


Perbandingan Propensity Score Stratification dan Propensity Score Matching dengan Pendekatan Multivariate Adaptive Regression Spline

Ingka Rizkyani Akolo, Setia Ningsih, dan Hendra Dukalang




Volume 6, Issue 2, Pages 152–159, August 2024

Diterima 19 Juni 2024, Direvisi 7 Juli 2024, Disetujui 10 Juli 2024, Diterbitkan 1 Agustus 2024

To Cite this Article : I. R. Akolo, S. Ningsih, dan H. Dukalang, "Perbandingan Propensity Score Stratification dan Propensity Score Matching dengan Pendekatan Multivariate Adaptive Regression Spline", *Jambura J. Math*, vol. 6, no. 2, pp. 152–159, 2024, <https://doi.org/10.37905/jjom.v6i2.26137>

© 2024 by author(s)

JOURNAL INFO • JAMBURA JOURNAL OF MATHEMATICS




	Homepage	:	http://ejurnal.ung.ac.id/index.php/jjom/index
	Journal Abbreviation	:	Jambura J. Math.
	Frequency	:	Biannual (February and August)
	Publication Language	:	English (preferable), Indonesia
	DOI	:	https://doi.org/10.37905/jjom
	Online ISSN	:	2656-1344
	Editor-in-Chief	:	Hasan S. Panigoro
	Publisher	:	Department of Mathematics, Universitas Negeri Gorontalo
	Country	:	Indonesia
	OAI Address	:	http://ejurnal.ung.ac.id/index.php/jjom/oai
	Google Scholar ID	:	iWLjgaUAAAAJ
	Email	:	info.jjom@ung.ac.id


JAMBURA JOURNAL • FIND OUR OTHER JOURNALS




Jambura Journal of Biomathematics



Jambura Journal of Mathematics Education



Jambura Journal of Probability and Statistics



EULER : Jurnal Ilmiah Matematika, Sains, dan Teknologi

Perbandingan *Propensity Score Stratification* dan *Propensity Score Matching* dengan Pendekatan *Multivariate Adaptive Regression Spline*

Ingka Rizkyani Akolo¹, Setia Ningsih^{2,*}, Hendra Dukalang³

¹Jurusan Pendidikan Guru Madrasah Ibtidaiyah, IAIN Sultan Amai Gorontalo, Gorontalo, Indonesia

²Program Studi Statistika, Universitas Negeri Gorontalo, Gorontalo, Indonesia

³Jurusan Perbankan Syariah, IAIN Sultan Amai Gorontalo, Gorontalo, Indonesia

ARTICLE HISTORY

Diterima 19 Juni 2024

Direvisi 7 Juli 2024

Disetujui 10 Juli 2024

Diterbitkan 1 Agustus 2024

KATA KUNCI

Propensity Score Stratification
Propensity Score Matching
MARS
Komplikasi DM

KEYWORDS

Propensity Score Stratification
Propensity Score Matching
MARS
DM Complications

ABSTRAK. Penelitian tentang komplikasi Diabetes Mellitus (DM) merupakan penelitian multifaktor dimana faktor resiko penyebab komplikasi DM saling berkorelasi sehingga menyebabkan munculnya bias confounding yang mengakibatkan hasil penelitian tidak akurat. Bias confounding dapat direduksi dengan metode propensity score. Penelitian ini bertujuan untuk membandingkan performa dari metode Propensity Score Stratification (PSS) dan Propensity Score Matching (PSM) dengan pendekatan Multivariate Adaptive Regression Spline (MARS) dalam mengestimasi efek perlakuan pada kasus komplikasi DM. Data yang digunakan adalah data rekam medis pasien DM tipe-2 di RS X. Hasil penelitian menunjukkan bahwa metode PSS dengan pendekatan MARS tidak cocok digunakan untuk data yang jumlahnya sedikit, karena dapat menyebabkan ada kelompok perlakuan ataupun kontrol yang tidak memiliki anggota sehingga *p*-value pada pengujian balance maupun Persen Bias Reduksi (PBR) tidak bisa dihitung. Hasil estimasi Average Treatment Effect (ATE) pada metode PSS adalah sebesar 0,340 dengan PBR sebesar 53,03%, sedangkan estimasi Average Treatment for Treated (ATT) pada metode PSM adalah sebesar 0,322 dengan PBR sebesar 87,83%. Nilai PBR ini menunjukkan bahwa metode terbaik untuk estimasi efek perlakuan dan mampu mereduksi bias terbesar pada kasus ini adalah metode PSM dengan MARS. Hasil analisis juga menunjukkan bahwa kadar Asam Urat Serum (AUS) berpengaruh signifikan terhadap status Neuropati Diabetik Perifer (NDP) pasien DM.

ABSTRACT. Research on complications of Diabetes Mellitus (DM) is multifactorial, where the risk factors causing DM complications are interrelated, leading to confounding bias, which results in inaccurate research findings. Confounding bias can be reduced using the propensity score method. This study aims to compare the performance of the Propensity Score Stratification (PSS) and Propensity Score Matching (PSM) methods with the Multivariate Adaptive Regression Spline (MARS) approach in estimating treatment effects on DM complication cases. The data used is the medical records of type-2 DM patients at Hospital X. The results showed that the PSS method with the MARS approach is not suitable for small data sets, as it can lead to treatment or control groups lacking members, making it impossible to calculate the *p*-value in balance testing or the Percent Bias Reduction (PBR). The estimated Average Treatment Effect (ATE) using the PSS method was 0.340 with a PBR of 53.03%, whereas the estimated Average Treatment for Treated (ATT) using the PSM method was 0.322 with a PBR of 87.83%. These PBR values indicate that the best method for estimating treatment effects and the one that can reduce the most bias in this case is the PSM method with MARS. The analysis also showed that serum uric acid levels significantly affect the peripheral diabetic neuropathy (PDN) status of DM patients.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. *Editorial of JJoM:* Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

1. Pendahuluan

Diabetes mellitus (DM) tipe 2 merupakan penyakit tidak menular yang semakin meningkat dalam beberapa tahun terakhir. Berdasarkan data *International Diabetes Federation* (IDF), penderita diabetes mellitus tipe-2 di Indonesia pada tahun 2021 mencapai 19 juta jiwa dan diproyeksikan pada tahun 2045 akan meningkat menjadi 28 juta jiwa [1]. Peningkatan prevalensi diabetes mellitus ini turut meningkatkan kejadian komplikasi diabetes me-

llitus seperti neuropati diabetik atau bahkan kematian. Peningkatan jumlah penderita diabetes mellitus yang cukup signifikan setiap tahunnya tentunya membutuhkan perhatian yang khusus dari pemerintah. Oleh karena itu, perlu dipelajari lebih mendalam tentang faktor resiko dari diabetes mellitus khususnya komplikasinya untuk menurunkan prevalensi komplikasi diabetes mellitus.

