

RUDYCT ACADEMIC SERIES 2026

Pilar-Pilar AI

Kerangka Socioteknis untuk AI yang Bernilai, Andal, dan Bertanggung Jawab

1. Data

2. Algoritma dan Model

3. Komputasi dan Infrastruktur

4. Manusia dan Kompetensi

5. Strategi, Proses, dan Nilai Organisasi

6. Tata Kelola, Etika, Keamanan, dan Akuntabilitas


7. Ekosistem Inovasi dan Kedaulatan Teknologi

Oleh: Prof Ir Rudy C Tarumingkeng, PhD

www.rudycr.com/cv.pdf

PILAR UTAMA AI

Fondasi Sosioteknis untuk AI yang
Bernilai, Andal, dan Bertanggung Jawab



AI BERDAMPAK =

DATA × MODEL × KOMPUTASI × MANUSIA ×
STRATEGI × TATA KELOLA × EKOSISTEM

Ketujuh pilar saling bergantung—
kelemahan satu pilar membatasi
keseluruhan sistem.



Oleh:
Prof Ir Rudy C Tarumingkeng, PhD

www.rudyc.com/cv.pdf



Abstrak

Kecerdasan artifisial tidak lahir dari satu teknologi tunggal dan tidak menghasilkan nilai hanya karena organisasi membeli perangkat lunak atau mengakses model yang canggih. AI merupakan sistem sosioteknis yang ditopang oleh tujuh pilar yang saling bergantung: data; algoritma dan model; komputasi dan infrastruktur; manusia dan kompetensi; strategi, proses, dan nilai organisasi; tata kelola, etika, keamanan, dan akuntabilitas; serta ekosistem inovasi dan kedaulatan teknologi. Artikel ini menjelaskan ketujuh pilar tersebut secara naratif dan integratif. Data menyediakan bahan pembelajaran; model mengubahnya menjadi pola dan keluaran; komputasi menentukan skala, biaya, serta ketahanan; manusia menetapkan tujuan dan menilai konteks; strategi menghubungkan kemampuan teknis dengan outcome; tata kelola memberi batas dan mekanisme koreksi; sedangkan ekosistem menentukan kemampuan belajar, bekerja sama, dan mempertahankan nilai dalam jangka panjang. Dengan pendekatan sistem, keberhasilan AI lebih tepat dipahami sebagai hasil perkalian daripada penjumlahan: kelemahan serius pada satu pilar dapat membatasi keseluruhan sistem. Pembahasan mencakup studi kasus kesehatan, pendidikan, pemerintahan, UMKM, pertanian, dan manajemen; model kematangan organisasi; indikator kinerja; serta peta jalan Indonesia. Kesimpulan utamanya ialah bahwa AI yang bernilai harus kompeten secara teknis, layak secara ekonomi, relevan secara sosial, aman secara operasional, dan dapat dipertanggungjawabkan secara moral maupun kelembagaan.

Kata Kunci: kecerdasan artifisial; pilar AI; data; algoritma; model AI; komputasi; kompetensi manusia; strategi AI; tata kelola AI; etika AI; ekosistem inovasi; Indonesia

TESIS UTAMA

**AI berdampak = Data × Model × Komputasi × Manusia × Strategi × Tata Kelola × Ekosistem.
Kelemahan serius pada satu pilar membatasi keseluruhan sistem.**

Ringkasan Eksekutif

Artikel ini memakai istilah tujuh pilar AI untuk menunjukkan bahwa kecerdasan artifisial tidak boleh direduksi menjadi model. Organisasi memperoleh nilai ketika data yang sah diproses oleh model yang sesuai, dijalankan pada infrastruktur yang andal, dipakai oleh manusia yang kompeten, dihubungkan dengan strategi dan proses, dibatasi oleh tata kelola yang nyata, serta ditopang ekosistem inovasi. Ketujuh pilar membentuk satu sistem. Karena hubungan itu bersifat saling melengkapi, keberhasilan lebih dekat kepada logika perkalian daripada penjumlahan. Satu kelemahan kritis dapat menghapus manfaat faktor lain. Model terbaik tidak menyelamatkan data yang salah; data yang baik tidak cukup

tanpa pengguna yang mampu menafsirkan; dan hasil yang akurat tidak legitimate bila tidak ada akuntabilitas.

