



Analisis Perbandingan Kinerja Cloud Amazon Web Services dan Google Cloud Platform untuk Learning Management System Menggunakan Metode Analytical Hierarchy Process

Reza Maulana^{1,*}, Faralita Faisal², Salman Fathy Shiroth³, Hany Hidianti¹

¹ Program Studi Teknik Informatika, Sekolah Tinggi Teknologi Terpadu Nurul Fikri, Depok, Indonesia

² Program Studi Sistem Informasi, Sekolah Tinggi Teknologi Terpadu Nurul Fikri, Depok, Indonesia

³ Program Studi Bisnis Digital, Sekolah Tinggi Teknologi Terpadu Nurul Fikri, Depok, Indonesia

Email: ^{1,*} rezamaulana@nurulfikri.ac.id, ²faralita.faisal@nurulfikri.ac.id, ³salman.fathy@nurulfikri.ac.id,

⁴hany22285ti@student.nurulfikri.ac.id

Email Penulis Korespondensi: rezamaulana@nurulfikri.ac.id

Abstrak—Transformasi digital pendidikan menuntut infrastruktur Learning Management System yang skalabel dan andal, namun institusi kerap menghadapi masalah dalam menentukan platform cloud yang tepat karena keputusan sering diambil tanpa dasar kinerja empiris dan hanya berbasis harga katalog atau fitur. Penelitian ini bertujuan membandingkan kinerja Amazon Web Services dan Google Cloud Platform pada lapisan Infrastructure as a Service serta menghasilkan rekomendasi pemilihan platform yang objektif untuk penerapan LMS. Metode penelitian dilakukan melalui lima tahap, yaitu penyediaan infrastruktur dua mesin virtual setara, penerapan aplikasi Moodle beserta basis data dan komponen pemantauan menggunakan kontainerisasi Docker, eksekusi pengujian beban dengan Apache JMeter pada 100, 250, dan 500 pengguna bersamaan, pengumpulan metrik kinerja, serta evaluasi menggunakan metode Analytical Hierarchy Process pada empat kriteria: kinerja, keandalan, biaya, dan integrasi. Hasil menunjukkan Google Cloud Platform unggul dalam menekan error hingga 0,12% dan stabilitas sistem operasi serta 27,7% lebih murah, sedangkan Amazon Web Services unggul throughput hingga 11,7 permintaan per detik dengan konsistensi respons maksimal. Evaluasi AHP menghasilkan skor 0,768 untuk AWS dan 0,762 untuk GCP dengan rasio konsistensi 0,041, sehingga AWS direkomendasikan untuk institusi berbeban tinggi sedangkan GCP cocok untuk penerapan berorientasi keandalan dan efisiensi biaya. Kontribusi penelitian adalah kerangka evaluasi terpadu pertama yang memadukan pengujian beban empiris JMeter pada beban kerja LMS Moodle dengan metode AHP, disertai arsitektur pengujian berbasis Docker yang portabel dan dapat direplikasi secara identik pada kedua platform.

Kata Kunci: Analytical Hierarchy Process; Amazon Web Services; Cloud Computing; Google Cloud Platform; Learning Management System

Abstract—The digital transformation of education demands scalable and reliable LMS infrastructure, yet institutions often struggle to choose the right cloud platform because decisions rely only on catalog prices or features without empirical performance evidence. This study compares the performance of Amazon Web Services and Google Cloud Platform at the Infrastructure as a Service layer through five stages: provisioning two equivalent virtual machines, deploying Moodle with its database and monitoring stack via Docker containerization, executing JMeter load tests at 100, 250, and 500 concurrent users, collecting performance metrics, and evaluating them with the Analytical Hierarchy Process across four criteria of performance, reliability, cost, and integration. GCP excels in error containment (as low as 0.12%) and OS-level stability and is 27.7% cheaper, while AWS leads in throughput up to 11.7 requests per second with consistent maximum response times. AHP yields scores of 0.768 for AWS and 0.762 for GCP with a consistency ratio of 0.041. The contribution of this research is the first integrated evaluation framework combining empirical JMeter load testing on LMS workloads with multi-criteria AHP decision making, together with a portable Docker-based testing architecture replicable on both platforms.

Keywords: Analytical Hierarchy Process; Amazon Web Services; Cloud Computing; Google Cloud Platform; Learning Management System

1. PENDAHULUAN

Transformasi digital di pendidikan tinggi mempercepat peralihan dari pembelajaran tatap muka menuju lingkungan belajar yang dimediasi teknologi. Pada tingkat infrastruktur, peralihan ini membebani Learning Management System (LMS) secara signifikan karena sistem harus melayani ribuan mahasiswa secara bersamaan, menyajikan konten kuliah, mengelola asesmen, serta mencatat learning analytics secara real-time [1]. Penyebaran server on-premises konvensional, yang lama menjadi pilihan utama hosting LMS institusional, semakin sulit memenuhi tuntutan ini secara hemat biaya, terutama saat lonjakan beban pada masa pendaftaran atau ujian akhir semester yang sulit diprediksi. Ketidakmampuan ini mendorong institusi pendidikan mencari alternatif infrastruktur yang lebih elastis dan ekonomis.

