



METODE PENELITIAN DENGAN FIMIX-PLS & PLS-POS

MENEMUKAN SEGMENTASI TERSEMBUNYI DAN MENINGKATKAN PREDIKSI DALAM PLS-SEM

Oleh: Rudy C Tarumingkeng


“Tidak semua responden memiliki pola hubungan yang sama. FIMIX-PLS menemukan segmen tersembunyi, PLS-POS meningkatkan kemampuan prediksi model.”



1. APA ITU?

FIMIX-PLS

Finite Mixture Partial Least Squares. Metode untuk menemukan segmen (komponen laten) yang tidak diketahui sebelumnya dalam data. Setiap segmen memiliki koefisien dan hubungan yang berbeda.



Tujuan: Mengungkap heterogenitas tersembunyi, memahami perilaku berbeda, dan menghasilkan strategi yang lebih tepat sasaran.

PLS-POS

Prediction-Oriented Segmentation. Metode segmentasi berbasis optimasi prediksi yang membagi responden ke dalam grup yang memaksimalkan kemampuan prediktif model PLS-SEM.



2. KAPAN DIGUNAKAN?

- ✓ Dugaan adanya kelompok responden dengan perilaku berbeda.
- ✓ Model PLS-SEM hasilnya kurang stabil / R^2 rendah.
- ✓ Tidak tersedia variabel pengelompokan (kategorik).
- ✓ Penelitian pemasaran, manajemen, pendidikan, kesehatan, AI adoption, CSR, ESG, dll.
- ✓ Ingin meningkatkan akurasi prediksi model.

Jika kelompok sudah diketahui sebelumnya (misal: pria vs wanita), gunakan MGA.
Jika belum diketahui, gunakan FIMIX-PLS atau PLS-POS.

3. PERBEDAAN FIMIX-PLS vs PLS-POS

ASPEK	FIMIX-PLS	PLS-POS
Tujuan Utama	Menemukan segmen tersembunyi (latent classes)	Meningkatkan kemampuan prediksi model
Pendekatan	Statistik Campuran (Finite Mixture Modeling)	Segmentasi berbasis optimasi prediksi
Algoritma	Expectation Maximization (EM) – Likelihood based	Iterative clustering & prediction optimization
Dasar Pemilihan Model Terbaik	AIC, BIC, CAIC, MDLS, Entropy	Peningkatan R^2 Predictive, Q^2 , RMSE
Fokus	Heterogenitas struktural	Performa prediksi
Keluaran	Jumlah segmen, proporsi segmen, koefisien tiap segmen	Segmen optimal dengan prediksi terbaik
Kelebihan	Menemukan pola tersembunyi yang bermakna secara teori	Prediksi lebih akurat, stabil, dan praktis
Keterbatasan	Interpretasi lebih kompleks, membutuhkan sampel besar	Tidak selalu menemukan segmen bermakna secara teori

4. LANGKAH FIMIX-PLS

1. Bangun model PLS-SEM awal. Pastikan validitas & reliabilitas terpenuhi.
2. Pilih menu Calculate → FIMIX-PLS.
3. Tentukan jumlah segmen yang akan diuji (misal: 2, 3, 4, 5).
4. Jalankan algoritma (EM Algorithm).
5. Bandingkan kriteria informasi (AIC, BIC, CAIC, MDLS) & Entropy.
6. Pilih jumlah segmen terbaik.
7. Interpretasi karakteristik dan perbedaan koefisien antar segmen.
8. Beri nama / label pada tiap segmen.
9. Laporkan hasil dan implikasi.

5. LANGKAH PLS-POS

1. Bangun model PLS-SEM awal.
2. Pilih menu Calculate → Prediction-Oriented Segmentation.
3. Tentukan rentang jumlah segmen (k). Algoritma akan menguji k yang berbeda.
4. Algoritma melakukan iterasi clustering dan optimasi prediksi.
5. Pilih jumlah segmen yang menghasilkan prediksi terbaik (R^2 pred tertinggi, RMSE terendah).
6. Analisis model pada tiap segmen.
7. Interpretasi dan beri nama segmen.
8. Laporkan hasil dan implikasi.