Penelitian tentang komplikasi diabetes mellitus merupakan penelitian multifaktor dimana faktor resiko penyebab komplika-

*Penulis Korespondensi.

sinya saling berkorelasi sehingga menyebabkan muncul bias *confounding* dalam penelitian [2]. *Confounding* merupakan faktor perancu yang mengganggu dugaan pengaruh faktor resiko dengan suatu penyakit [3]. Bias *confounding* ini ditimbulkan dari faktor yang saling berkorelasi sehingga mempengaruhi akurasi kesimpulan hasil studi [4]. Salah satu metode yang dapat mereduksi bias *confounding* adalah metode *Propensity Score* (PS). Metode PS merupakan peluang bersyarat untuk menerima perlakuan berdasarkan karakteristik yang diamati sebelumnya [5]. Ada beberapa jenis metode PS, yakni *Propensity Score Stratification* (PSS), *Propensity Score Matching* (PSM), dan *Propensity Score Weighting* (PSW).

Penelitian tentang PS pada kasus DM sudah banyak dilakukan sebelumnya, seperti Ernawati, dkk [2] yang menggunakan PSS dengan *Support Vector Machine* dan diperoleh 4 strata memberikan persen reduksi terbesar yakni 86,39%, Faulina, dkk [3] menggunakan PSM dengan regresi logistik dan bias yang mampu direduksi sebesar 57,10%, Adityaningrum [6] menggunakan PSM dengan MARS namun tidak dijelaskan persentase reduksi biasanya, serta Wahyuni [7] menggunakan PSS dengan MARS dan bias yang mampu direduksi adalah kurang dari 25%. Pada penelitian Wahyuni [7] pembagian strata hanya sampai 2 strata, padahal untuk PSS semakin banyak strata yang dibuat, semakin besar bias yang mampu direduksi [5]. Penelitian tersebut menunjukkan bahwa belum ada penelitian DM yang membandingkan metode PS. Padahal perbandingan antar metode PS dapat menunjukkan seberapa baik metode tersebut dalam mereduksi bias *confounding* pada kasus DM.

Oleh karena itu, pada penelitian ini digunakan 2 metode PS yakni metode *Propensity Score Stratification* (PSS) dan *Propensity Score Matching* (PSM) dengan pendekatan *Multivariate Adaptive Regression Spline* (MARS) untuk mengestimasi efek perlakuan dan mereduksi bias *confounding* dalam penelitian komplikasi DM. Penelitian tentang PSS dengan MARS sebenarnya sudah dilakukan oleh Wahyuni [7] akan tetapi tidak dilakukan analisis lebih jauh dan hanya terbatas pada 2 strata saja, sedangkan penelitian tentang PSM dengan MARS sudah dilakukan oleh Adityaningrum [6] tapi tidak dijelaskan persen reduksi biasanya. Oleh karena itu dalam penelitian ini, kedua metode tersebut dibandingkan performa dan dianalisis lebih jauh terkait bias yang mampu direduksi oleh metode PSS dan PSM. Metode PSS dipilih karena mudah digunakan, mudah diinterpretasikan serta efisien seperti halnya *matching* [8]. Metode PSM dipilih karena mempunyai kinerja bagus dalam menduga marjinal *odds ratio* [9]. Metode PSM juga dapat menyesuaikan dengan berbagai model regresi sehingga bisa digunakan bersamaan dengan model regresi lainnya [10]. MARS dipilih karena model ini dapat digunakan pada data non linier dan data berdimensi tinggi [11].

Berdasarkan uraian di atas, penelitian tentang komplikasi DM sangat penting untuk mencegah peningkatan prevalensinya. Untuk mereduksi bias yang muncul pada penelitian ini digunakan metode *Propensity Score Stratification* (PSS) dan *Propensity Score Matching* (PSM) dengan pendekatan model MARS. Tujuan penelitian ini adalah untuk membandingkan performa dari dua metode *propensity score* untuk estimasi efek perlakuan pada kasus komplikasi DM. Perbandingan ini dapat menjadi referensi untuk penelitian selanjutnya ketika menggunakan metode PS dengan pendekatan model MARS.

2. Metode

2.1. Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini merupakan data rekam media pasien DM tipe-2 yang dirawat di RS X tahun 2014. Jumlah responden sebanyak 73 pasien. Adapun variabel penelitian yang digunakan yakni Komplikasi *Neuropathy Diabetik Perifer* (NDP) sebagai variabel respon, dan 6 variabel prediktor yakni jenis kelamin (X_1), status hipertensi (X_2), lama DM (X_3), status obesitas (X_4), status kadar HbA1C (X_5) dan status kadar Asam Urat Serum atau kadar AUS (X_6).

2.2. Tahapan Penelitian

Tahapan dalam penelitian ini diuraikan sebagai berikut.

1. Analisis deskriptif data penelitian.
2. Menentukan variabel *confounding* berdasarkan teori dan pengujian.
3. Estimasi nilai *propensity score* menggunakan model *multivariate adaptive regression spline* biner dan menghitung ketepatan klasifikasi model.
4. Analisis *propensity score stratification* berdasarkan nilai *propensity* yang diperoleh pada tahap 3.
 - (a) Mengelompokkan data menjadi 2-5 strata berdasarkan nilai *propensity score*.
 - (b) Menguji *balance* kovariat data.
 - (c) Menghitung nilai estimasi *Average Treatment Effect* (ATE).
 - (d) Menghitung standar *error* ATE.
 - (e) Menghitung nilai Persen Reduksi Bias (PBR) masing-masing strata.
 - (f) Pemilihan strata terbaik.
5. Analisis *Propensity Score Matching* berdasarkan nilai *propensity* yang diperoleh pada tahap 3.
 - (a) Melakukan *matching* data antara kelompok perlakuan dan control berdasarkan nilai *propensity score*. Data yang tidak berpasangan, tidak masuk dalam analisis.
 - (b) Menguji *balance* kovariat data.
 - (c) Menghitung nilai estimasi *Average Treatment for Treated* (ATT)
 - (d) Menghitung standar *error* ATT.
 - (e) Menghitung nilai Persen Reduksi Bias (PBR).
6. Membandingkan nilai PBR dari *propensity score stratification* dengan *Propensity Score Matching* dan memilih model terbaik.
7. Memodelkan hubungan X dan Y.

2.3. Penentuan *Confounding* dalam Analisis *Propensity Score*

Faktor *confounding* adalah faktor yang mengganggu taksiran pengaruh antara paparan (*exposure*) dengan kejadian penyakit (*outcome*) [12]. *Confounding* dapat membuat kesimpulan hasil studi menjadi bias atau tidak akurat. Kriteria *confounding* yakni merupakan penyebab dari suatu penyakit dan punya hubungan dengan variabel *exposure* lainnya. Pemilihan *confounding* dapat pula didasarkan dari penelitian sebelumnya (teori) yang kemudian dibuktikan melalui pengujian empiris menggunakan uji dependensi dengan statistik uji yakni uji *chi-square*.