Komputasi awan menjadi solusi yang menjanjikan karena menyediakan sumber daya sesuai permintaan, penskalaan elastis, dan model penagihan berbasis konsumsi yang selaras dengan pola penggunaan kalender akademik [2]. Di antara berbagai platform yang tersedia, Amazon Web Services (AWS) dan Google Cloud Platform (GCP) merupakan dua penyedia yang paling banyak dievaluasi dalam konteks penelitian maupun industri, masing-masing menawarkan kapabilitas Infrastructure as a Service (IaaS) yang komprehensif untuk menopang arsitektur LMS multi-tier [3]. Meskipun demikian, memilih di antara kedua platform untuk skenario penerapan tertentu, khususnya pada institusi pendidikan dengan keterbatasan anggaran, memerlukan dasar yang lebih objektif daripada sekadar membandingkan fitur secara kualitatif. Keputusan yang keliru dapat berakibat pada pembengkakan biaya operasional atau penurunan kualitas layanan pembelajaran.

Penelitian terdahulu telah membahas pemanfaatan cloud dalam pendidikan dari berbagai sudut pandang, namun masing-masing memiliki keterbatasan yang belum terjawab. AlAjmi [2] membangun model adopsi e-learning berbasis



cloud yang menekankan fleksibilitas dan efisiensi biaya sebagai faktor pendorong, namun kajian tersebut bersifat konseptual tanpa pengukuran kinerja empiris antarpemedia sehingga tidak memberikan panduan konkret bagi institusi dalam memilih platform. Yegon dkk. [4] meneliti penerapan IaaS untuk keberlanjutan LMS di universitas publik dan menemukan peningkatan kinerja serta pengurangan downtime, namun studinya hanya melibatkan satu institusi dan satu penyedia cloud tanpa perbandingan lintas platform sehingga temuannya tidak dapat dijadikan dasar pemilihan antara AWS dan GCP.

Mohammed dan Zeebaree [3] menyusun tinjauan komparatif atas layanan IaaS, PaaS, dan SaaS dari berbagai penyedia cloud, namun perbandingannya sepenuhnya bersifat teoretis tanpa data pengujian beban empiris sehingga perbedaan kinerja nyata antar platform tidak terukur. Çapari dkk. [6] mengevaluasi efisiensi platform cloud untuk aplikasi web multipengguna menggunakan metrik kinerja, namun pengujiannya menggunakan beban kerja generik, bukan pola permintaan HTTP yang mencerminkan aktivitas LMS, dan tidak melibatkan metode pengambilan keputusan multikriteria untuk menjembatani data teknis dengan kebutuhan institusional. Noviani dkk. [10] secara langsung membandingkan kinerja AWS dan GCP, namun konteks pengujiannya adalah beban kerja komputasi umum, bukan skenario LMS, dan tidak menyertakan evaluasi multikriteria yang mempertimbangkan biaya dan kemudahan integrasi.

Berdasarkan penelusuran empat penelitian terdahulu tersebut, tampak kesenjangan yang jelas apabila keempatnya dibandingkan secara langsung. AlAjmi [2] bersifat konseptual dan tidak menyertakan data kinerja empiris antarpemedia, sedangkan Yegon dkk. [4] telah melakukan pengujian empiris namun terbatas pada satu platform dan satu institusi sehingga tidak dapat membandingkan AWS dengan GCP. Mohammed dan Zeebaree [3] menyediakan perbandingan lintas layanan cloud, tetapi sepenuhnya teoretis tanpa pengujian beban. Çapari dkk. [6] dan Noviani dkk. [10] keduanya telah melakukan pengujian kinerja empiris, bahkan Noviani dkk. membandingkan langsung AWS dan GCP, namun keduanya menggunakan beban kerja generik di luar konteks LMS dan tidak satu pun melibatkan metode pengambilan keputusan multikriteria seperti AHP untuk menerjemahkan hasil teknis menjadi rekomendasi pemilihan platform. Dengan demikian, tidak satu pun dari keempat penelitian tersebut memadukan tiga komponen sekaligus, yaitu pengujian beban empiris pada beban kerja LMS nyata, perbandingan langsung antara AWS dan GCP, serta evaluasi multikriteria berbasis AHP. Kesenjangan inilah yang menjadi titik tolak dan justifikasi penelitian ini.

Urgensi menutup kesenjangan ini semakin nyata mengingat Kabra dkk. [22] mengidentifikasi kinerja dan biaya sebagai penentu utama keputusan adopsi cloud di institusi pendidikan, sementara Walker dan Voce [21] mendokumentasikan percepatan adopsi teknologi pembelajaran pasca-pandemi yang menuntut infrastruktur lebih tangguh.

Berdasarkan uraian kesenjangan tersebut, penelitian ini memberi tiga kontribusi konkret. Pertama, perbandingan kinerja empiris AWS dan GCP menggunakan beban kerja LMS berbasis Moodle yang lebih merepresentasikan skenario penggunaan nyata dibandingkan studi sebelumnya. Kedua, kerangka evaluasi AHP multikriteria yang memadukan data kinerja empiris dengan penilaian bobot untuk menghasilkan rekomendasi terukur dan dapat dikalibrasi ulang oleh institusi lain. Ketiga, arsitektur pengujian berbasis Docker yang terbukti portabel dan dapat direplikasi secara identik pada AWS maupun GCP sebagai acuan praktis bagi institusi yang hendak memigrasikan LMS ke infrastruktur cloud.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan rancangan eksperimental-analitis yang memadukan benchmarking kinerja kuantitatif dengan evaluasi multikriteria terstruktur. Tahapan penelitian disusun secara sistematis dalam lima langkah yang saling berurutan sebagaimana digambarkan pada Gambar 1.