Faktor data mencakup lebih dari volume. Data harus mempunyai provenance, mutu, keterwakilan, keamanan, hak penggunaan, dan kesesuaian tujuan. Data adalah representasi dunia yang selalu dipilih dan dibentuk oleh institusi. Karena itu, bias bukan semata cacat statistik; ia dapat berasal dari siapa yang terlihat, bagaimana label dibuat, keputusan sejarah apa yang direkam, dan kelompok mana yang tidak mempunyai jejak digital. Strategi data yang matang mengelola seluruh siklus hidup dari perolehan hingga penghapusan, mendokumentasikan transformasi, menguji subkelompok, dan memberi mekanisme koreksi. Bagi Indonesia, representasi bahasa daerah, wilayah kepulauan, praktik informal, dan variasi kualitas layanan merupakan agenda strategis.

Faktor algoritma dan model menentukan cara sistem belajar serta menghasilkan keluaran. Pilihan model perlu berangkat dari karakter masalah, bukan popularitas teknologi. Evaluasi harus menghubungkan metrik teknis dengan konsekuensi: false positive dan false negative mempunyai biaya yang berbeda; akurasi agregat dapat menyembunyikan ketidakadilan; dan kefasihan model generatif dapat menyamarkan halusinasi. Organisasi perlu membandingkan baseline sederhana, melakukan uji stres, red teaming, evaluasi subkelompok, dan pemantauan drift. Dokumentasi seperti model cards membuat tujuan, performa, dan keterbatasan dapat ditelusuri. Pada keputusan berisiko tinggi, interpretabilitas dan kemampuan keberatan lebih penting daripada tambahan skor yang kecil.

Faktor komputasi dan infrastruktur menentukan apakah AI dapat beroperasi pada skala yang dibutuhkan, dengan latensi, biaya, reliabilitas, privasi, dan ketahanan yang dapat diterima. Pilihan cloud, edge, on-premise, atau hybrid tidak bersifat ideologis; ia harus mengikuti kebutuhan. Di negara kepulauan, model kecil yang berjalan offline dapat lebih berguna daripada model besar yang bergantung pada koneksi. Efisiensi perlu diukur melalui biaya dan energi per outcome yang berhasil. Kedaulatan AI tidak berarti membuat semua komponen sendiri, tetapi memiliki pilihan, kontrol atas data penting, kemampuan audit, interoperabilitas, serta exit strategy dari vendor. Infrastruktur digital dan energi harus direncanakan secara terpadu.

Faktor manusia dan kompetensi menempatkan AI sebagai perubahan pekerjaan dan organisasi. Manusia menetapkan tujuan, menilai konteks, menangani pengecualian, dan bertanggung jawab atas keputusan. Human-in-the-loop harus mempunyai makna operasional: titik intervensi, informasi, waktu, kewenangan, dan kemampuan override. Pelatihan harus berbasis peran, dari literasi dewan direksi sampai MLOps, keamanan, audit, dan desain interaksi. Reskilling tidak cukup mengajarkan satu aplikasi; ia harus memperkuat problem framing, literasi data, verifikasi, penalaran, komunikasi, kreativitas, dan etika. Kepemimpinan perlu mengelola rasa takut, hype, insentif, redesign proses, dan pembagian manfaat produktivitas.

Pilar strategi, proses, dan nilai organisasi menjawab pertanyaan mengapa AI digunakan dan perubahan apa yang hendak dicapai. Use case harus berangkat dari masalah, baseline, pemilik proses, dan outcome yang terukur. Implementasi kemudian mengubah alur kerja, hak keputusan, insentif, struktur biaya, serta hubungan dengan pengguna. Tanpa pilar ini, organisasi mudah terjebak pada pilot yang menarik tetapi tidak pernah masuk operasi, atau otomatisasi yang mempercepat proses yang sebenarnya tidak bernilai. Kepemimpinan perlu mengelola portofolio, menetapkan stage gate, mendesain ulang pekerjaan, dan menghentikan proyek yang tidak membuktikan manfaat.