2.4. *Multivariate Adaptive Regression Spline* (MARS) Respon Biner

Multivariate Adaptive Regression Spline (MARS) merupakan pengembangan dari metode RPR dengan menggunakan prinsip

spline [11]. Model ini sangat cocok digunakan untuk data yang berdimensi tinggi ataupun data yang mempunyai variabel yang banyak [13]. Dalam model MARS, terdapat tiga hal penting yang perlu diketahui yakni 1) jumlah maksimal dari Basis Fungsi (BF) adalah 2 sampai 4 kali jumlah prediktor; 2) jumlah Maksimum Interaksi (MI) dalam model adalah 1, 2, 3; serta 3) Minimum Observasi (MO) adalah 0, 1, 2, dan 3. Jika memilih diatas kriteria ini, biasanya nilai GCV akan meningkat [6]. Adapun model MARS respon biner sebagai berikut.

$$\ln \left[\frac{\pi(x)}{1 - \pi(x)} \right] = a_0 + \sum_{m=1}^M a_m \prod_{k=1}^{K_m} [s_{km}(x_{v(k,m)} - t_{km})], \quad (1)$$

dimana a_0 adalah konstanta dan $\pi(x)$ adalah probabilitas sukses. Model MARS dipilih berdasarkan nilai minimum dari GCV. Formulasi GCV yang digunakan dituliskan sebagai berikut:

$$GCV(M) = \frac{\frac{1}{N} \sum_{i=1}^N [y_i - \hat{f}_M(x_i)]^2}{\left[\frac{1 - \hat{C}(M)}{N} \right]^2}, \quad (2)$$

dengan N merupakan banyak data, M merupakan banyak fungsi basis, $\hat{C}(M)$ merupakan jumlah dari C(M) dan dM. C(M) merupakan Trace $(\mathbf{B}(\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T) + 1$, dan d adalah nilai saat fungsi basis mencapai nilai optimal ($2 \leq d \leq 4$) [13].

MARS biner biasanya digunakan untuk klasifikasi. Untuk mengetahui ketepatan klasifikasi model, dapat dihitung dari nilai Total Accuracy Rate (TAR) menggunakan formulasi berikut.

$$TAR = \left(1 - \frac{n_{10} + n_{01}}{n} \right) \times 100\%, \quad (3)$$

dengan n = jumlah observasi, n_{10} = jumlah observasi y_1 yang salah diklasifikasikan sebagai y_0 , n_{01} = jumlah observasi y_0 yang salah diklasifikasikan sebagai y_1 [7].

2.5. Propensity Score Stratification (PSS)

Propensity Score Stratification (PSS) merupakan salah satu metode statistika yang mampu mengurangi bias *confounding*. PSS juga merupakan analisis yang mengelompokkan data menjadi beberapa strata berdasarkan urutan nilai *propensity score* [5]. Pembentukan strata ini dimaksudkan untuk mendapatkan strata yang memenuhi asumsi (syarat) *balance*, yakni tidak ada perbedaan antara kelompok perlakuan dan kelompok kontrol [7].

2.6. Propensity Score Matching (PSM)

Propensity Score Matching (PSM) merupakan analisis yang digunakan untuk menyeimbangkan data antara kelompok kontrol dan perlakuan dengan cara mencocokkan datanya berdasarkan nilai *propensity*. Pada PSM data yang tidak punya pasangan tidak akan diikutsertakan dalam analisis. Ada beberapa metode analisis *matching* yang digunakan dalam PSM yakni *nearest neighbor matching* [14], *caliper* atau *full matching* [15].

2.7. Uji Balance Kovariat

Balance kovariat merupakan syarat yang harus dipenuhi sebelum estimasi efek perlakuan. Balance kovariat berarti tidak ada

perbedaan antara kelompok perlakuan dan kontrol. Pada PSS *balance* kovariat harus dipenuhi pada semua strata. Apabila ada strata yang tidak *balance*, maka strata tersebut tidak dipilih [5]. Pada PSM *balance* kovariat setelah *matching* harus dipenuhi. Kovariat yang tidak *balance* maka harus dikeluarkan dari analisis. Pengujian *balance* kovariat untuk data kontinu menggunakan uji t dua sampel bebas, sedangkan data kategori menggunakan uji z [6].

2.8. Estimasi nilai Average Treatment Effect (ATE), Average Treatment for Treated (ATT) dan Standar Errornya

Efek perlakuan dapat diketahui ketika syarat *balance* sudah terpenuhi. Menurut Tu & Zhou dalam Akolo, dkk [5], efek perlakuan (ATE) dan standar errornya pada analisis PSS dihitung dengan formulasi berikut.

$$\hat{\theta}_{ATE} = \sum_{k=1}^K \frac{n_{tk} + n_{ck}}{n_t + n_c} (\hat{Y}_{tk} - \hat{Y}_{ck}), \quad (4)$$

$$SE(\hat{\theta}_{ATE}) = \sqrt{\sum_{k=1}^K \left(\frac{n_{tk} + n_{ck}}{n_t + n_c} \right) \left(\frac{s_{tk}^2}{n_{tk}} + \frac{s_{ck}^2}{n_{ck}} \right)}, \quad (5)$$

dengan

$$\hat{p}_{tk} = \sum_{i=1}^{N_{tk}} \frac{Y_{tki}}{N_{tk}}; \quad \hat{p}_{ck} = \sum_{i=1}^{N_{ck}} \frac{Y_{cki}}{N_{ck}}; \quad n_t = \sum_{k=1}^K n_{tk}; \quad n_c = \sum_{k=1}^K n_{ck}, \quad (6)$$

$\hat{\theta}_{ATE}$ merupakan rata-rata efek perlakuan (ATE), $SE(\hat{\theta})$ merupakan standar error ATE, n_{tk} dan n_{ck} jumlah subjek kelompok perlakuan dan kontrol kelas ke-k, Y_{tk} dan Y_{ck} adalah respon kelompok perlakuan dan kontrol kelas ke-k, \hat{p}_{tk} dan \hat{p}_{ck} adalah proporsi respon kelompok perlakuan dan kontrol kelas ke-k, s_{tk}^2 dan s_{ck}^2 adalah varians respon kelompok perlakuan dan kontrol kelas ke-k, $k = 1, \dots, K$.

Untuk *Propensity Score Matching*, dihitung *Average Treatment for Treated* (ATT) dan standar errornya dengan formulasi berikut.

$$\hat{\theta}_{ATT} = \left(\frac{1}{n_t} \sum_{i \in t} Y_{ti} - \frac{1}{n_c} \sum_{i \in c} Y_{ci} \right), \quad (7)$$

$$SE(\hat{\theta}_{ATT}) = \sqrt{\frac{(n_t - 1) s_t^2 + (n_c - 1) s_c^2}{n_t + n_c - 2} \left(\frac{1}{n_t} + \frac{1}{n_c} \right)}, \quad (8)$$

$\hat{\theta}_{ATT}$ merupakan ATT, $SE(\hat{\theta}_{ATT})$ merupakan standar error ATT, n_t dan n_c jumlah subjek kelompok perlakuan dan kontrol, Y_t respon kelompok perlakuan, Y_c respon kelompok kontrol k, s_t^2 dan s_c^2 adalah varians respon untuk kelompok perlakuan dan kontrol.