6. MENENTUKAN JUMLAH SEGMENTASI TERBAIK (FIMIX-PLS)

KRITERIA INFORMASI (Semakin kecil semakin baik)

AIC	Akaike Information Criterion
BIC	Bayesian Information Criterion
CAIC	Consistent AIC
MDLS	Minimum Description Length
Entropy	(0 – 1) Semakin besar semakin baik

CONTOH HASIL (Data Uji k Segmen)

k (Segmen)	AIC	BIC	CAIC	MDLS	Entropy
2	3520	3605	3618	3475	0,72
★ 3	3331	3460	3481	3264	0,83
4	3348	3519	3547	3276	0,79
5	3372	3585	3620	3289	0,76


Model terbaik: k = 3 segmen (BIC & CAIC paling kecil, Entropy tertinggi dan stabil).

7. EVALUASI SETELAH SEGMENTASI

FIMIX-PLS	PLS-POS
✓ Periksa ukuran tiap segmen (minimal ≥ 10% dari total sampel).	✓ Periksa peningkatan R^2 pred / Q^2 pred.
✓ Periksa stabilitas koefisien.	✓ Periksa RMSE, MAE, MAPE.
✓ Bandingkan path coefficient antar segmen.	✓ Pastikan setiap segmen memiliki makna substantif.
✓ Lakukan IPMA pada tiap segmen (jika diperlukan).	✓ Bandingkan koefisien jalur antar segmen.
✓ Pastikan interpretasi teoritis masuk akal.	✓ Pastikan tidak terjadi over-segmentation.

8. CONTOH MODEL PENELITIAN

Model: Digital Leadership (DL) → Innovation Capability (IC) → Organizational Performance (PERF)



Hipotesis:
H1: DL → IC (positif)
H2: IC → PERF (positif)
H3: DL → PERF (positif)
H4: IC mediasi pengaruh DL terhadap PERF

9. CONTOH HASIL PERBEDAAN KOEFISIEN ANTAR SEGMENT (FIMIX-PLS)

Hubungan	Segmen 1 (n = 160)	Segmen 2 (n = 140)	Segmen 3 (n = 100)	Perbedaan Signifikan?
DL → IC	0,81***	0,46**	0,15 (ns)	S1 ≠ S2, S3
IC → PERF	0,70***	0,52**	0,22 (ns)	S1 ≠ S3
DL → PERF	0,28*	0,18 (ns)	0,05 (ns)	S1 ≠ S3

Keterangan: *** p < 0,001; ** p < 0,01; * p < 0,05; ns = tidak signifikan

10. CONTOH HASIL PREDIKSI PLS-POS

Jumlah Segmen (k)	R^2 pred (Rata-rata)	Q^2 pred (Rata-rata)	RMSE (Rata-rata)	MAE (Rata-rata)
2	0,41	0,28	0,412	0,312
★ 3	0,58	0,40	0,321	0,238
4	0,56	0,38	0,335	0,243
5	0,54	0,36	0,352	0,255

Model terbaik: k = 3 segmen → prediksi paling baik (R^2 pred tertinggi, RMSE terendah).

11. CONTOH KARAKTERISTIK SEGMENTASI

FIMIX-PLS (Contoh 3 Segmen)

- Segmen 1: Innovator (32%)
Tinggi pada DL, IC, PERF.
Cepat adopsi teknologi, berani inovasi.
- Segmen 2: Adopter (43%)
Sedang pada semua variabel.
Adaptif, tetapi berhati-hati.
- Segmen 3: Traditional (25%)
Rendah pada DL, IC, PERF.
Resistan terhadap perubahan.

PLS-POS (Contoh 3 Segmen)

- Segmen A: High Performer (30%)
Prediksi sangat akurat.
Kinerja tinggi & konsisten.
- Segmen B: Moderate (50%)
Prediksi cukup akurat.
Butuh dukungan peningkatan kapabilitas.
- Segmen C: Low Performer (20%)
Prediksi sulit, varians perilaku tinggi.
Perlu intervensi khusus.