Faktor tata kelola dan etika menerjemahkan nilai menjadi struktur keputusan. Prinsip kemanfaatan, keadilan, privasi, transparansi, keamanan, robustness, dan akuntabilitas harus muncul sebagai kontrol konkret: klasifikasi risiko, impact assessment, dokumentasi, review lintas fungsi, audit, monitoring, incident response, dan jalur pemulihan. Governance harus proporsional. Aplikasi rendah risiko tidak memerlukan prosedur seberat sistem yang memengaruhi kesehatan, pendidikan, pekerjaan, kredit, bantuan sosial, atau hak warga. Namun pada semua tingkat, institusi tidak boleh mengalihkan tanggung jawab kepada vendor atau operator. Akuntabilitas berarti mampu menjelaskan, membuktikan kehati-hatian, memperbaiki, dan menerima konsekuensi.

Pilar ekosistem inovasi dan kedaulatan teknologi menegaskan bahwa tidak ada organisasi atau negara yang membangun AI sendirian. Implikasi strategis bagi Indonesia adalah perlunya membangun ekosistem, bukan sekadar mengimpor aplikasi atau mengejar simbol model nasional. Ekosistem mencakup corpus lokal yang sah, benchmark publik, komputasi bersama untuk riset, talenta lintas disiplin, dukungan startup, pengadaan yang cerdas, pusat keahlian, keamanan, dan regulasi berbasis risiko. Prioritas dapat diarahkan pada kesehatan primer, pendidikan, pertanian, perikanan, kehutanan, kebencanaan, layanan publik, dan UMKM. Peta jalan perlu menyatakan outcome, pemilik, indikator pemerataan, mekanisme evaluasi independen, dan dukungan bagi daerah dengan kapasitas lebih rendah. Dengan cara ini, AI menjadi instrumen pembangunan manusia dan kelembagaan.

Rekomendasi pelaksanaannya adalah memulai dari portofolio kecil namun terukur. Tetapkan baseline sebelum AI, pilih masalah bernilai, klasifikasikan risiko, periksa kesiapan ketujuh pilar, dan jalankan pilot yang reversibel. Setiap tahap harus mempunyai keputusan go, revise, atau stop. Ukur outcome, kualitas, adopsi, biaya, energi, fairness, insiden, dan pembelajaran; jangan hanya menghitung pengguna atau jumlah otomatisasi. Bangun dokumentasi dan observability sejak awal agar kesalahan dapat direkonstruksi. Organisasi yang matang bukan organisasi yang tidak pernah gagal, melainkan yang mampu menemukan kegagalan lebih dini, membatasi dampaknya, belajar, dan memperbaiki secara transparan.

Dengan demikian, artikel ini dapat dibaca dalam dua lapisan. Pembaca yang membutuhkan orientasi strategis dapat memakai kerangka tujuh pilar sebagai alat diagnosis: temukan faktor pembatas, tetapkan prioritas, dan hubungkan investasi dengan outcome. Pembaca yang bertanggung

jawab atas implementasi dapat memakai uraian siklus hidup, model kematangan, indikator, serta studi kasus sebagai pedoman penyusunan kontrol. Pada kedua lapisan, pesan dasarnya sama: teknologi harus ditempatkan di dalam tujuan manusia dan kapasitas institusi. AI yang cepat tetapi tidak dapat diperiksa akan rapuh; AI yang akurat tetapi tidak adil akan kehilangan legitimasi; dan AI yang murah tetapi mengikis kompetensi akan menimbulkan biaya jangka panjang. Keunggulan berkelanjutan lahir dari keseimbangan antara inovasi, pembelajaran, efisiensi, ketahanan, serta tanggung jawab.

Peta Pembahasan

- Landasan konseptual: AI sebagai sistem sosioteknis dan kerangka tujuh pilar.
- Pilar 1 - Data: kualitas, bias, representasi, privasi, dan siklus hidup.
- Pilar 2 - Algoritma dan model: evaluasi, explainability, foundation models, dan AI generatif.
- Pilar 3 - Komputasi: cloud-edge, efisiensi, energi, dan kedaulatan infrastruktur.
- Pilar 4 - Manusia: kompetensi, human-in-the-loop, kolaborasi, dan reskilling.
- Pilar 5 - Strategi dan proses: kepemimpinan, perubahan, portofolio, dan penciptaan nilai.
- Pilar 6 - Tata kelola: etika, audit, akuntabilitas, keamanan, dan manajemen insiden.
- Pilar 7 - Ekosistem: riset, industri, kebijakan, standar, dan kedaulatan teknologi.
- Integrasi: studi kasus, model kematangan, peta jalan, indikator, dan masa depan AI.