2.9. Persen Bias Reduksi (PBR)

Metode *propensity score* dikategorikan baik apabila besar bias yang mampu direduksi oleh metode tersebut cukup besar. Semakin besar bias yang mampu direduksi, maka metodenya semakin baik. Oleh karena itu, dalam analisis propensity score perlu dihitung Persen Bias Reduksi (PBR). Formulasi rumus yang digunakan untuk mengukur PBR dalam PSS [5] adalah sebagai berikut.

$$PBR = \frac{B_{\text{before PS}} - B_{\text{after PS}}}{B_{\text{before PS}}} \times 100\% \quad (9)$$

dan

$$B = p_1(x_p) - p_0(x_p) \tag{10}$$

$$B_{after\ PPS} = \sum_{k=1}^K B_k \tag{11}$$

dengan PBR merupakan *Percent Bias Reduction*, B merupakan selisih rata-rata dari kelompok perlakuan dan kelompok kontrol untuk setiap kovariat, $p_1(x_p)$ dan $p_0(x_p)$ merupakan proporsi atau rata-rata kovariat untuk kelompok perlakuan dan kelompok kontrol, $B_{before\ PS}$ dan $B_{after\ PS}$ merupakan selisih rata-rata kelompok perlakuan dan kontrol sebelum dilakukan *propensity score* dan setelah dilakukan *propensity score*.

Formulasi rumus yang digunakan mengukur PBR dalam PSM sebagai berikut.

$$B_{matching} = M_t(x_p) - M_c(x_p) \tag{12}$$

$$PBR = \frac{B_{before\ matching} - B_{after\ matching}}{B_{before\ matching}} \times 100\% \tag{13}$$

dengan PBR merupakan *Percent Bias Reduction*, $B_{matching}$ merupakan selisih rata-rata dari kelompok perlakuan dan kelompok kontrol untuk setiap kovariat, $p_1(x_p)$ dan $p_0(x_p)$ merupakan proporsi atau rata-rata kovariat untuk kelompok perlakuan dan kelompok kontrol.

3. Hasil dan Pembahasan

3.1. Deskripsi Data Penelitian

Deskripsi data penelitian dilakukan untuk eksplorasi data sehingga diperoleh gambaran umum data pasien yang menjadi subjek penelitian. Data penelitian terdiri atas 6 variabel (data kategori) dan 1 variabel (data kontinu). Deskripsi data kategori disajikan pada [Tabel 1](#).

Tabel 1. Deskripsi data

Kovariat (X)	Status NDP		Total (%)
	Tidak Ada	Ada	
Jenis Kelamin (X_1)			
Laki-Laki	9	29	52,10%
Perempuan	15	20	47,90%
Hipertensi (X_2)			
Tidak	19	14	45,20%
Ya	5	35	54,80%
Obesitas (X_4)			
Tidak	14	17	42,50%
Ya	10	32	57,50%
Kadar HbA1C (X_5)			
Rendah	13	16	39,70%
Tinggi	11	33	60,30%
Kadar AUS (X_6)			
Rendah	20	12	43,80%
Tinggi	4	37	56,20%
Total (%)	32,90%	67,10%	

Berdasarkan [Tabel 1](#) diketahui sebagian besar pasien adalah laki-laki, memiliki hipertensi, obesitas, kadar HbA1C dan kadar AUS tinggi. Hal ini dapat dilihat dari persentase total masing-masing kovariat yang lebih dari 50%. Dari [Tabel 1](#) juga diketahui bahwa persentase total pasien yang memiliki NDP lebih banyak dari yang tidak NDP, hal ini menunjukkan bahwa pasien yang diteliti sebagian besar terkena NDP.

3.2. Penentuan Variabel Confounding

Analisis *propensity score* diawali dengan penentuan variabel *confounding*. Berdasarkan penelitian Akolo, dkk [5] variabel yang berpotensi menjadi variabel *confounding* yakni kadar AUS (X_6). Oleh karena itu dilakukan pengujian secara empiris menggunakan uji *chi-square* untuk data kategori. Hasil pengujian disajikan pada [Tabel 2](#).

Tabel 2. Hasil Uji dependensi kovariat X menggunakan uji chi-square

Variabel	χ^2	df	P-value	Keputusan
$X_1 * X_6$	4,836	1	0,028	Tolak H_0
$X_2 * X_6$	16,360	1	0,000	Tolak H_0
$X_4 * X_6$	0,453	1	0,501	Gagal tolak H_0
$X_5 * X_6$	0,453	1	0,501	Gagal tolak H_0
$Y * X_6$	22,657	1	0,000	Tolak H_0

[Tabel 2](#) memberikan informasi bahwa ada dua kovariat yang berpengaruh signifikan terhadap status kadar AUS (X_6) yakni variabel jenis kelamin (X_1) dan status hipertensi (X_2). Variabel kadar AUS juga berpengaruh signifikan terhadap status NDP (Y). Dengan demikian, kadar AUS (X_6) dipilih sebagai variabel *confounding* (Z).

3.3. Estimasi Nilai Propensity Score dengan Model MARS Biner

3.3.1. Estimasi Nilai Propensity Score dengan Model MARS terbaik

Nilai *propensity score* pada penelitian ini diestimasi menggunakan model MARS biner. Sebelum dilakukan estimasi parameter, terlebih dahulu dipilih model MARS terbaik berdasarkan nilai GCV. Pemodelan dilakukan antara variabel kovariat X_1, X_2, X_3, X_4 dan X_5 dengan variabel *confounding* ($Z = X_6$). Hasil *trial* dan *error* untuk pemilihan model MARS disajikan pada [Tabel 3](#).

Tabel 3. Pemilihan model MARS biner

Model	Kombinasi			GCV	Model	Kombinasi			GCV
	BF	MI	MO			BF	MI	MO	
1	10	1	0	0,174	19	15	2	2	0,144
2	10	1	1	0,170	20	15	2	3	0,150
3	10	1	2	0,208	21	15	3	0	0,170
4	10	1	3	0,174	22	15	3	1	0,120
5	10	2	0	0,166	23	15	3	2	0,126
6	10	2	1	0,162	24	15	3	3	0,129
7	10	2	2	0,163	25	20	1	0	0,170
8	10	2	3	0,166	26	20	1	1	0,143
9	10	3	0	0,162	27	20	1	2	0,145
10	10	3	1	0,162	28	20	1	3	0,155
11	10	3	2	0,163	29	20	2	0	0,133
12	10	3	3	0,166	30	20	2	1	0,128
13	15	1	0	0,170	31	20	2	2	0,131
14	15	1	1	0,150	32	20	2	3	0,133
15	15	1	2	0,152	33	20	3	0	0,123
16	15	1	3	0,166	34	20	3	1	0,105*
17	15	2	0	0,151	35	20	3	2	0,108
18	15	2	1	0,142	36	20	3	3	0,112

[Tabel 3](#) memberikan informasi bahwa GCV terkecil ada pada model ke-34 yakni model MARS dengan BF = 20, MI = 3 dan MO = 1. Dari Model yang terpilih, dapat dibentuk model MARS

sebagai berikut.

$$\begin{aligned}
 Z = & 6,212 + 0,704X_{2,1} - 0,979 \max(0, X_3 - 3) \\
 & + 0,641 \max(0, X_3 - 3, 5) - 0,380 \max(0, 18 - X_3) \\
 & - 0,133 \max(0, X_3 - 18) - 0,060X_{1,1}X_{2,1} \\
 & + 0,869X_{1,1} (\max(0, X_3 - 18)) \\
 & - 0,032X_{2,1} (\max(0, X_3 - 2)) \\
 & - 1,294X_{2,1} (\max(0, 2 - X_3)) \\
 & - 0,846X_{1,1}X_{2,1}X_{5,1} \\
 & + 0,012X_{1,1}X_{2,1} (\max(0, X_3 - 6)) \\
 & + 0,195X_{1,1}X_{2,1} (\max(0, 6 - X_3)).
 \end{aligned}
 \tag{14}$$

Interpretasi model MARS biner pada [Persamaan \(14\)](#) adalah sebagai berikut.

