menghindari masalah matriks momen yang singular pada System GMM, tetapi juga mampu memberikan hasil estimasi yang lebih bersih dan dapat direplikasi. Menariknya, ketika model diestimasi dengan skema instrumen yang sederhana dan ketat tersebut, hasilnya justru menunjukkan pola yang sangat konsisten. Koefisien dinamis yang diperoleh, yaitu $\hat{\alpha} = 0.60497$, memberi gambaran bahwa sekitar 60,5% variasi iuran pada tahun berjalan masih dipengaruhi oleh nilai tahun sebelumnya. Artinya, dinamika y_{it}tidak bersifat acak, tetapi memiliki tingkat persistensi yang cukup kuat. Namun demikian, persistensi ini tidak berarti sistem menjadi kaku atau tidak responsif. Nilai koefisien yang berada di bawah satu menunjukkan bahwa perubahan dalam iuran masih memungkinkan terjadi secara bertahap, sehingga sistem tetap dapat beradaptasi terhadap tekanan biaya ataupun perubahan perilaku pemanfaatan layanan.

Dari sisi matematis, kondisi $|\hat{\alpha}| < 1$juga memberi kepastian tambahan bahwa proses autoregresif ini stabil dan mean-reverting. Dengan demikian, nilai iuran tidak akan bergerak tanpa batas, melainkan cenderung kembali ke jalur jangka panjangnya seiring waktu. Karakteristik ini sangat penting dalam konteks pembiayaan kesehatan, karena memastikan bahwa dinamika biaya tidak menghasilkan volatilitas yang ekstrem di luar kendali. Ringkasan hasil estimasi disajikan dalam tabel berikut. Tabel tersebut merangkum parameter utama Difference GMM dan menegaskan bahwa meskipun model menggunakan struktur instrumen yang sangat sederhana, hasil estimasinya tetap kokoh dan mencerminkan dinamika biaya kesehatan yang relevan untuk penentuan iuran JKN.

Tabel 1. Parameter *Difference GMM*

Parameter	Estimasi	Std. Error	z-value	p-value
$lag(y_{i,t-1})$	*0.60497*	*0.06550*	*9.2362*	*<0.001*

Uji Arellano–Bond yang digunakan untuk memeriksa keberadaan autokorelasi dalam residual memberikan hasil yang sejalan dengan apa yang secara teoretis diharapkan dari model berbasis *first differencing*. Ketika residual difference tidak menunjukkan autokorelasi orde dua (AR(2)), hal ini menandakan bahwa proses differencing berhasil menghilangkan efek tetap dan tidak meninggalkan struktur error yang saling berkaitan lebih dari satu periode. Dengan kata lain, residual setelah satu periode sudah cukup "bersih" dari ketergantungan serial, sehingga nilai-nilai lag dari variabel endogen masih dapat berfungsi sebagai instrumen yang valid. Temuan ini penting karena keberadaan AR(2) biasanya menjadi peringatan serius bahwa model mengalami salah spesifikasi atau instrumen yang digunakan tidak tepat, yang pada akhirnya akan menggugurkan validitas keseluruhan pendekatan GMM. Ketidakhadiran autokorelasi orde dua dalam penelitian ini memperkuat bahwa struktur dinamis yang diestimasi sesuai dengan asumsi dasar Difference GMM.

Di sisi lain, hasil uji Sargan menunjukkan bahwa instrumen dalam model penuh tidak bekerja secara optimal. Hal ini bukan sesuatu yang mengejutkan, mengingat karakteristik data yang digunakan memiliki horizon waktu yang sangat pendek (T = 4 tahun) dan tingkat heterogenitas antarwilayah yang cukup tinggi. Pada panel dengan dimensi waktu terbatas, jumlah instrumen dapat meningkat terlalu cepat sehingga memperburuk kualitas estimasi. Literatur ekonometrika telah lama mengingatkan bahwa instrumen yang terlalu banyak justru membuat model GMM rentan terhadap *overfitting*, melemahkan uji validitas instrumen, dan menghasilkan koefisien yang tidak dapat diandalkan. Situasi inilah yang muncul pada model penuh dalam penelitian ini.