1. Pendahuluan: AI sebagai Sistem Sosioteknis

Pokok persoalan dalam bagian ini adalah AI lebih tepat dipahami sebagai susunan teknologi, manusia, proses, institusi, dan nilai yang bekerja bersama. Model yang tampak cerdas pada layar sesungguhnya bergantung pada rantai panjang pengumpulan data, pemilihan tujuan, desain antarmuka, penyediaan komputasi, pengawasan manusia, dan keputusan mengenai siapa yang menanggung risiko. Perspektif tersebut menggeser pembicaraan dari pertanyaan sempit mengenai kemampuan perangkat menjadi pertanyaan manajerial mengenai kesesuaian, keterhubungan, dan konsekuensi. Dalam sistem AI, sebuah komponen tidak pernah benar-benar berdiri sendiri. Ia menerima masukan dari komponen lain, mengubah perilaku organisasi, lalu menghasilkan umpan balik yang dapat memperkuat manfaat maupun memperbesar risiko. Karena itu, analisis perlu memperhatikan proses sebelum model dijalankan, keputusan ketika keluaran digunakan, dan dampak setelah keputusan terjadi.

Secara analitis, ruang lingkupnya dapat diuraikan sebagai berikut. Pertama, kecerdasan mesin bersifat terikat tugas dan konteks. Kedua, keluaran probabilistik tidak sama dengan kebenaran. Ketiga, adopsi organisasi selalu mengubah pembagian kerja dan wewenang. Keempat, dampak AI muncul setelah hasil model masuk ke keputusan nyata. Unsur-unsur tersebut tidak sebaiknya

diperlakukan sebagai daftar pemeriksaan yang mekanis. Hubungan di antaranya perlu dicari: peningkatan pada satu dimensi mungkin memperburuk dimensi lain, dan penghematan pada tahap awal dapat menimbulkan biaya koreksi yang lebih besar kemudian. Pendekatan yang matang selalu menyatakan trade-off, asumsi, serta batas penerapan.

Sebuah ilustrasi membantu memperjelasnya. Sebuah rumah sakit dapat membeli sistem prediksi risiko pasien, tetapi manfaatnya baru muncul jika data rekam medis konsisten, dokter memahami batas model, infrastruktur tersedia saat dibutuhkan, dan prosedur klinis menentukan kapan rekomendasi boleh diikuti atau harus ditolak. Kasus ini menunjukkan bahwa nilai AI bersifat kontekstual. Model yang sama dapat berhasil di satu tempat dan gagal di tempat lain karena perbedaan populasi, alur kerja, tujuan, atau kapasitas. Pilot karena itu bukan sekadar uji perangkat, melainkan uji hipotesis tentang sistem kerja baru.

Risiko utama muncul ketika asumsi tidak terlihat. Kesalahan umum adalah menyamakan demonstrasi yang mengesankan dengan kesiapan produksi. Prototipe dapat bekerja pada sampel bersih, lalu gagal ketika menghadapi bahasa lokal, data hilang, perubahan perilaku pengguna, serangan keamanan, atau tuntutan akuntabilitas. Masalah ini sering membesar secara perlahan karena keluaran yang salah tidak selalu langsung menimbulkan keluhan. Kelompok yang dirugikan mungkin tidak mengetahui bahwa AI terlibat, tidak memiliki kanal keberatan, atau tidak mempunyai data pembandingan. Karena itu, ketiadaan insiden yang dilaporkan bukan bukti ketiadaan kerugian.

Implikasi manajerialnya adalah Pimpinan perlu memulai dari masalah dan konsekuensi, bukan dari produk. Pertanyaan pertama bukan model apa yang paling besar, melainkan keputusan apa yang hendak diperbaiki, bukti apa yang cukup, siapa pemilik proses, dan bagaimana kerugian dapat dideteksi serta dipulihkan. Keputusan tersebut perlu diterjemahkan ke dalam pemilik, jadwal, anggaran, bukti, dan ambang. Tanpa kelima unsur itu, rekomendasi berubah menjadi aspirasi. Dewan atau pimpinan juga perlu menerima laporan tentang asumsi dan ketidakpastian, bukan hanya keberhasilan proyek.