12. TIPS SUKSES MENGGUNAKAN FIMIX/PLS-POS

- ✓ Pastikan model PLS-SEM awal sudah baik.
- ✓ Gunakan ukuran sampel yang memadai (minimal total ≥ 200–300, ideal lebih besar).
- ✓ Jangan hanya memilih berdasarkan satu kriteria. Gabungkan BIC, CAIC, Entropy, interpretasi.
- ✓ Beri nama segmen berdasarkan teori dan data.
- ✓ Gunakan hasil segmentasi untuk strategi manajerial yang berbeda.



13. KELEBIHAN UTAMA

- Menemukan segmen tersembunyi
- Mengurangi bias model homogen
- Meningkatkan prediksi & akurasi
- Strategi yang lebih tepat sasaran
- Memperkaya teori & kontribusi ilmiah

14. APLIKASI BIDANG

- Pemasaran
- SDM
- Pendidikan
- Kesehatan
- Perbankan
- Teknologi
- Pemerintahan
- ESG & Keberlanjutan

Oleh:

[Prof Ir Rudy C Tarumingkeng, PhD](#)

Professor of Management NUP: 9903252922

Professor Emeritus, IPB-University

Anggota MPR-RI, 1982-1987

Dekan Fak. Kehutanan IPB University. 1967-1968, 1968-1971, 1977-1978

Rektor, Universitas Cenderawasih, Papua (1978-1988, dan

Rektor, Kampus AGRO Manokwari sekarang Universitas Papua Manokwari

Coordinator, CIDA/DIKTI SFU Burnaby BC Canada 1988-1991

Rektor, Universitas Kristen Krida Wacana, Jakarta (1991-2000)

Ketua, Dewan Guru Besar, IPB-University, Bogor (2005-2006)

AI - Data Analyst, dan Ketua, Senat Akademik, IBM-ASMI, Jakarta 2024-

© RudyCT Academic Series

rudict75@gmail.com

29 Juni 2026

METODE PENELITIAN DENGAN FIMIX-PLS DAN PLS-POS

Segmentasi Tersembunyi dan Heterogenitas Tak Teramati dalam PLS-SEM

Abstrak

Perkembangan **Partial Least Squares Structural Equation Modeling (PLS-SEM)** telah mendorong munculnya berbagai teknik analisis lanjutan untuk mengidentifikasi heterogenitas data yang tidak dapat diamati secara langsung. Salah satu tantangan utama dalam penelitian empiris adalah asumsi homogenitas responden, yaitu anggapan bahwa seluruh individu dalam sampel memiliki karakteristik dan pola hubungan antarvariabel yang sama. Dalam praktiknya, asumsi ini sering kali tidak terpenuhi. Responden dapat berasal dari kelompok-kelompok tersembunyi yang memiliki perilaku, preferensi, dan mekanisme kausal yang berbeda. Untuk mengatasi persoalan tersebut, dikembangkan metode **Finite Mixture Partial Least Squares (FIMIX-PLS)** dan **Prediction-Oriented Segmentation (PLS-POS)**.

FIMIX-PLS merupakan teknik berbasis model statistik campuran (*finite mixture modeling*) yang bertujuan mengidentifikasi segmen laten dalam data. Metode ini memungkinkan peneliti menemukan kelompok-kelompok responden yang tidak diketahui sebelumnya, tetapi memiliki pola hubungan struktural yang berbeda. Sementara itu, PLS-POS merupakan pendekatan segmentasi berbasis prediksi yang mengoptimalkan kemampuan prediktif model PLS-SEM. Kedua metode ini menjadi instrumen penting dalam penelitian pemasaran, manajemen strategis, kesehatan, pendidikan, transformasi digital, perilaku konsumen, serta kecerdasan buatan.