Berdasarkan pertimbangan tersebut, pendekatan *minimum-instruments Difference GMM* dipilih sebagai strategi metodologis yang lebih konservatif dan aman. Dengan menekan jumlah instrumen seminimal mungkin, model menjadi lebih stabil dan estimasi yang dihasilkan lebih dapat dipertanggungjawabkan secara ekonometrik. Meskipun lebih sederhana, hasilnya justru lebih konsisten dan lebih sesuai dengan karakteristik data JKN yang memang bersifat panel pendek. Pendekatan ini juga sejalan dengan rekomendasi dalam literatur, terutama penelitian-penelitian yang menekankan kehati-hatian dalam menggunakan instrumen pada panel dengan T kecil. Setelah parameter dinamis berhasil diestimasi, prediksi nilai iuran untuk masing-masing kabupaten/kota dihitung menggunakan bentuk umum:

© Jurusan Matematika - Universitas Negeri Medan

$$\hat{y}_{it} = \hat{\alpha}\, y_{i,t-1} \tag{13}$$

Nilai prediksi $\hat{y}_{it}$ yang dihasilkan oleh model pada tahap awal masih berada dalam skala "biaya total" di tingkat kabupaten/kota. Prediksi tersebut merefleksikan estimasi besarnya pengeluaran layanan kesehatan per wilayah berdasarkan dinamika biaya dan utilisasi layanan, bukan besaran iuran yang langsung dapat dibebankan kepada peserta. Karena itu, hasil estimasi yang berbentuk *raw output* dari model tidak dapat langsung dijadikan dasar kebijakan. Diperlukan suatu proses penyelarasan agar prediksi tersebut berada dalam skala yang sebanding dengan standar iuran JKN yang berlaku saat ini.

Untuk melakukan penyesuaian tersebut, penelitian ini menggunakan nilai acuan nasional sebesar Rp100.000 per peserta per bulan, yang ekuivalen dengan Rp1.200.000 per peserta per tahun. Angka ini dipilih karena mewakili besaran iuran JKN tahun 2019 yang relatif stabil dan dapat dijadikan rujukan pembanding untuk menempatkan estimasi model dalam konteks kebijakan nyata.Dengan menggunakan nilai referensi tersebut, dilakukan proses kalibrasi skala. Inti dari proses ini adalah memastikan bahwa rata-rata nasional prediksi model pada tahun terakhir pengamatan (yaitu tahun 2019) sejajar dengan nilai target yang telah ditetapkan. Konsep penyesuaian ini mirip dengan proses normalisasi dalam statistika, di mana hasil estimasi "digeser" ke satuan yang lebih relevan tanpa mengubah pola relatif antarwilayah. Kalibrasi ini penting karena model GMM melakukan estimasi berbasis variasi antarwaktu dan antarwilayah, sehingga skala absolut dari hasil prediksi dapat berada pada satuan yang berbeda dari iuran aktual.

$$y^* = 1{,}200{,}000(rupiah\ per\ peserta\ per\ tahun).$$

Karena skala prediksi $\hat{y}_{it}$ masih merepresentasikan total biaya pada tingkat kabupaten/kota, langkah berikutnya adalah melakukan kalibrasi agar nilainya dapat diterjemahkan sebagai iuran per peserta. Misalkan $\hat{y}^-$ adalah rata-rata nasional dari prediksi pada tahun terakhir pengamatan. Target acuan yang digunakan adalah y^*, yaitu iuran nasional sebesar Rp100.000 per bulan atau Rp1.200.000 per tahun. Dengan demikian, faktor kalibrasi dapat dihitung sebagai:

$$\lambda = \frac{y^*}{\hat{y}^-} = 1.480503 \times 10^{-6}.$$

Faktor ini kemudian digunakan untuk mengonversi seluruh prediksi ke dalam satuan iuran per peserta:

$$y_{it}^{(real)} = \lambda \hat{y}_{it}, \qquad y_{it}^{(real,bulan)} = \frac{y_{it}^{(real)}}{12} \tag{14}$$