- $BF1 = 0,704X_{2,1}$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien dengan hipertensi adalah sebesar $e^{0,704} = 2,021$ kali dibandingkan pasien yang tidak hipertensi.
- $BF2 = -0,979 \max(0, X_3 - 3)$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien yang lama DM lebih dari 3 tahun adalah $e^{-0,979} = 0,376$ kali dibandingkan pada pasien yang lama DM kurang dari 3 tahun.
- $BF3 = 0,641 \max(0, X_3 - 3, 5)$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien yang lama DM lebih dari 3,5 tahun adalah $e^{0,641} = 1,898$ kali dibandingkan pada pasien yang lama DM kurang dari 3,5 tahun.
- $BF4 = -0,380 \max(0, 18 - X_3)$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien yang lama DM kurang dari 18 tahun adalah $e^{-0,380} = 0,684$ kali kecil dibandingkan pada pasien yang lama DM lebih dari 18 tahun.
- $BF5 = -0,133 \max(0, X_3 - 18)$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien yang lama DM lebih dari 18 tahun adalah $e^{-0,133} = 0,875$ kali dibandingkan pada pasien yang lama DM kurang dari 18 tahun.
- $BF6 = -0,060X_{1,1}X_{2,1}$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien perempuan yang mengalami hipertensi adalah $e^{-0,060} = 0,942$ kali dibandingkan pada pasien laki-laki yang tidak hipertensi.
- $BF7 = 0,869 X_{1,1} \max(0, X_3 - 18)$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien perempuan yang lama DM lebih dari 18 tahun adalah $e^{0,869} = 2,384$ kali dibandingkan pada pasien laki-laki yang lama DM kurang dari 18 tahun.
- $BF8 = -0,032X_{2,1} \max(0, X_3 - 2)$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien hipertensi yang lama DM lebih dari 2 tahun adalah $e^{-0,032} = 0,968$ kali dibandingkan pada pasien tidak hipertensi yang lama DM kurang dari 2 tahun.
- $BF9 = -1,294X_{2,1} \max(0, 2 - X_3)$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien hipertensi yang lama DM kurang dari 2 tahun adalah $e^{-1,294} = 0,274$ kali dibandingkan pada pasien tidak hipertensi yang lama DM lebih dari 2 tahun.
- $BF10 = -0,846X_{1,1}X_{2,1}X_{5,1}$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien perempuan yang hipertensi dan kadar HbA1C tinggi adalah $e^{-0,846} = 0,429$

kali dibandingkan pada pasien laki-laki yang tidak hipertensi dan kadar HbA1C rendah.

- $BF11 = 0,012X_{1,1}X_{2,1} \max(0, X_3 - 6)$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien perempuan, yang hipertensi dan lama DM lebih dari 6 tahun adalah $e^{0,012} = 1,012$ kali dibandingkan pada pasien laki-laki yang tidak hipertensi dan lama DM kurang dari 6 tahun.
- $BF12 = 0,195X_{1,1}X_{2,1} \max(0, 6 - X_3)$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien perempuan, yang hipertensi dan lama DM kurang dari 6 tahun adalah $e^{0,195} = 1,215$ kali dibandingkan pada pasien laki-laki yang tidak hipertensi dan lama DM lebih dari 6 tahun

Berdasarkan model MARS pada [Persamaan \(14\)](#), dapat diperoleh nilai propensity score sebagai berikut.

$$e(x_i) = \frac{\exp(Z)}{1 + \exp(Z)} \tag{15}$$

dengan Z merupakan model [Persamaan \(14\)](#).

3.3.2. Akurasi Klasifikasi Model MARS

Untuk menghitung akurasi dari klasifikasi model MARS, terlebih dahulu dibuat tabel klasifikasinya. Setelah dibuat tabel, selanjutnya dapat dihitung nilai TAR dari model MARS biner. Hasil klasifikasi disajikan pada [Tabel 4](#).

Tabel 4. Klasifikasi menggunakan model MARS

Data Aktual (Z)	Data Prediksi (Z)		Total
	Rendah (0)	Tinggi (1)	
Rendah (0)	27	6	34
Tinggi (1)	5	35	39

Dari [Tabel 4](#) diketahui nilai $n_{10} = 5$ dan $n_{01} = 6$, dengan menggunakan [Persamaan \(3\)](#) dihitung nilai TAR dari model MARS sebagai berikut.

$$\begin{aligned}
 TAR &= \left(1 - \frac{5+6}{73}\right) x 100\% \\
 TAR &= \left(1 - (0,1507)\right) x 100\% \\
 TAR &= 84,93\%.
 \end{aligned}$$

Nilai TAR sebesar 84,93% mengindikasikan bahwa model MARS mampu memprediksi data aktual dengan tepat sebesar 84,39 %.

3.4. Analisis Propensity Score Stratification

Setelah nilai propensity score diperoleh, maka tahapan selanjutnya adalah mengelompokkan data menjadi beberapa strata. Pada penelitian ini data dikelompokkan menjadi 2 – 5 strata. Setelah strata dibentuk, tahapan selanjutnya adalah pengujian balance kovariat menggunakan uji t dua sampel bebas untuk variabel lama DM (X_3) dan uji z dua sampel untuk variabel lainnya. Hasil pengujian balance kovariat disajikan pada [Tabel 5](#).

Berdasarkan [Tabel 5](#) diketahui bahwa hanya 2 strata yang memenuhi asumsi *balance* kovariat. Hal ini dapat dilihat dari p-value untuk 2 strata yang lebih dari α (5%). Untuk strata 3, terdapat satu kovariat yang tidak *balance*, yakni kovariat X_2 pada strata ke-2 dimana p-value kurang dari α (5%). Pada 3 strata juga terdapat nilai NA (*Not Available*), yang menunjukkan bahwa ada strata yang salah satu kelompok perlakuan atau kontrol tidak mempunyai anggota, sehingga nilai p-value tidak bisa dihitung. Untuk

Tabel 5. Pengujian balance kovariat

n-strata	Strata ke-	p-value uji z				p-value uji t
		X ₁	X ₂	X ₄	X ₅	
Sebelum strata		0,028	0,635	0,501	0,731	0,010
2	1	0,874	0,123	0,931	0,538	0,434
	2	0,913	0,102	0,201	0,836	0,786
3	1	0,215	0,264	0,636	0,960	0,919
	2	0,752	0,011	0,968	0,752	0,699
4	3	0,394	NA	0,343	0,703	0,123
	1	0,215	0,264	0,636	0,960	0,919
5	2	0,303	NA	0,740	0,740	0,782
	3	0,764	0,364	0,259	0,943	0,393
5	4	NA	NA	NA	NA	NA
	1	NA	NA	NA	NA	NA
5	2	0,494	NA	0,180	1,000	0,906
	3	0,214	0,125	0,387	0,125	0,920
5	4	0,425	NA	0,533	0,649	0,850
	5	NA	NA	NA	NA	NA

4 strata dan 5 strata, semua nilai p-value lebih dari α (5%), akan tetapi banyak strata yang p-value = NA, sehingga tidak dapat diketahui secara pasti *balance* kovariat terpenuhi atau tidak. Oleh karena itu, hanya 2 dan 3 strata yang dianalisis pada tahap selanjutnya.