Gambar 1. Bagan Alur Tahapan Penelitian

Berdasarkan Gambar 1, langkah pertama adalah penyediaan infrastruktur, yaitu membangun dua mesin virtual dengan spesifikasi setara pada AWS dan GCP di region yang sama, dengan sistem operasi, jumlah vCPU, kapasitas memori, dan model penagihan yang dikontrol agar identik. Langkah kedua adalah penerapan tumpukan aplikasi, di mana Moodle beserta basis data MariaDB dan komponen observabilitas dideploy melalui Docker menggunakan berkas konfigurasi yang sama di kedua platform. Langkah ketiga adalah eksekusi pengujian beban menggunakan Apache JMeter pada tiga tingkat konkurensi, yaitu 100, 250, dan 500 pengguna bersamaan. Langkah keempat adalah pengumpulan dan analisis komparatif metrik kinerja yang direkam melalui Prometheus, Node Exporter, dan Grafana. Langkah kelima adalah penilaian platform menggunakan metode AHP dan perumusan rekomendasi penerapan. Urutan tahapan ini memastikan setiap kesimpulan yang ditarik berlandaskan data yang terukur dan dapat ditelusuri kembali.


2.2 Konfigurasi Infrastruktur dan Arsitektur Pengujian

Kedua platform dikonfigurasi dengan spesifikasi IaaS yang sebanding untuk menjaga validitas evaluasi. Kedua mesin virtual ditempatkan di region asia-southeast1 (Singapura) sebagai pusat data terdekat dengan konteks institusi target sehingga latensi jaringan tereliminasi sebagai variabel pengganggu. Spesifikasi rinci kedua lingkungan disajikan pada Tabel 1.

Tabel 1. Konfigurasi Infrastruktur Eksperimen pada AWS dan GCP

No	Atribut	AWS	GCP
1	Layanan Komputasi	EC2	Compute Engine (E2)
2	Instance	t3.medium (t3 family)	e2-medium (2 vCPU, 4 GB)
3	Lokasi Server	asia-southeast1 (Singapore)	asia-southeast1 (Singapore)
4	Machine Type	2 vCPU & 4 GiB memori	1-2 vCPU (1 shared core), 4 GB
5	Image / OS	Ubuntu Server 22.04 LTS 64-bit	Ubuntu 22.04 LTS Minimal x86/64
6	Biaya	\$46,32 / bulan (On-Demand)	\$33,47 / bulan (~\$0,05/jam)
7	Billing	On-Demand	On-Demand (per-second)
8	Network	Default VPC	Default VPC
9	Storage	EBS 30 GiB gp3	20 GB persistent disk

Kedua instance merepresentasikan konfigurasi general-purpose tingkat awal yang sesuai untuk beban dasar LMS, masing-masing dengan 2 vCPU dan 4 GB memori. Perbedaan menonjol terdapat pada biaya: dengan model On-Demand yang sama, e2-medium GCP diestimasikan \$33,47 per bulan, sekitar 27,7% lebih rendah dari \$46,32 per bulan instance AWS yang setara. Di atas setiap mesin virtual, seluruh tumpukan aplikasi dideploy melalui Docker sehingga konfigurasi identik dapat direplikasi tanpa ketergantungan pada layanan terkelola spesifik penyedia. Lingkungan pengujian terdiri atas lima kontainer utama, yaitu Moodle sebagai aplikasi LMS yang diuji, MariaDB sebagai basis data, serta Prometheus, Grafana, dan Node Exporter sebagai komponen observabilitas untuk merekam metrik tingkat sistem. Seluruh data persisten disimpan pada Docker Volume. Rancangan arsitektur pengujian ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur Pengujian LMS Berbasis Cloud IaaS dengan Kontainerisasi Docker



Berdasarkan Gambar 2, alur permintaan dimulai dari pengguna yang mengakses LMS melalui internet publik menuju mesin virtual IaaS berbasis Ubuntu, tempat mesin Docker menjalankan seluruh layanan sebagai kontainer terisolasi. Rincian peran setiap kontainer disajikan pada Tabel 2.

Tabel 2. Komponen Kontainer dalam Arsitektur Pengujian

Kontainer	Kategori	Peran dalam Arsitektur
Moodle	Aplikasi LMS	Menangani permintaan HTTP pengguna: autentikasi, akses materi, pengumpulan tugas, dan rendering dasbor. Menjadi objek utama uji beban JMeter.
MariaDB	Basis Data	Menyimpan data pengguna, kursus, nilai, dan log. Dipanggil Moodle pada setiap transaksi baca/tulis data.
Prometheus	Monitoring	Mengumpulkan dan menyimpan metrik time-series dari Node Exporter secara periodik untuk analisis kinerja.
Grafana	Visualisasi	Menyajikan metrik kinerja dalam dasbor real-time untuk pemantauan CPU, RAM, throughput, dan error.
Node Exporter	Monitoring	Mengekspos metrik tingkat sistem operasi (CPU, RAM, beban sistem) dari mesin virtual ke Prometheus.

Konfigurasi tunggal-VM ini dipilih secara sengaja sebagai keputusan metodologis. Dengan menempatkan seluruh tumpukan pada satu mesin virtual tanpa penskalaan otomatis maupun distribusi beban antarserver, perbedaan kinerja yang terukur dapat dipastikan murni mencerminkan karakteristik infrastruktur IaaS masing-masing platform. Pendekatan terkontrol ini memperkuat validitas internal perbandingan karena kedua platform menjalankan tumpukan kontainer yang sama persis dengan parameter dan beban yang sama.