Artikel ini membahas konsep, teori, prosedur, interpretasi, keunggulan, keterbatasan, serta aplikasi FIMIX-PLS dan PLS-POS dalam penelitian kontemporer.

Kata Kunci: *FIMIX-PLS, PLS-POS, PLS-SEM, Segmentation, Heterogeneity, SmartPLS, Latent Classes, Prediction-Oriented Segmentation.*

1. Pendahuluan

Salah satu asumsi paling umum dalam penelitian kuantitatif adalah bahwa seluruh responden berasal dari populasi yang homogen.

Dalam konteks SEM, asumsi ini berarti bahwa:

seluruh responden memiliki struktur hubungan antarvariabel yang sama.

Sebagai contoh.

Peneliti ingin mengetahui pengaruh:

Digital Leadership

↓

Innovation Capability

↓

Performance

PLS-SEM konvensional akan menghasilkan satu koefisien:

$$\beta = 0,62$$

Namun pertanyaan penting muncul:

Apakah semua organisasi memiliki hubungan yang sama?

Apakah perusahaan startup memiliki pola yang sama dengan perusahaan tradisional?

Apakah pengguna teknologi muda memiliki mekanisme yang sama dengan pengguna senior?

Apakah pelanggan premium dan pelanggan biasa menunjukkan perilaku yang identik?

Jawabannya sering kali:

Tidak.

Dalam banyak penelitian terdapat kelompok tersembunyi (*latent segments*) yang memiliki karakteristik berbeda.

Kelompok-kelompok ini tidak selalu dapat diidentifikasi melalui:

gender,

umur,

pendapatan,

jenis organisasi.

Karena itu dibutuhkan metode yang mampu menemukan kelompok tersebut secara otomatis.

Metode tersebut adalah:

FIMIX-PLS

dan

PLS-POS.

2. Heterogenitas dalam Penelitian

Heterogenitas adalah variasi karakteristik antar responden.

Secara umum terdapat dua jenis heterogenitas.

Observed heterogeneity

Diketahui sebelumnya.

Contoh:

Pria

Wanita

Generasi X

Generasi Z

Rumah sakit negeri

Rumah sakit swasta

Heterogenitas ini dapat dianalisis menggunakan:

MGA.

Unobserved heterogeneity

Tidak diketahui sebelumnya.

Tidak ada informasi eksplisit.

Kelompok tersembunyi.

Inilah yang dianalisis menggunakan:

FIMIX.

PLS-POS.

3. Mengapa Heterogenitas Penting?

Jika heterogenitas diabaikan.

Hasil penelitian dapat bias.

Sebagai contoh.

Terdapat dua kelompok.

Kelompok A:

$$\beta = 0,80$$

Kelompok B:

$$\beta = 0,20$$

Jika digabung.

Hasil menjadi:

$$\beta = 0,50$$

Padahal tidak ada responden yang memiliki nilai 0,50.

Kesimpulan menjadi menyesatkan.

Dengan demikian.

Mengidentifikasi heterogenitas penting untuk:

- meningkatkan validitas model;
- memahami perilaku kelompok;
- menghasilkan strategi berbeda;
- memperkuat kontribusi teoritis.

4. Segmentasi dalam SEM

Segmentasi adalah proses membagi populasi menjadi kelompok yang relatif homogen.

Pendekatan segmentasi dapat berupa:

A priori segmentation

Kelompok diketahui sebelumnya.

MGA.

Ex post segmentation

Kelompok dicari dari data.

FIMIX.

POS.

REBUS-PLS.

PLS-GAS.

5. Apa itu FIMIX-PLS?

FIMIX adalah singkatan:

Finite Mixture Partial Least Squares.

Dikembangkan oleh:

Hahn et al.

Sarstedt et al.

Ringle et al.

Metode ini menggabungkan:

Finite Mixture Modeling

dengan

PLS-SEM.

Tujuan:

Menemukan segmen tersembunyi dalam data.

6. Dasar Konseptual FIMIX

FIMIX mengasumsikan bahwa data berasal dari beberapa populasi yang berbeda.