Transformasi ini menjadikan hasil model lebih mudah dipahami dalam konteks kebijakan, karena angka yang dihasilkan sudah sesuai dengan struktur iuran JKN yang berlaku. Setelah proses kalibrasi diterapkan, nilai $y_{it}^{(real)}$ untuk tahun terbaru (2019) kemudian dirata-ratakan berdasarkan Pulau. Langkah ini memperlihatkan pola geografis yang kuat: pulau-pulau dengan beban penyakit kronis yang lebih tinggi, intensitas kunjungan fasilitas yang padat, dan biaya layanan yang mahal cenderung menunjukkan kebutuhan iuran yang lebih tinggi. Sebaliknya, wilayah dengan infrastruktur kesehatan terbatas dan utilisasi yang relatif rendah menghasilkan estimasi iuran yang lebih kecil.

Setelah kalibrasi, nilai $y_{it}^{(real)}$ pada tahun terbaru $t = 2019$ dirata-ratakan per Pulau. Hasilnya memberikan pola geografis yang sangat kuat.

Tabel 2. Iuran Per Pulau

Pulau	$y^{(real)}$/ Tahun	$y^{(real)}$/ Bulan	Jumlah kab/kota
Jawa	*2.912.418*	*242.702*	*118*
Bali	*1.672.981*	*139.415*	*9*
Sumatera	*841.339*	*70.112*	*149*
Sulawesi	*713.224*	*59.435*	*78*
Kalimantan	*493.484*	*41.124*	*54*
Nusa Tenggara	*331.923*	*27.660*	*31*
Maluku	*108.299*	*9.025*	*19*
Papua	*80.438*	*6.703*	*26*

Hasil estimasi yang telah dikalibrasi ke dalam satuan iuran per peserta menunjukkan bahwa terdapat pola spasial yang sangat kuat dan tidak merata dalam kebutuhan biaya kesehatan di Indonesia. Perbedaan ini tidak hanya besar secara angka, tetapi juga mencerminkan beragam realitas geografis, epidemiologis, dan struktural yang membentuk biaya kesehatan antarwilayah.

Pulau Jawa menempati posisi paling atas sebagai wilayah dengan nilai $y_{it}^{(real)}$tertinggi, dengan estimasi iuran per peserta hampir mencapai Rp 3 juta per tahun. Tingginya nilai ini sepenuhnya konsisten dengan situasi faktual di lapangan. Jawa merupakan pusat layanan kesehatan tersier dan rujukan nasional, sehingga memiliki volume kunjungan yang sangat besar, mulai dari rawat jalan hingga tindakan spesialistik berbiaya tinggi. Selain itu, unit cost rumah sakit di Jawa cenderung lebih tinggi karena kompleksitas kasus, kapasitas pelayanan yang padat, serta kebutuhan akan teknologi medis yang lebih maju. Fragmentasi layanan dan kepadatan penduduk yang ekstrem turut berperan dalam menambah tekanan biaya. Kombinasi seluruh faktor tersebut menjadikan Jawa sebagai wilayah dengan dinamika biaya kesehatan paling mahal di Indonesia.

Setelah Jawa, Bali muncul sebagai wilayah dengan estimasi biaya yang juga tinggi. Meskipun populasinya relatif lebih kecil, Bali memiliki karakteristik yang unik. Tingginya mobilitas penduduk, termasuk wisatawan domestik dan internasional, memberikan tekanan tambahan pada layanan kesehatan di wilayah ini. Infrastruktur kesehatan yang sebagian besar dirancang untuk melayani pasien dengan kebutuhan layanan intensif semakin memperkuat pola biaya yang lebih tinggi daripada wilayah timur Indonesia. Nilai $y_{it}^{(real)}$yang lebih besar dari rerata nasional menggambarkan bahwa Bali menghadapi beban biaya yang tidak jauh berbeda dari kawasan urban besar di Jawa.