2.3 Protokol Uji Beban dan Kerangka AHP

Apache JMeter digunakan untuk mensimulasikan perilaku pengguna bersamaan secara realistis pada tiga tingkat beban: 100, 250, dan 500 virtual user. Setiap skenario menjalankan urutan permintaan HTTP terstandar terhadap Moodle yang merepresentasikan interaksi LMS umum, yakni autentikasi, pengambilan konten kuliah, pengumpulan tugas, dan rendering dasbor. Enam metrik dicatat per eksekusi, yaitu rata-rata waktu respons, waktu respons maksimal, tingkat error, throughput, utilisasi CPU, dan utilisasi RAM. Metrik tingkat sistem dikumpulkan melalui Node Exporter dan Prometheus, kemudian divisualisasikan pada Grafana [7], [8].

Analytic Hierarchy Process disusun atas empat kriteria utama yang diinformasikan oleh hasil empiris dan pertimbangan pengadaan cloud dalam konteks pendidikan, yaitu kinerja (waktu respons dan throughput), keandalan (tingkat error dan stabilitas CPU), biaya (efisiensi sumber daya dan harga On-Demand), serta integrasi (kompatibilitas API dan kompleksitas penerapan). Matriks perbandingan berpasangan disusun berdasarkan bukti eksperimen yang dipadukan dengan penilaian pakar, mengikuti validasi rasio konsistensi ($CR < 0,10$) untuk memastikan koherensi matriks [9], [11].

2.4 Definisi Metrik Evaluasi

Untuk menjamin objektivitas pengukuran, setiap metrik yang direkam selama pengujian didefinisikan secara operasional sebagaimana dirangkum pada Tabel 3. Definisi yang jelas ini penting agar interpretasi hasil tidak ambigu dan dapat dibandingkan secara adil antar platform maupun antar tingkat beban.

Tabel 3. Definisi Operasional Metrik Evaluasi Kinerja

Metrik	Definisi Operasional	Satuan
Rata-rata Respons	Waktu rata-rata yang diperlukan server untuk menyelesaikan satu permintaan dari seluruh sampel dalam satu skenario beban.	milidetik (ms)
Respons Maksimal	Waktu respons terlama yang tercatat dalam satu skenario, merepresentasikan kasus terburuk yang dialami pengguna.	milidetik (ms)
Tingkat Error	Persentase permintaan yang gagal diproses terhadap total permintaan.	persen (%)
Throughput	Jumlah permintaan yang berhasil dilayani server per satuan waktu.	permintaan/detik
Utilisasi CPU	Persentase penggunaan prosesor mesin virtual selama pengujian.	persen (%)
Utilisasi RAM	Persentase penggunaan memori mesin virtual selama pengujian.	persen (%)

Keenam metrik pada Tabel 3 dipilih karena mencakup tiga dimensi kualitas layanan yang paling relevan bagi pengalaman pengguna LMS, yaitu kecepatan, keandalan, dan efisiensi sumber daya. Kombinasi ketiga dimensi ini memberikan gambaran menyeluruh atas perilaku platform, sehingga rekomendasi yang dihasilkan tidak bias terhadap satu aspek tunggal.

3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil pengujian beban pada ketiga tingkat konkurensi, diikuti analisis komparatif dan sintesis melalui kerangka AHP. Setiap skenario beban diuji untuk memperoleh gambaran perilaku kedua platform mulai dari



kondisi ringan hingga mendekati batas kapasitas, sehingga karakteristik masing-masing penyedia dapat dipetakan secara menyeluruh.

3.1 Kinerja pada 100 Pengguna Bersamaan

Pengujian pertama dilakukan pada beban 100 pengguna bersamaan untuk mengukur perilaku kedua platform pada kondisi ringan. Hasil pengukuran disajikan pada Tabel 4.

Tabel 4. Hasil Pengujian pada 100 Pengguna Bersamaan

Metrik	GCP	AWS	Analisis Komparatif
Rata-rata Respons	237 ms	602 ms	GCP merespons 2,5x lebih cepat pada beban rendah
Respons Maksimal	9.116 ms	1.950 ms	AWS lebih stabil menangani antrean awal
Tingkat Error	0,12%	1,03%	GCP lebih andal meminimalkan koneksi terputus
Throughput	2,2 req/s	7,7 req/s	AWS melayani 3,5x lebih banyak permintaan/detik
Beban CPU	4,2%	8,2%	Keduanya dalam rentang aman
Penggunaan RAM	27,4%	27,8%	Konsumsi memori praktis identik

Berdasarkan Tabel 4, Pada 100 pengguna bersamaan, GCP menunjukkan keunggulan nyata pada latensi rata-rata, memproses permintaan hampir 2,5 kali lebih cepat dari AWS. Namun keunggulan ini tidak berlaku pada perilaku kasus terburuk: waktu respons maksimal GCP sebesar 9.116 ms mengungkap kerentanan dini terhadap lonjakan latensi yang sepenuhnya dihindari AWS dengan batas 1.950 ms. Dominasi throughput AWS sebesar 7,7 berbanding 2,2 permintaan per detik mengindikasikan strategi antrean permintaan yang berbeda, yang memprioritaskan volume pemrosesan di atas optimalisasi respons individual. Tingkat error GCP 0,12% berbanding 1,03% pada AWS menegaskan keandalan koneksi GCP yang lebih baik pada beban ini, suatu keunggulan penting bagi LMS karena kegagalan autentikasi atau pengambilan konten secara langsung menurunkan pengalaman mahasiswa. Sementara itu, utilisasi CPU dan RAM kedua platform masih berada jauh di bawah ambang kritis, menandakan bahwa beban 100 pengguna belum menjadi tantangan berarti bagi keduanya.