Misalnya:

Populasi sebenarnya terdiri atas:

Segmen 1

Segmen 2

Segmen 3

Namun peneliti tidak mengetahui keanggotaannya.

FIMIX akan mengestimasi:

jumlah segmen;

proporsi segmen;

koefisien masing-masing segmen.

7. Model Matematis FIMIX

Secara umum.

Distribusi keseluruhan:

$f(y)$

=

$\sum \pi_k f_k(y)$

dimana:

π_k

proporsi segmen

f_k

fungsi distribusi segmen

k

jumlah segmen.

8. Tujuan FIMIX

Mengidentifikasi latent classes.

Mengurangi bias.

Meningkatkan prediksi.

Menjelaskan variasi perilaku.

Mengembangkan teori.

9. Kapan Menggunakan FIMIX?

FIMIX digunakan jika:

hasil model kurang stabil;

R^2 rendah;

literatur menunjukkan variasi perilaku;

tidak tersedia variabel kelompok;

dugaan terdapat segmen tersembunyi.

10. Langkah FIMIX

Langkah 1.

Estimasi model PLS.

Langkah 2.

Pilih FIMIX.

Langkah 3.

Tentukan jumlah segmen.

Langkah 4.

Bandingkan kriteria informasi.

Langkah 5.

Pilih model terbaik.

Langkah 6.

Interpretasikan segmen.

11. Menentukan Jumlah Segmen

Biasanya diuji:

2 segmen

3 segmen

4 segmen

5 segmen

Kemudian dibandingkan.

12. Kriteria Evaluasi FIMIX

Beberapa ukuran digunakan.

AIC

Akaike Information Criterion

BIC

Bayesian Information Criterion

CAIC

Consistent AIC

MDL5

Minimum Description Length

Entropy

13. BIC

Semakin kecil.

Semakin baik.

Contoh.

• Segmen	• BIC
• 2	• 3421
• 3	• 3318
• 4	• 3362

Model terbaik:

3 segmen.

14. Entropy

Mengukur kejelasan segmentasi.

Nilai:

0–1

Semakin tinggi.

Semakin baik.

Pedoman:

0,50

baik.

0,70

sangat baik.

15. CAIC

Mirip BIC.

Lebih konservatif.

Semakin kecil lebih baik.

16. MDL5

Digunakan SmartPLS.

Semakin rendah.

Semakin baik.

17. Interpretasi Segmen

Misalnya.

FIMIX menemukan:

Segmen 1

42%

Segmen 2

35%

Segmen 3

23%

Peneliti kemudian menganalisis karakteristik segmen.

18. Contoh Pemasaran

Service Quality

↓

Satisfaction

↓

Loyalty

FIMIX menghasilkan:

Segmen Premium

Segmen Value-Oriented

Segmen Transactional

19. Contoh Digitalisasi

Digital Leadership

↓

Innovation

↓

Performance

Segmen:

Digital Enthusiast

Digital Skeptic

Digital Pragmatist

20. Contoh Rumah Sakit

Segmen 1

Patient-centered

Segmen 2

Cost-sensitive

Segmen 3

Convenience-oriented

21. Kelebihan FIMIX

Tidak membutuhkan variabel kelompok.

Menemukan segmen tersembunyi.

Meningkatkan kualitas model.

Mengurangi bias.

22. Keterbatasan FIMIX

Komputasi tinggi.

Interpretasi sulit.

Tidak selalu stabil.

Membutuhkan sampel besar.

23. Ukuran Sampel

Hair et al.

merekomendasikan:

300–500.

Lebih besar lebih baik.

24. Apa itu PLS-POS?

PLS-POS adalah:

Prediction-Oriented Segmentation.

Dikembangkan untuk meningkatkan kemampuan prediktif.

Berbasis algoritma clustering.

Tujuan:

memaksimalkan prediksi.

25. Filosofi PLS-POS

Jika FIMIX berfokus pada:

likelihood.