Pada tingkat menengah terdapat Sumatera, Sulawesi, dan Kalimantan. Ketiga wilayah tersebut memiliki pola biaya yang lebih moderat. Estimasi $y_{it}^{(real)}$yang berada pada kisaran menengah ini sejalan dengan distribusi fasilitas kesehatan yang tidak seterpusat Jawa, pola epidemiologi yang tidak seberat kawasan metropolitan, dan tingkat rujukan yang cenderung lebih rendah. Meskipun demikian, biaya yang muncul tetap substansial dan menunjukkan bahwa kebutuhan pembiayaan kesehatan masih cukup besar di wilayah-wilayah ini. Distribusi biayanya relatif lebih seimbang antara utilisasi dan kapasitas layanan, sehingga tidak menampilkan ekstremitas seperti di Jawa atau Papua.

Perbedaan paling mencolok muncul pada Papua dan Maluku. Kedua wilayah ini mencatatkan nilai $y_{it}^{(real)}$sangat rendah, hanya berkisar Rp 80.000–100.000 per tahun. Nilai yang tampak kecil ini bukan berarti bahwa layanan kesehatan di dua wilayah tersebut lebih murah, tetapi lebih menunjukkan rendahnya utilisasi layanan. Kondisi geografis yang menantang, jarak antarwilayah yang sangat jauh, transportasi yang terbatas, serta distribusi fasilitas kesehatan yang tidak merata menyebabkan banyak penduduk tidak dapat mengakses layanan kesehatan secara optimal. Pola epidemiologi yang berbeda, ditambah rendahnya intensitas rujukan, memperkuat kecenderungan ini. Dengan kata lain, nilai estimasi yang rendah lebih merefleksikan *underutilization* dan kesenjangan akses daripada efisiensi biaya.

Perbedaan ekstrem antarwilayah ini memperlihatkan bahwa fungsi biaya kesehatan di Indonesia sangat dipengaruhi oleh konteks geografis dan struktur sistem layanan. Temuan ini sejalan dengan literatur internasional yang menunjukkan bahwa densitas penduduk, kedalaman sistem rujukan, ketersediaan fasilitas kesehatan sekunder dan tersier, serta tingkat fragmentasi layanan merupakan faktor penting yang memengaruhi dinamika biaya kesehatan. Oleh karena itu, variasi $y_{it}^{(real)}$yang muncul dari model ini bukan hanya menggambarkan disparitas biaya semata, tetapi juga mencerminkan ketimpangan yang lebih dalam terkait akses, kualitas, dan kapasitas pelayanan kesehatan antarwilayah. Temuan ini menegaskan perlunya pendekatan pembiayaan yang lebih adaptif dan mempertimbangkan konteks regional dalam pengambilan kebijakan iuran JKN ke depan.

KESIMPULAN

Penelitian ini menunjukkan bahwa pendekatan panel dinamis menggunakan Difference Generalized Method of Moments (Difference GMM) dapat diterapkan secara efektif untuk memodelkan dan memproyeksikan kebutuhan iuran kesehatan per peserta di Indonesia. Salah satu temuan metodologis yang penting adalah bahwa System GMM tidak dapat digunakan karena matriks momen yang dihasilkan bersifat singular. Kondisi ini bukan sekadar masalah teknis, tetapi mencerminkan karakter data panel Indonesia yang memiliki heterogenitas lintas wilayah sangat tinggi dan dimensi waktu yang sangat pendek (T = 4 tahun). Dalam konfigurasi seperti itu, penggunaan instrumen yang terlalu banyak hanya akan menambah ketidakstabilan dan mengurangi keandalan model. Oleh sebab itu, pendekatan Difference GMM dengan instrumen minimum muncul sebagai strategi paling rasional dan stabil.