3.2 Kinerja pada 250 Pengguna Bersamaan

Pengujian kedua meningkatkan beban menjadi 250 pengguna bersamaan untuk mengamati perilaku kedua platform pada kondisi menengah. Hasil disajikan pada Tabel 5.

Tabel 5. Hasil Pengujian pada 250 Pengguna Bersamaan

Metrik	GCP	AWS	Analisis Komparatif
Rata-rata Respons	718 ms	490 ms	AWS berbalik lebih cepat seiring bertambahnya beban
Respons Maksimal	59.813 ms	2.409 ms	GCP mengalami bottleneck ekstrem; AWS tetap responsif
Tingkat Error	0,25%	1,02%	GCP mempertahankan rasio keberhasilan lebih baik
Throughput	4,0 req/s	8,9 req/s	AWS memproses lebih dari dua kali lipat lebih cepat
Beban CPU	8,1%	3,6%	AWS mengeksekusi thread lebih efisien
Penggunaan RAM	28,3%	28,4%	Manajemen memori identik dan stabil

Berdasarkan Tabel 5, skenario 250 pengguna menandai titik balik penting dalam perilaku komparatif kedua platform. Waktu respons maksimal GCP melonjak drastis ke 59.813 ms, naik 556% dari skenario 100 pengguna, yang mengindikasikan bottleneck internal parah, kemungkinan akibat kehabisan thread pool atau saturasi antrean koneksi pada konfigurasi IaaS. Sebaliknya, AWS mempertahankan respons maksimal hanya 2.409 ms, menunjukkan resiliensi arsitektur yang tidak dimiliki GCP pada beban menengah ini. Data utilisasi CPU semakin memperkuat keunggulan efisiensi AWS, yang hanya mengonsumsi 3,6% CPU untuk mengelola beban yang mendorong GCP hingga 8,1%, mengindikasikan penjadwalan thread tingkat kernel yang lebih efektif. Meskipun demikian, GCP tetap mempertahankan keunggulan keandalan dengan tingkat error 0,25% berbanding 1,02% pada AWS, sebuah pola yang konsisten di seluruh tingkat beban dan layak menjadi pertimbangan bagi institusi yang menempatkan integritas koneksi di atas volume throughput. Temuan ini menunjukkan bahwa pada beban menengah, keunggulan masing-masing platform mulai terpolarisasi secara jelas.

3.3 Kinerja pada 500 Pengguna Bersamaan

Pengujian ketiga menerapkan beban maksimal 500 pengguna bersamaan untuk menguji batas kapasitas kedua platform. Hasil disajikan pada Tabel 6.

Tabel 6. Hasil Pengujian pada 500 Pengguna Bersamaan

Metrik	GCP	AWS	Analisis Komparatif
Rata-rata Respons	560 ms	504 ms	Seimbang, AWS sedikit unggul
Respons Maksimal	9.991 ms	2.155 ms	AWS sangat konsisten; GCP pulih dari lonjakan 250 user
Tingkat Error	0,15%	0,58%	Keduanya di bawah ambang toleransi 5%
Throughput	6,6 req/s	11,7 req/s	Kapasitas pemrosesan AWS jauh meninggalkan GCP



Metrik	GCP	AWS	Analisis Komparatif
Beban CPU	8,2%	23,1%	GCP unggul stabilitas OS; AWS mulai kewalahan
Penggunaan RAM	28,6%	32,2%	RAM AWS naik menahan antrean sistem

Berdasarkan Tabel 6, pada beban maksimal tersimulasi, lanskap kinerja sebagian berkonvergensi sekaligus mengungkap tanda tekanan baru. Waktu respons rata-rata GCP pulih ke 560 ms, membaik nyata dari 718 ms pada skenario 250 pengguna, yang menunjukkan mekanisme penjadwalan internalnya stabil pada konkurensi berkelanjutan yang lebih tinggi. AWS terus memimpin throughput dengan 11,7 berbanding 6,6 permintaan per detik dan mempertahankan batas respons maksimal yang konsisten pada 2.155 ms. Namun, utilisasi CPU AWS naik ke 23,1% dengan beban sistem mencapai 72,0%, menandakan mendekatnya ambang penskalaan yang akan memerlukan ekspansi sumber daya vertikal atau horizontal pada kondisi produksi. GCP, yang beroperasi pada 8,2% CPU dan 19,0% beban sistem, menunjukkan headroom infrastruktur yang lebih unggul, suatu keunggulan yang langsung berdampak pada biaya tambahan lebih rendah saat penskalaan ke penerapan institusional yang lebih besar. Kedua platform tetap berada di bawah ambang tingkat error 5% yang dianggap dapat diterima untuk beban aplikasi web, menegaskan bahwa keduanya layak secara operasional pada beban 500 pengguna.