PLS-POS berfokus pada:

prediction accuracy.

26. Algoritma PLS-POS

Tahap:

estimasi awal;

pengelompokan;

optimasi prediksi;

re-estimasi.

Iterasi dilakukan berulang.

27. Tujuan POS

Meningkatkan R^2 .

Meningkatkan prediksi.

Menghasilkan kelompok homogen.

28. Keunggulan POS

Lebih stabil.

Lebih mudah.

Lebih baik untuk prediksi.

29. FIMIX vs POS

- | • Aspek | • FIMIX | • POS |
|----------------|----------------------|------------------------|
| • Tujuan | • Likelihood | • Prediction |
| • Pendekatan | • Statistik campuran | • Segmentasi prediktif |
| • Stabilitas | • Sedang | • Tinggi |
| • Interpretasi | • Kompleks | • Lebih sederhana |
| • Fokus | • Heterogenitas | • Prediksi |
-

30. Kapan Menggunakan POS?

Ketika tujuan penelitian:

prediksi.

PLSpredict.

machine learning.

decision support.

31. SmartPLS dan FIMIX

SmartPLS menyediakan menu:

Calculate

↓

FIMIX-PLS

↓

Number of Segments

↓

Output

32. SmartPLS dan POS

Calculate

↓

Prediction-Oriented Segmentation

↓

Iterasi

↓

Output.

33. Interpretasi Hasil FIMIX

Segmen 1.

$\beta=0,81$

Segmen 2.

$\beta=0,36$

Segmen 3.

$\beta=0,15$

Artinya:

hubungan tidak homogen.

34. Interpretasi POS

Segmen dengan prediksi terbaik dipilih.

Kemudian dianalisis.

35. FIMIX dan MGA

FIMIX menemukan kelompok.

MGA membandingkan kelompok.

Keduanya dapat dikombinasikan.

36. FIMIX dan MICOM

MICOM tidak wajib.

Karena kelompok ditemukan otomatis.

Namun dapat digunakan setelah segmentasi.

37. FIMIX dan IPMA

Setelah segmen ditemukan.

IPMA dapat dilakukan.

Prioritas tiap segmen berbeda.

38. Contoh ESG

ESG

↓

Firm Value

FIMIX menghasilkan.

Segmen konservatif.

Segmen progresif.

Investor ESG.

Investor tradisional.

39. Contoh Pendidikan

Digital Mindset

↓

Teaching Innovation

↓

Performance

Segmen:

Innovator Teachers

Traditional Teachers

Adaptive Teachers

40. Contoh AI

AI Readiness

↓

Performance

Segmen:

AI Champions

AI Followers

AI Skeptics

41. FIMIX dan Dynamic Capability

Kapabilitas dinamis berbeda.

Segmentasi membantu menjelaskan.

42. FIMIX dan Customer Analytics

Sangat populer.

Customer segmentation.

Behavioral segmentation.

Digital segmentation.

43. FIMIX dan Machine Learning

Konsep mirip clustering.

Namun tetap mempertahankan SEM.

44. Heterogenitas dalam Teori

FIMIX memperkuat:

Contingency Theory.

Institutional Theory.

Behavioral Theory.

Dynamic Capability Theory.

45. Kesalahan Umum

Memilih segmen hanya dari BIC.

Mengabaikan entropy.

Tidak memberi nama segmen.

Tidak ada dasar teori.

Menggunakan sampel kecil.

46. Checklist FIMIX

✓ Sampel memadai

✓ Model stabil

✓ BIC diperiksa

✓ Entropy diperiksa

✓ Segmen bermakna

✓ Proporsi memadai

✓ Interpretasi teoritis

47. Masa Depan Segmentasi

PLS-POS.

Machine Learning.

Hybrid Analytics.

Explainable AI.

Big Data.

Human-centered Analytics.

48. Implikasi Praktis

Perusahaan dapat:

menentukan strategi berbeda.

Rumah sakit:

menyesuaikan pelayanan.

Universitas:

menyesuaikan kebijakan.