Langkah selanjutnya adalah estimasi efek perlakuan atau nilai ATE dan standar errornya. Perhitungan nilai ATE menggunakan [Persamaan \(4\)](#) dan standar error ATE menggunakan [Persamaan \(5\)](#). Hasil estimasi nilai ATE dan SE (ATE) disajikan pada [Tabel 6](#).

Tabel 6. Estimasi nilai ATE dan SE (ATE)

n-strata	Strata ke-	ATE per strata	ATE	SE (ATE)	p-value
2	1	0,205	0,340	0,191	0,04
	2	0,134			
3	1	0,217	0,532	0,182	0,002
	2	0,166			
	3	0,149			

[Tabel 6](#) menunjukkan bahwa nilai ATE pada 2 strata adalah sebesar 0,340 dengan standar error sebesar 0,191 dan p-value = 0,04. Hal ini menunjukkan bahwa kadar AUS berpengaruh signifikan terhadap status NDP pasien. Dari [Tabel 5](#) juga terlihat bahwa nilai ATE pada 3 strata lebih besar dibandingkan 2 strata dan p-value = 0,0002, akan tetapi karena pada saat pengelompokan ada strata yang tidak *balance* (strata 2), sehingga 3 strata tidak memenuhi persyaratan *balance*. Dengan demikian, hanya 2 strata yang dilanjutkan pada tahapan selanjutnya.

Langkah terakhir dari analisis PSS adalah perhitungan persen bias reduksi (PBR). Perhitungan PBR menggunakan [Persamaan \(9\)](#), [\(10\)](#) dan [\(11\)](#). Hasil perhitungan PBR disajikan pada [Tabel 7](#).

Tabel 7. Hasil perhitungan PBR PSS

Keterangan	Besar Bias	PBR (%)
Sebelum strata	0,139	53,03
Setelah strata	0,062	

[Tabel 7](#) menunjukkan bahwa besar bias yang mampu direduksi oleh metode *Propensity Score Stratification* dengan 2 strata adalah sebesar 53,03%.

3.5. Analisis Propensity Score Matching (PSM)

Analisis *Propensity Score Matching* (PSM) diawali dengan mencocokkan data antara kelompok perlakuan dan kelompok kontrol. Pada penelitian ini, metode yang digunakan untuk mencocokkan adalah metode *nearest neighbor matching*. Setelah dilakukan pencocokan, langkah selanjutnya adalah uji *balance* kovariat. Hasil pengujian *balance* kovariat disajikan pada [Tabel 8](#).

Tabel 8. Pengujian balance kovariat pada PSM

Keterangan	p-value uji z				p-value uji t
	X ₁	X ₂	X ₄	X ₅	
Sebelum <i>matching</i>	0,051	0,000	0,061	0,675	0,000
Setelah <i>matching</i>	0,974	0,018	0,003	0,365	0,238

Berdasarkan [Tabel 8](#), diketahui bahwa variabel X₂ dan X₄ tidak memenuhi asumsi *balance* kovariat. Hal ini dapat dilihat dari p-value setelah *matching* kurang dari α (5%). Oleh karena itu, estimasi nilai propensity score dilakukan kembali menggunakan model MARS biner dengan mengeluarkan variabel X₃ dalam analisis. Hasil ini diperoleh dari trial and error. Model MARS biner yang digunakan mengeluarkan variabel X₃ adalah model MARS dengan BF = 20, MI = 3 dan MO = 1. Nilai estimasi propensity score dituliskan pada [Persamaan \(16\)](#).

$$e_{match}(x_i) = \frac{\exp(Z_{match})}{1 + \exp(Z_{match})} \tag{16}$$

dengan Z_{match} merupakan model MARS pada persamaan [\(17\)](#).

$$\begin{aligned} Z_{match} = & 0,353 + 0,236X_{2.1} - 0,103X_{4.1} + 0,526X_{4.1}X_{5.1} \\ & + 0,360X_{2.1}X_{4.1} + 0,257X_{2.1}X_{5.1} \\ & - 0,431X_{1.1}X_{2.1}X_{4.1} - 0,931X_{1.1}X_{2.1}X_{5.1} \\ & - 0,191X_{2.1}X_{4.1}X_{5.1}. \end{aligned} \tag{17}$$

Interpretasi model MARS pada persamaan [\(17\)](#) adalah sebagai berikut.

- BF1 = 0,236 X_{2.1} berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien dengan hipertensi adalah sebesar e^{0,236} = 1,266 kali dibandingkan pasien yang tidak hipertensi.
- BF2 = -0,103 X_{4.1} berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien obesitas adalah sebesar e^{-0,103} = 0,902 kali dibandingkan pasien yang tidak obesitas.
- BF3 = 0,526 X_{1.1}X_{2.1} berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien perempuan yang mengalami hipertensi adalah e^{0,526} = 1,692 kali dibandingkan pada pasien laki-laki yang tidak hipertensi
- BF4 = 0,360 X_{2.1}X_{4.1} berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien dengan hipertensi dan obesitas adalah e^{0,360} = 1,433 kali dibandingkan pada pasien tidak hipertensi dan tidak obesitas.

- $BF5 = 0,257X_{2,1}X_{5,1}$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien dengan hipertensi dan kadar HbA1C tinggi adalah $e^{0,257} = 1,293$ kali dibandingkan pada pasien tidak hipertensi dan kadar HbA1C rendah.
- $BF6 = -0,431X_{1,1}X_{2,1}X_{4,1}$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien perempuan yang hipertensi dan obesitas adalah $e^{-0,431} = 0,650$ kali dibandingkan pada pasien laki-laki yang tidak hipertensi dan tidak obesitas.
- $BF7 = -0,931X_{1,1}X_{2,1}X_{5,1}$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien perempuan yang hipertensi dan kadar HbA1C tinggi adalah $e^{-0,931} = 0,394$ kali dibandingkan pada pasien laki-laki yang tidak hipertensi dan kadar HbA1C rendah.
- $BF8 = -0,191X_{2,1}X_{4,1}X_{5,1}$ berarti resiko pasien DM mengalami kadar AUS tinggi pada pasien perempuan yang obesitas dan kadar HbA1C tinggi adalah $e^{-0,191} = 0,826$ kali dibandingkan pada pasien laki-laki yang tidak obesitas dan kadar HbA1C rendah.

Langkah selanjutnya adalah pencocokan dan dilanjutkan dengan uji balance kovariat. Hasil pengujian balance kovariat disajikan pada Tabel 9.