3.4 Analisis Tren Lintas Beban

Selain analisis per skenario, pemahaman yang lebih dalam diperoleh dengan menelaah bagaimana setiap metrik berubah ketika beban meningkat dari 100 ke 250 hingga 500 pengguna. Pada waktu respons rata-rata, GCP memperlihatkan pola non-linear yang khas: latensi memburuk tajam dari 237 ms menjadi 718 ms saat beban naik ke 250 pengguna, lalu justru membaik kembali ke 560 ms pada 500 pengguna. Pola ini mengindikasikan mekanisme penjadwalan internal GCP mengalami fase transisi yang tidak stabil pada beban menengah sebelum menemukan keseimbangan pada konkurensi tinggi. Sebaliknya, AWS menunjukkan tren yang jauh lebih landai dan dapat diprediksi, bergerak dari 602 ms ke 490 ms lalu 504 ms, yang justru membaik seiring bertambahnya beban. Karakteristik ini menunjukkan AWS dioptimalkan untuk beban tinggi, sementara GCP lebih efisien pada beban ringan.

Pada throughput, tren keduanya meningkat secara monoton namun dengan laju berbeda. AWS naik dari 7,7 ke 8,9 lalu 11,7 permintaan per detik, sedangkan GCP naik dari 2,2 ke 4,0 lalu 6,6 permintaan per detik. Selisih yang konsisten ini menegaskan AWS memiliki kapasitas pemrosesan paralel yang secara fundamental lebih tinggi pada konfigurasi setara. Yang paling menarik adalah tren utilisasi CPU: GCP mempertahankan konsumsi relatif stabil (4,2%, 8,1%, 8,2%), sedangkan AWS melonjak dari 8,2% dan 3,6% menjadi 23,1% pada 500 pengguna. Lonjakan ini menunjukkan strategi AWS memaksimalkan throughput dibayar dengan konsumsi CPU yang jauh lebih agresif pada beban puncak, sehingga ambang penskalaannya tercapai lebih cepat dibanding GCP.

Secara teknis, perbedaan perilaku kedua platform dapat dijelaskan melalui mekanisme pengelolaan sumber daya pada lapisan IaaS. Lonjakan waktu respons maksimal GCP yang ekstrem pada beban 250 pengguna mengindikasikan terjadinya antrean permintaan yang menumpuk akibat keterbatasan kapasitas pemrosesan thread secara simultan, kondisi yang dikenal sebagai thread pool saturation. Ketika jumlah permintaan masuk melampaui kapasitas thread tersedia, sebagian permintaan menunggu dalam antrean sehingga menghasilkan latensi puncak yang sangat tinggi meskipun rata-rata latensi tetap wajar. AWS tampak menerapkan strategi manajemen antrean yang lebih agresif dengan mengalokasikan lebih banyak sumber daya CPU untuk memproses permintaan secara paralel, yang menjelaskan throughput lebih tinggi sekaligus konsumsi CPU yang melonjak pada beban puncak.

3.5 Pembahasan dan Rekomendasi Berbasis AHP

Sintesis temuan menunjukkan kedua platform memiliki profil kinerja yang berbeda dan saling melengkapi, bukan saling mengungguli secara mutlak. AWS unggul dalam throughput dan konsistensi respons maksimal, sedangkan GCP unggul dalam keandalan koneksi, stabilitas sistem operasi, dan efisiensi biaya 27,7% lebih murah. Untuk mengubah trade-off ini menjadi keputusan yang dapat ditindaklanjuti, keempat kriteria dievaluasi melalui metode AHP.

Langkah pertama menetapkan bobot prioritas antar kriteria melalui matriks perbandingan berpasangan berskala Saaty 1 sampai 9, dengan asumsi institusi pendidikan berbeban sinkron menempatkan kinerja sebagai prioritas tertinggi diikuti keandalan, biaya, dan integrasi. Matriks perbandingan berpasangan ditunjukkan pada Tabel 7. Konsistensi penilaian diverifikasi melalui perhitungan Consistency Ratio dan diperoleh nilai CR sebesar 0,041 yang berada di bawah ambang 0,10, sehingga matriks dinyatakan konsisten dan dapat diterima.

Tabel 7. Matriks Perbandingan Berpasangan Kriteria AHP

Kriteria	Kinerja	Keandalan	Biaya	Integrasi
Kinerja	1	2	2	4
Keandalan	1/2	1	2	3
Biaya	1/2	1/2	1	2
Integrasi	1/4	1/3	1/2	1

Dari matriks pada Tabel 7, normalisasi kolom dan perataan baris menghasilkan bobot akhir sebesar 0,40 untuk kinerja, 0,30 untuk keandalan, 0,20 untuk biaya, dan 0,10 untuk integrasi. Langkah kedua memberikan skor pada setiap



platform untuk masing-masing kriteria berdasarkan data empiris. Hasil akhir penggabungan bobot dan skor dirangkum pada Tabel 8.

Tabel 8. Skor Evaluasi AHP Antar Kriteria

Kriteria AHP	Bobot	Skor GCP	Skor AWS	Unggul
Kinerja (Throughput & Latensi)	0,40	0,65	0,85	AWS
Keandalan (Error & Stabilitas)	0,30	0,88	0,72	GCP
Biaya (Efisiensi Sumber Daya)	0,20	0,82	0,66	GCP
Integrasi (Kemudahan Penerapan)	0,10	0,75	0,78	AWS
Total Berbobot	1,00	0,762	0,768	AWS

Berdasarkan Tabel 8, total berbobot AHP menghasilkan skor 0,768 untuk AWS berbanding 0,762 untuk GCP, selisih yang sangat tipis. Margin sempit ini menegaskan tidak terdapat pemenang absolut, melainkan rekomendasi yang bersifat kontekstual. Institusi dengan ekspektasi pengguna bersamaan lebih rendah atau anggaran lebih ketat dapat memperoleh rekomendasi berbeda dengan menyesuaikan bobot kriteria, dan dalam hal ini GCP akan dengan mudah mengungguli AWS karena keunggulan biaya dan keandalannya.