Bank:

menyesuaikan layanan.

49. Kontribusi Akademik

FIMIX dan POS memperkaya PLS-SEM.

Tidak semua responden dianggap sama.

Penelitian menjadi lebih realistis.

Lebih kontekstual.

Lebih kuat secara teoritis.

50. Kesimpulan

FIMIX-PLS dan PLS-POS merupakan pendekatan lanjutan dalam PLS-SEM untuk mengidentifikasi heterogenitas tak teramati.

FIMIX berfokus pada:

probabilitas segmentasi.

PLS-POS berfokus pada:

kemampuan prediksi.

Kedua metode sangat berguna ketika peneliti menduga adanya kelompok-kelompok tersembunyi dalam data.

Dengan menggunakan FIMIX dan PLS-POS, penelitian tidak lagi mengasumsikan bahwa seluruh responden memiliki perilaku yang identik.

Sebaliknya, peneliti dapat memahami bahwa:

populasi sering terdiri atas berbagai segmen dengan karakteristik unik, mekanisme hubungan yang berbeda, serta kebutuhan kebijakan yang spesifik.

Hal ini menjadikan FIMIX dan PLS-POS sebagai salah satu perkembangan metodologis paling penting dalam era **PLS-SEM prediktif, Big Data, dan Artificial Intelligence**.

Glossarium

AIC

Akaike Information Criterion.

BIC

Bayesian Information Criterion.

CAIC

Consistent Akaike Information Criterion.

Entropy

Ukuran kejelasan segmentasi.

FIMIX-PLS

Finite Mixture Partial Least Squares.

Hidden Heterogeneity

Heterogenitas yang tidak dapat diamati secara langsung.

Latent Segment

Kelompok tersembunyi dalam populasi.

MDL5

Minimum Description Length.

PLS-POS

Prediction-Oriented Segmentation.

Segmentation

Proses pengelompokan responden.

Unobserved Heterogeneity

Variasi karakteristik yang tidak diketahui sebelumnya.

Daftar Pustaka

Becker, J. M., Ringle, C. M., Sarstedt, M., & Völckner, F. (2013). How collinearity affects mixture regression results. *Marketing Letters*, 24(2), 159–172. <https://doi.org/10.1007/s11002-012-9199-9>

Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2022). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)* (3rd ed.). Sage.

Hahn, C., Johnson, M. D., Herrmann, A., & Huber, F. (2002). Capturing customer heterogeneity using a finite mixture PLS approach. *Schmalenbach Business Review*, 54(3), 243–269. <https://doi.org/10.1007/BF03396654>

Ringle, C. M., Wende, S., & Becker, J. M. (2026). *SmartPLS 4 User Manual*. SmartPLS GmbH.

Sarstedt, M., Becker, J. M., Ringle, C. M., & Schwaiger, M. (2011). Uncovering and treating unobserved heterogeneity with FIMIX-PLS.

Marketing Letters, 22(3), 221–236. <https://doi.org/10.1007/s11002-010-9119-x>

Sarstedt, M., Hair, J. F., Ringle, C. M., Thiele, K. O., & Gudergan, S. P. (2016). Estimation issues with PLS and CB-SEM. *Journal of Business Research*, 69(10), 3998–4010. <https://doi.org/10.1016/j.jbusres.2016.06.007>

Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J. H., Ting, H., Vaithilingam, S., & Ringle, C. M. (2019). Predictive model assessment in PLS-SEM using PLSpredict. *European Journal of Marketing*, 53(11), 2322–2347. <https://doi.org/10.1108/EJM-02-2019-0189>

Wold, H. (1982). Soft modeling: The basic design and some extensions. In K. Jöreskog & H. Wold (Eds.), *Systems under indirect observation* (pp. 1–54). North-Holland.

Copilot for this article: ChatGPT, Access date: 29 June 2026. Author's account (Rudy C Tarumingkeng). <https://chatgpt.com/c/6a408e68-cd18-83ec-a9dc-3674adb4ef97>