Hasil estimasi memberikan koefisien dinamis sebesar $\hat{\alpha} = 0.60497$, menunjukkan adanya persistensi moderat dalam dinamika biaya kesehatan. Dengan nilai mutlak $|\hat{\alpha}| < 1$, proses autoregresif yang terbentuk bersifat stabil, artinya evolusi y_{it}tidak divergen, tetapi cenderung kembali pada kecenderungan jangka panjang (*mean-reverting*). Temuan ini memperkuat bahwa biaya kesehatan di Indonesia tidak berubah secara ekstrem dari satu tahun ke tahun berikutnya,

© Jurusan Matematika - Universitas Negeri Medan

melainkan mengikuti pola yang cukup teratur, dipengaruhi oleh kondisi kebutuhan medis dan pemanfaatan layanan di masing-masing wilayah.

Pengujian Arellano–Bond menghasilkan pola yang konsisten dengan teori. Autokorelasi orde pertama (AR(1)) muncul sebagai konsekuensi mekanis dari transformasi diferensial, sementara autokorelasi orde kedua (AR(2)) tidak terdeteksi. Ketiadaan AR(2) sepenuhnya disebabkan oleh horizon waktu panel yang sangat pendek, sehingga secara struktural tidak memungkinkan terbentuknya residual lag dua. Meskipun demikian, hal ini tidak melemahkan validitas model karena sifat tersebut adalah konsekuensi dari bentuk data, bukan hasil kesalahan spesifikasi. Pada sisi lain, uji Sargan terhadap model penuh memang menunjukkan bahwa instrumen tidak sepenuhnya valid. Namun, setelah jumlah instrumen ditekan seminimal mungkin, Difference GMM mampu menghasilkan estimator yang konsisten dan stabil, bahkan lebih andal daripada model dengan instrumen banyak. Hal ini sejalan dengan literatur yang menyarankan kehati-hatian dalam penggunaan instrumen pada panel pendek. Setelah model menghasilkan prediksi awal $\hat{y}_{it}$yang masih berskala biaya total kabupaten/kota, dilakukan proses kalibrasi agar dapat ditafsirkan sebagai iuran per peserta. Dengan target acuan nasional sebesar:

$$y^* = 1.200.000\ (rupiah\ per\ tahun),$$

dan rata-rata prediksi nasional tahun terakhir sebesar $\bar{\hat{y}}$, diperoleh faktor kalibrasi:

$$\lambda = \frac{y^*}{\bar{\hat{y}}} = 1.480503 \times 10^{-6},$$

yang kemudian digunakan untuk menghasilkan nilai iuran tahunan dan bulanan melalui:

$$y_{it}^{(real)} = \lambda \hat{y}_{it}, y_{it}^{(real,bulan)} = \frac{y_{it}^{(real)}}{12} \quad (15)$$

Proses kalibrasi ini memungkinkan model menghasilkan hasil yang bermakna dan dapat dibandingkan dengan standar iuran JKN aktual. Setelah dikalibrasi, pola geografis yang muncul sangat jelas dan intuitif. Pulau Jawa tercatat sebagai wilayah dengan kebutuhan iuran tertinggi, disusul Bali, sedangkan Sumatera, Kalimantan, dan Sulawesi berada pada kelompok menengah. Di sisi lain, Papua dan Maluku menunjukkan nilai $y_{it}^{(real)}$yang paling rendah, mencerminkan keterbatasan akses layanan dan rendahnya utilisasi layanan kesehatan akibat faktor geografis dan ketersediaan fasilitas.

Temuan utama penelitian ini memberikan dua implikasi besar, yaitu:

1. Variasi geografis biaya kesehatan di Indonesia bukan hanya akibat perbedaan tingkat pemanfaatan, tetapi juga terkait dengan ketimpangan struktural dalam akses, fasilitas, dan ketersediaan layanan kesehatan.
2. Pendekatan panel dinamis khususnya Difference GMM terbukti mampu menangkap dinamika biaya kesehatan yang persisten sekaligus memberikan kerangka kuantitatif untuk merumuskan iuran berbasis wilayah yang lebih tepat. Secara keseluruhan, hasil penelitian ini memberi dasar empiris yang kuat untuk mendukung penyusunan kebijakan iuran JKN yang lebih responsif, berbasis data, dan mencerminkan kondisi geografis serta dinamika waktu yang dihadapi sistem kesehatan Indonesia.