3.6 Pembahasan: Perbandingan dengan Penelitian Terdahulu

Temuan penelitian ini dikonfirmasi dan sekaligus diperluas oleh beberapa penelitian sebelumnya. Noviani dkk. [10] yang membandingkan AWS dan GCP pada beban kerja komputasi umum juga menemukan keunggulan throughput AWS yang konsisten, selaras dengan temuan penelitian ini (11,7 vs 6,6 req/s pada 500 pengguna). Namun penelitian ini memperluas temuan Noviani dkk. dengan konteks yang lebih spesifik, beban kerja LMS Moodle dengan pola HTTP bersamaan yang realistis, serta mengungkap dimensi baru berupa keunggulan GCP pada keandalan error rate dan efisiensi biaya yang tidak dikaji dalam studi tersebut.

Çapari dkk. [6] menemukan variasi kinerja yang signifikan antara platform cloud pada beban aplikasi web multipengguna, khususnya pada metrik latensi dan throughput. Penelitian ini mengkonfirmasi pola tersebut sekaligus menambahkan interpretasi mekanisme teknis (thread pool saturation pada GCP di beban 250 pengguna) yang tidak dibahas Çapari dkk., serta menempatkannya dalam konteks LMS yang lebih operasional. Sementara itu, Niemcewicz dkk. [9] menerapkan AHP untuk pemilihan penyedia cloud dan merekomendasikan pembobotan kinerja sebagai kriteria tertinggi, konsisten dengan bobot 0,40 yang ditetapkan dalam penelitian ini berdasarkan kebutuhan institusi pendidikan dengan beban pembelajaran sinkron.

Dari perspektif adopsi cloud dalam pendidikan, Yegon dkk. [4] melaporkan bahwa penerapan IaaS meningkatkan ketersediaan LMS dan mengurangi downtime, yang dalam kerangka penelitian ini berkorelasi dengan temuan keunggulan GCP pada tingkat error yang lebih rendah (0,12%–0,25%) — sebuah validasi empiris atas klaim kualitatif Yegon dkk. AlAjmi [2] menekankan efisiensi biaya sebagai faktor adopsi utama di pendidikan tinggi, selaras dengan temuan penelitian ini bahwa GCP 27,7% lebih murah dari AWS pada konfigurasi setara, menjadikannya pilihan yang lebih sesuai secara ekonomis bagi institusi dengan anggaran terbatas.

Secara keseluruhan, penelitian ini tidak hanya mengkonfirmasi pola umum yang ditemukan studi sebelumnya, tetapi juga menjembatani gap metodologis yang tidak terpenuhi oleh satu pun studi terdahulu: memadukan pengujian beban empiris berbasis JMeter pada beban LMS nyata, perbandingan langsung AWS dan GCP, serta evaluasi multikriteria AHP dalam satu kerangka terpadu yang menghasilkan rekomendasi terukur dan dapat dikalibrasi ulang oleh institusi lain.

4. KESIMPULAN

Pengujian beban empiris pada beban kerja LMS Moodle membuktikan bahwa AWS dan GCP memiliki profil kinerja yang saling melengkapi: AWS unggul pada throughput (hingga 11,7 req/s) dan konsistensi respons maksimal, sedangkan GCP unggul pada keandalan error rate (serendah 0,12%) dan efisiensi biaya (27,7% lebih murah). Evaluasi Analytical Hierarchy Process dengan CR = 0,041 menghasilkan skor 0,768 untuk AWS dan 0,762 untuk GCP, menjadikan AWS rekomendasi utama bagi institusi berbeban pengguna tinggi, sementara GCP lebih sesuai bagi institusi yang mengutamakan keandalan dan anggaran. Kontribusi utama penelitian ini adalah kerangka evaluasi terpadu pertama yang memadukan pengujian beban empiris JMeter pada beban LMS nyata dengan metode AHP multikriteria, menghasilkan rekomendasi berbasis data yang dapat dikalibrasi ulang sesuai prioritas institusi, sekaligus menyediakan arsitektur pengujian berbasis Docker yang portabel dan replikatif sebagai acuan implementasi. Penelitian mendatang disarankan mengkaji perilaku auto-scaling, mengintegrasikan trafik mahasiswa nyata, serta memperluas perbandingan ke topologi multi-cloud.

REFERENCES

- [1] M. Al-Fraihat, M. Joy, R. Masa'deh, and J. Sinclair, "Evaluating e-learning systems success: An empirical study," *Comput. Human Behav.*, vol. 102, pp. 67–86, Jan. 2020, doi: 10.1016/j.chb.2019.08.004.
- [2] Q. AlAjmi, "Adoption model for cloud-based e-learning in higher education," in *Advances on Intelligent Computing and Data Science*, LNDECT, vol. 179, Cham: Springer, 2023, pp. 569–580, doi: 10.1007/978-3-031-36258-3_51.