Tabel 9. Pengujian balance kovariat tanpa X_2 dan X_5 pada PSM

Keterangan	p-value uji z			
	X1	X2	X4	X5
Sebelum <i>matching</i>	0,000	0,000	0,056	0,675
Setelah <i>matching</i>	0,274	0,081	0,450	0,144

Berdasarkan Tabel 9 diketahui bahwa semua variabel sudah memenuhi asumsi balance kovariat. Hal ini dapat dilihat dari p-value setelah matching lebih dari α (5%). Selanjutnya dilakukan estimasi nilai ATT dan standar errornya berdasarkan Persamaan (7) dan Persamaan (8). Berdasar estimasi diperoleh nilai $\hat{\theta}_{ATT} = 0,322$, $SE(\hat{\theta}_{ATT}) = 0,153$ dan p-value = 0,035. Hasil ini menunjukkan bahwa kadar AUS berpengaruh signifikan terhadap status NDP pasien DM.

Tahapan akhir adalah melakukan perhitungan PBR berdasarkan Persamaan (12) dan Persamaan (13). Hasil perhitungan PBR disajikan pada Tabel 10.

Tabel 10. Hasil perhitungan PBR PSM

Keterangan	Besar Bias	PBR (%)
Sebelum <i>matching</i>	0,606	87,83
Setelah <i>matching</i>	0,069	

Tabel 10 menunjukkan bahwa besar bias yang mampu direduksi oleh metode Propensity Score Matching dengan pendekatan MARS biner adalah sebesar 87,83%.

3.6. Perbandingan PBR Propensity Score Stratification dan Propensity Score Matching

Pada tahap ini akan dibandingkan PSS dan PSM berdasarkan persen bias yang mampu direduksi oleh metode tersebut. Perbandingan Persen Bias Reduksi (PBR) disajikan pada Tabel 11.

Tabel 11. Perbandingan PBR PSS dan PSM

Metode	PBR (%)
PSS	53,03
PSM	87,83

Tabel 11 menunjukkan bahwa besar bias yang mampu direduksi oleh metode PSM lebih besar dibandingkan metode PSS. Besar persen reduksi biasanya adalah sebesar 87,83%. Hal ini mengindikasikan bahwa metode PSM dengan pendekatan MARS biner sangat baik digunakan untuk kasus pada penelitian ini.

3.7. Pemodelan Hubungan X dan Y dengan MARS Biner

Pada tahap ini akan dimodelkan hubungan antara kovariat X dan Y tanpa melibatkan faktor *confounding*. Pemodelan MARS pada tahap ini juga menggunakan trial dan error untuk memilih model MARS terbaik berdasarkan nilai GCV. Dari hasil pengolahan data diperoleh model yang terpilih adalah model MARS dengan $BF = 20$, $MI = 3$ dan $MO = 2$. Dari model yang terpilih, dapat dibentuk model MARS sebagai berikut.

$$\begin{aligned}
 Z = & -17,545 - 0,596X_{2,1} + 2,840 \max(0, X_3 - 1,6) \\
 & + 2,750 \max(0, 8 - X_3) - 2,797 \max(0, X_3 - 8) \\
 & + 0,824X_{2,1}X_{4,1} + 0,354X_{2,1}(\max(0, X_3 - 7)) \\
 & + 0,231X_{2,1}(\max(0, 7 - X_3)) \\
 & - 0,378X_{2,1}(\max(0, X_3 - 9)) \\
 & + 0,050(\max(0, 8 - X_3))X_{5,1} \\
 & - 0,214X_{2,1} \max(0, X_3 - 6)X_{4,1} \\
 & - 0,142X_{2,1} \max(0, 6 - X_3)X_{4,1} \\
 & + 0,201X_{2,1} \max(0, X_3 - 9)X_{4,1}.
 \end{aligned}
 \tag{18}$$

Interpretasi model MARS biner pada persamaan (18) adalah sebagai berikut.

- $BF1 = -0,596 X_{2,1}$ berarti resiko pasien DM menderita NDP pada pasien dengan hipertensi adalah sebesar $e^{-0,596} = 0,551$ kali dibandingkan pasien yang tidak hipertensi.
- $BF2 = 2,840 \max(0, X_3 - 1,6)$ berarti resiko pasien DM menderita NDP pada pasien yang lama DM lebih dari 1,6 tahun adalah $e^{2,840} = 17,116$ kali dibandingkan pada pasien yang lama DM kurang dari 1,6 tahun.
- $BF3 = 2,750 \max(0, 8 - X_3)$ berarti resiko pasien DM menderita NDP pada pasien yang lama DM kurang dari 8 tahun adalah $e^{2,750} = 15,643$ kali dibandingkan pada pasien yang lama DM lebih dari 1,6 tahun.
- $BF4 = -2,797 \max(0, X_3 - 8)$ berarti resiko pasien DM menderita NDP pada pasien yang lama DM lebih dari 8 tahun adalah $e^{-2,797} = 0,061$ kali dibandingkan pada pasien yang lama DM kurang dari 8 tahun.
- $BF5 = 0,824X_{2,1}X_{4,1}$ berarti resiko pasien DM menderita NDP pada pasien hipertensi dan obesitas adalah $e^{0,824} = 2,280$ kali dibandingkan pada pasien yang tidak hipertensi dan tidak obesitas.
- $BF6 = 0,354 \max(0, X_3 - 7)$ berarti resiko pasien DM menderita NDP pada pasien hipertensi yang lama DM lebih dari 7 tahun adalah $e^{0,354} = 1,425$ kali dibandingkan pada pasien tidak hipertensi yang lama DM kurang dari 7 tahun.

- $BF7 = 0,231 \max(0, 7 - X_3)$ berarti resiko pasien DM menderita NDP pada pasien hipertensi yang lama DM kurang dari 7 tahun adalah $e^{0,231} = 1,260$ kali dibandingkan pada pasien tidak hipertensi yang lama DM lebih dari 7 tahun.
- $BF8 = -0,378 \max(0, X_3 - 9)$ berarti resiko pasien DM menderita NDP pada pasien hipertensi yang lama DM lebih dari 9 tahun adalah $e^{-0,378} = 0,685$ kali dibandingkan pada pasien tidak hipertensi yang lama DM kurang dari 9 tahun.
- $BF9 = 0,050 \max(0, 7 - X_3) X_{5,1}$ berarti resiko pasien DM menderita NDP pada pasien yang lama DM kurang dari 7 tahun dan kadar HbA1C tinggi adalah $e^{0,050} = 1,051$ kali dibandingkan pada pasien yang lama DM lebih dari 7 tahun dan kadar HbA1C rendah.
- $BF10 = -0,214 \max(0, X_3 - 7) X_{4,1}$ berarti resiko pasien DM menderita NDP pada pasien yang lama DM lebih dari 6 tahun dan obesitas adalah $e^{-0,214} = 0,807$ kali dibandingkan pada pasien yang lama DM kurang dari 6 tahun dan tidak obesitas.
- $BF11 = -0,142 X_{2,1} \max(0, 6 - X_3) X_{4,1}$ berarti resiko pasien DM menderita NDP pada pasien yang hipertensi dan lama DM kurang dari 6 tahun serta obesitas adalah $e^{-0,142} = 0,868$ kali dibandingkan pada pasien tidak hipertensi yang lama DM lebih dari 6 tahun dan tidak obesitas.
- $BF12 = 0,201 X_{4,1} \max(0, X_3 - 9) X_{4,1}$ berarti resiko pasien DM menderita NDP pada pasien yang hipertensi dan lama DM lebih dari 9 tahun serta obesitas adalah $e^{0,201} = 1,223$ kali dibandingkan pada pasien tidak hipertensi yang lama DM kurang dari 9 tahun dan tidak obesitas.