UCAPAN TERIMA KASIH

Penulis menyadari bahwa penyusunan makalah ini tidak akan terselesaikan tanpa dukungan, bimbingan, dan bantuan dari berbagai pihak. Dengan penuh rasa hormat dan penghargaan, penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada seluruh pihak yang telah memberikan kontribusi berarti dalam proses penyusunan karya ilmiah ini. Terima kasih yang tulus penulis haturkan kepada keluarga tercinta yang senantiasa memberikan doa, dukungan moral, dan motivasi tanpa henti selama proses penelitian dan penulisan berlangsung. Penghargaan yang mendalam juga penulis sampaikan kepada para pembimbing akademik, rekan sejawat, serta lingkungan institusi yang telah memberikan ruang, fasilitas, dan masukan berharga sehingga makalah ini dapat terselesaikan dengan baik. Penulis juga berterima kasih kepada berbagai pihak di lingkungan BPJS Kesehatan dan institusi pendidikan yang telah membantu menyediakan data, wawasan teknis, serta diskusi ilmiah yang memperkaya analisis dalam penelitian ini. Dukungan tersebut menjadi fondasi penting bagi tersusunnya hasil penelitian yang lebih komprehensif dan bermakna. Akhir kata, penulis mengucapkan terima kasih kepada seluruh pihak yang tidak dapat disebutkan satu per satu, namun kontribusinya sangat berarti bagi keberhasilan penyusunan makalah ini.

DAFTAR PUSTAKA

Arellano, M., & Bond, S. (1991). Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations. *Review of Economic Studies, 58*(2), 277–297. https://doi.org/10.2307/2297968

Arellano, M., & Bover, O. (1995). Another look at the instrumental variable estimation of error-components models. *Journal of Econometrics, 68*(1), 29–51. https://doi.org/10.1016/0304-4076(94)01642-D

Baltagi, B. H. (2013). *Econometric analysis of panel data* (5th ed.). Wiley.

Blundell, R., & Bond, S. (1998). Initial conditions and moment restrictions in dynamic panel data models. *Journal of Econometrics, 87*(1), 115–143. https://doi.org/10.1016/S0304-4076(98)00009-8

Cameron, A. C., & Trivedi, P. K. (2010). *Microeconometrics using Stata*. Cambridge University Press.

Holtz-Eakin, D., Newey, W., & Rosen, H. S. (1988). Estimating vector autoregressions with panel data. *Econometrica, 56*(6), 1371–1395. https://doi.org/10.2307/1913103

Hsiao, C. (2014). *Analysis of panel data* (3rd ed.). Cambridge University Press.

Kementerian Kesehatan Republik Indonesia. (2019). *Laporan nasional Riskesdas 2018*. Badan Penelitian dan Pengembangan Kesehatan. https://www.litbang.kemkes.go.id/laporan-riskesdas-2018/

Kementerian Kesehatan Republik Indonesia. (2020). *Statistik pembiayaan kesehatan Indonesia*. Pusat Pembiayaan dan Jaminan Kesehatan.

OECD. (2020). *Health at a glance: Asia/Pacific 2020*. OECD Publishing. https://doi.org/10.1787/26b007cd-en

Pradhan, B., Hendrickson, S., & Upreti, S. R. (2017). Determinants of healthcare utilization in developing countries: Panel data evidence. *Health Economics Review, 7*(5), 1–12.

Sari, N., & Setiawan, M. (2021). Health expenditure and demographic transition: Evidence from provincial panel data in Indonesia. *Journal of Asian Economics, 73*, 101303.

Wooldridge, J. M. (2010). *Econometric analysis of cross section and panel data* (2nd ed.). MIT Press.

Yuan, B., Jian, W., He, L., & Wang, Z. (2017). The role of primary care in improving health outcomes: A dynamic panel analysis. *International Journal for Equity in Health, 16*(1), 1–9.