- [3] C. M. Mohammed and S. R. M. Zeebaree, "Sufficient comparison among cloud computing services: IaaS, PaaS, and SaaS: A review," *Int. J. Sci. Bus.*, vol. 5, no. 2, pp. 17–30, 2021, doi: 10.5281/zenodo.4450129.
- [4] E. Yegon, R. Rono, and Y. Etene, "Infrastructure as a service for sustainable learning management system in public universities in Kenya," *Int. J. Res. Innov. Soc. Sci.*, vol. 9, no. 7, pp. 276–284, Jul. 2025. [Online]. Available: <https://www.rsinternational.org>
- [5] F. Thabit and Y. Aburezeq, "Cloud computing for developing e-learning systems," in *Proc. Int. Arab Conf. Inf. Technol. (ACIT)*, Dec. 2021, pp. 1–6, doi: 10.1109/ACIT54780.2021.9671346.
- [6] K. Çapari, D. Elmazi, and M. Prieditis, "Efficiency performance evaluation on multi-user web application platforms in cloud computing," *Int. J. Innov. Technol. Interdiscip. Sci.*, vol. 5, no. 3, pp. 1014–1032, 2022, doi: 10.1515/IJITIS.2022.5.3.1014-1032.
- [7] I. Indrianto, "Performance testing on web information system using Apache JMeter and BlazeMeter," *J. Ilm. Ilmu Terap. Univ. Jambi*, vol. 7, no. 2, pp. 138–149, Dec. 2023, doi: 10.22437/jiituj.v7i2.28440.
- [8] J. van Riet, I. Malavolta, and T. A. Ghaleb, "Optimize along the way: An industrial case study on web performance," *J. Syst. Softw.*, vol. 198, p. 111593, Apr. 2023, doi: 10.1016/j.jss.2022.111593.
- [9] P. Niemcewicz, K. Hauke, and M. Owoc, "The use of the multi-criteria AHP method to select a cloud computing provider," *Procedia Comput. Sci.*, vol. 192, pp. 2558–2567, 2021, doi: 10.1016/j.procs.2021.09.025.
- [10] Noviani, P. Handayani, and A. Junaedi, "Performance analysis of AWS and GCP cloud providers," in *Proc. IEEE Int. Conf. Cybern. Comput. Intell. (CyberneticsCom)*, Jun. 2022, pp. 1–6, doi: 10.1109/CyberneticsCom55287.2022.9865532.
- [11] C. Fountzoula and K. Aravossis, "Analytic hierarchy process and its applications in the public sector: A review," *Acad. Account. Financ. Stud. J.*, vol. 25, no. 6, pp. 1–13, 2021. [Online]. Available: <https://www.abacademies.org>
- [12] S. Jamal and H. Wimmer, "Performance analysis of machine learning algorithms on cloud platforms: AWS vs Azure vs GCP," in *Advances Intell. Syst. Comput.*, Cham: Springer, 2023, pp. 42–55, doi: 10.1007/978-3-031-31353-0_5.
- [13] L. Sanchez, J. Penarreta, and X. Soria Poma, "Learning management systems for higher education: A brief comparison," *Discover Educ.*, vol. 3, no. 1, pp. 1–15, May 2024, doi: 10.1007/s44217-024-00143-5.
- [14] M. Bolanowski, M. Ćmil, and A. Starzec, "New model for defining and implementing performance tests," *Future Internet*, vol. 16, no. 10, p. 366, Oct. 2024, doi: 10.3390/fi16100366.
- [15] O. Dahham and H. Fawareh, "E-learning migration model for cloud-based education," in *Proc. 23rd Int. Arab Conf. Inf. Technol. (ACIT)*, Nov. 2022, pp. 1–6, doi: 10.1109/ACIT57182.2022.9994064.
- [16] K. Wiechork and A. S. Charão, "Investigating the performance of Moodle database queries in cloud environments," in *Proc. 22nd Int. Conf. Enterp. Inf. Syst. (ICEIS)*, May 2020, vol. 1, pp. 269–275, doi: 10.5220/0009451802690275.
- [17] M. Zbril and V. Svatá, "Comparison of cloud service consumption in the Czech Republic, Visegrád Group and European Union," *E&M Econ. Manag.*, vol. 25, no. 3, pp. 158–173, 2022, doi: 10.15240/tul/001/2022-3-010.
- [18] K. Jewargi, "What is cloud computing? Benefits and challenges of cloud," *Glob. J. Comput. Sci. Theory Res.*, vol. 13, no. 1, pp. 1–12, 2023. [Online]. Available: <https://globaljournals.org>
- [19] A. Almazroi, "Cloud-based e-learning adoption determinants in higher education: An empirical study," *Educ. Inf. Technol.*, vol. 27, no. 6, pp. 8231–8256, Nov. 2022, doi: 10.1007/s10639-022-10919-7.
- [20] H. Hussein and M. F. Hilmi, "Cloud computing based e-learning in Malaysian universities," *Int. J. Emerg. Technol. Learn.*, vol. 15, no. 8, pp. 4–21, 2020, doi: 10.3991/ijet.v15i08.12401.
- [21] R. Walker and J. Voce, "Post-pandemic learning technology developments in UK higher education," *Sustainability*, vol. 15, no. 17, p. 12831, Aug. 2023, doi: 10.3390/su151712831.
- [22] G. Kabra, V. Ghosh, and Y. Joshi, "Factors influencing adoption of cloud computing services in higher education institutions," *Cogent Bus. Manag.*, vol. 10, no. 2, p. 2220190, 2023, doi: 10.1080/23311975.2023.2220190.