4. Kesimpulan

Berdasarkan uraian pembahasan, diketahui bahwa metode PSS dengan pendekatan model MARS biner tidak cocok digunakan untuk data yang jumlahnya sedikit, karena dapat menyebabkan ada kelompok perlakuan ataupun kelompok kontrol yang tidak memiliki anggota sehingga *p-value* pada pengujian balance maupun PBR tidak bisa dihitung. Hasil estimasi ATE pada metode PSS adalah sebesar 0,340 dengan PBR sebesar 53,03%, sedangkan estimasi ATT pada metode PSM adalah sebesar 0,322 dengan PBR sebesar 87,83%. Dapat disimpulkan bahwa metode terbaik untuk estimasi efek perlakuan dan mampu mereduksi bias terbesar pada kasus ini adalah metode *Propensity Score Matching*. Hasil analisis juga menunjukkan bahwa kadar Asam Urat Serum (AUS) berpengaruh signifikan terhadap status NDP pasien DM.

Kontribusi Penulis. **Ingka Rizkyani Akolo:** Konseptualisasi, metodologi, perangkat lunak, analisis formal, penulisan-draf asli, penulisan-review dan editing, pendanaan. **Setia Ningsih:** Konseptualisasi, metodologi, perangkat lunak, analisis formal, akuisisi pendanaan. **Hendra Dukalang:** Konseptualisasi, akuisisi pendanaan. Semua penulis telah membaca dan menyetujui versi manuskrip yang diterbitkan.

Ucapan Terima Kasih. Para penulis menyampaikan terima kasih kepada editor dan reviewer atas pembacaan yang cermat, kritik yang mendalam,

dan rekomendasi yang praktis untuk meningkatkan kualitas tulisan ini.

Pembiayaan. Penelitian ini tidak menerima pembiayaan eksternal.

Konflik Kepentingan. Para penulis menyatakan tidak ada konflik kepentingan yang terkait dengan artikel ini.

Referensi

- [1] IDF, "Indonesia Diabetes Report 2000 - 2045," 2024. [Online] Available: <https://diabetesatlas.org/data/en/country/94/id.html>. [diakses Jun 19, 2024].
- [2] E. Ernawati, B. W. Otok, dan S. Sutikno, "Penggunaan Propensity Score Stratification-Support Vector Machine Untuk Mengestimasi Efek Perlakuan Aktivitas Olahraga Pada Penderita Diabetes Melitus," *Indones. J. Stat. Its Appl.*, vol. 4, no. 3, pp. 510–527, 2020. doi: [10.29244/ijsa.v4i3.653](https://doi.org/10.29244/ijsa.v4i3.653).
- [3] N. Faulina, K. Nisa, D. Aziz, dan E. Setiawan, "Analisis Propensity Score Matching Pada Kejadian Diabetes Melitus Yang Memuat Faktor Confounding," *J. Siger Mat.*, vol. 02, no. 02, pp. 43–51, 2021.
- [4] L. Meuli dan F. Dick, "Understanding Confounding in Observational Studies," *Eur. J. Vasc. Endovasc. Surg.*, vol. 55, no. 5, p. 737, 2018. doi: [10.1016/j.ejvs.2018.02.028](https://doi.org/10.1016/j.ejvs.2018.02.028).
- [5] I. R. Akolo, B. W. Otok, S. W. Purnami, dan R. Hiola, "Propensity Score Stratification Analysis using Logistic Regression for Observational Studies in Diabetes Mellitus Cases," in *Proceeding of 3rd International Conference on Research, Implementation and Education of Mathematics and Science*, 2016, pp. 59–66.
- [6] A. Adityaningrum, "Estimasi Propensity Score Matching Berdasarkan Pendekatan Multivariate Adaptive Regression Splines," Institut Teknologi Sepuluh Nopember, 2017.
- [7] A. Wahyuni, "Propensity Score Stratification (PSS) Menggunakan Multivariate Adaptive Regression Spline (MARS) Pada Kasus Diabetes Melitus Tipe 2," Institut Teknologi Sepuluh Nopember, 2019.
- [8] J. L. Adelson, D. B. McCoach, H. J. Rogers, J. A. Adelson, dan T. M. Sauer, "Developing and applying the propensity score to make causal inferences: Variable selection and stratification," *Front. Psychol.*, vol. 8, pp. 1–10, 2017. doi: [10.3389/fpsyg.2017.01413](https://doi.org/10.3389/fpsyg.2017.01413).
- [9] H. Nisa, "Perbandingan Propensity Score Weighting dan Matching menggunakan Regresi Logistik (Studi Kasus: Data Kelulusan ASI Eksklusif di Kecamatan Selopuro Kabupaten Blitar)," Universitas Brawijaya, 2019.
- [10] U. Benedetto, S. J. Head, G. D. Angelini, dan E. H. Blackstone, "Statistical primer: Propensity score matching and its alternatives," *Eur. J. Cardio-thoracic Surg.*, vol. 53, no. 6, hal. 1112–1117, 2018, doi: [10.1093/ejcts/ezy167](https://doi.org/10.1093/ejcts/ezy167).
- [11] M. R. Mattalunru, S. Annas, dan M. K. Aidid, "Aplikasi Multivariate Adaptive Regression Splines (Mars) Untuk Mengetahui Faktor Yang Mempengaruhi Curah Hujan Di Kota Makassar," *VARIANSI J. Stat. Its Appl. Teach. Res.*, vol. 4, no. 1, pp. 9–19, 2022. doi: [10.35580/variansium2](https://doi.org/10.35580/variansium2).
- [12] B. W. Otok, A. Aisyah, Purhadi, dan S. Andari, "Propensity score matching of the gymnastics for diabetes mellitus using logistic regression," *AIP Conf. Proc.*, vol. 1913, 2017. doi: [10.1063/1.5016668](https://doi.org/10.1063/1.5016668).
- [13] S. Anam, S. Sugiman, dan S. Sunarmi, "Ketepatan Klasifikasi dengan Menggunakan Metode Multivariate Adaptive Regression Spline (MARS) Pada Data Kelompok Rumah Tangga Kabupaten Cilacap," *UNNES J. Math.*, vol. 6, no. 1, pp. 92–101, 2017.
- [14] S. Hasanah, B. W. Otok, dan A. Adeni, "Perbandingan Metode Propensity Score Matching-Support Vector Machine dan Propensity Score Matching-Regresi Logistik Biner Pada Kasus HIV/AIDS," *Sainmatika J. Ilm. Mat. dan Ilmu Penge-tah. Alam*, vol. 18, no. 1, p. 93, 2021. doi: [10.31851/sainmatika.v17i3.4925](https://doi.org/10.31851/sainmatika.v17i3.4925).
- [15] P. C. Austin dan E. A. Stuart, "The Effect of A Constraint on The Maximum Number of Controls Matched to Each Treated Subject on The Performance of Full Matching on The Propensity Score When Estimating Risk Differences," *Stat. Med.*, vol. 40, no. 1, hal. 101–118, 2021, doi: [10.1002/sim.8764](https://doi.org/10.1002/sim.8764).