Konteks nasional dan lokal menambah lapisan penting. Bagi Indonesia, pendekatan sistem penting karena kesenjangan kapasitas antardaerah, keragaman bahasa, ketimpangan kualitas data, dan variasi kematangan digital membuat satu solusi nasional tidak selalu dapat dipindahkan tanpa adaptasi lokal. Kebijakan harus mempertimbangkan bahwa kapasitas tidak merata. Standar nasional perlu menjaga hak dan interoperabilitas, sedangkan implementasi memberi ruang adaptasi sektoral serta lokal. Pendekatan berlapis ini lebih realistis daripada satu solusi untuk semua.

Landasan ilmiah memperkuat argumen tersebut. Rahwan et al. (2019) mengusulkan studi perilaku mesin di lingkungan nyata, sedangkan Stanford AI Index 2026 menyoroti kesenjangan yang melebar antara kemampuan teknis AI dan kesiapan masyarakat untuk mengukur serta mengelolanya. Literatur ini tidak memberi resep tunggal, tetapi memberi cara berpikir: dokumentasikan asumsi, ukur

pada konteks penggunaan, libatkan pihak terdampak, dan pertahankan kemampuan koreksi. Dengan demikian, bukti ilmiah menjadi sarana pembelajaran organisasi.

Jika bagian ini dihubungkan kembali dengan kerangka tujuh pilar, terlihat pola sistemik. Mutu satu faktor menentukan beban faktor lain. Data yang lemah memaksa model bekerja lebih keras; model yang rumit menuntut komputasi dan keahlian lebih besar; antarmuka yang buruk meningkatkan risiko manusia; governance yang terlambat memperbesar biaya perubahan. Sebaliknya, dokumentasi, modularitas, dan pembelajaran lintas fungsi menciptakan efek pengungkit. Organisasi tidak harus sempurna sebelum memulai, tetapi harus mengetahui kelemahannya, membatasi ruang risiko, dan membangun jalur peningkatan.

Bagi pengambil keputusan, bagian ini dapat dijadikan bahan refleksi sebelum menyetujui investasi. Apakah manfaat yang dijanjikan mempunyai baseline dan indikator outcome? Apakah ketidakpastian disampaikan secara jujur? Apakah pengguna memiliki waktu dan kewenangan untuk memeriksa? Apakah kelompok terdampak dapat mengoreksi data dan keputusan? Apakah organisasi sanggup memelihara sistem setelah pilot berakhir? Pertanyaan-pertanyaan ini mengubah diskusi dari antusiasme teknologi menjadi tanggung jawab institusional. Jawaban tidak harus selalu sempurna, tetapi harus dibuktikan dan ditinjau ulang.

2. Kerangka Tujuh Pilar dan Logika Saling Ketergantungan

Kerangka tujuh pilar menyederhanakan kompleksitas tanpa mereduksi AI menjadi mesin semata. Data memberi pengalaman; algoritma membentuk cara belajar; komputasi menyediakan daya; manusia memberi tujuan dan penilaian; strategi menghubungkan teknologi dengan nilai; tata kelola menetapkan legitimasi dan tanggung jawab; sedangkan ekosistem menyediakan jaringan inovasi, standar, dan pembelajaran. Pernyataan ini penting karena banyak proyek AI dinilai terlalu awal dari penampilan demonstrasi. Keberhasilan sebenarnya baru dapat diketahui ketika sistem menghadapi variasi pengguna, data yang tidak sempurna, tekanan waktu, gangguan infrastruktur, dan tuntutan pertanggungjawaban. Dengan kata lain, kecerdasan teknis harus diterjemahkan menjadi kemampuan institusional. Terjemahan itu membutuhkan desain tujuan, proses, insentif, dan pengawasan yang konsisten.

Ada beberapa dimensi yang harus dibaca secara bersamaan. Setiap pilar mempunyai sisi kuantitatif dan kualitatif. Banyak data belum tentu representatif; model besar belum tentu sesuai; komputasi cepat belum tentu efisien; tenaga ahli belum tentu mampu berkolaborasi; strategi belum tentu menghasilkan nilai; kode etik belum tentu dilaksanakan; dan ekosistem yang ramai belum tentu mempunyai kemampuan domestik yang berkelanjutan. Masing-masing dapat diukur, tetapi angka tidak pernah berbicara tanpa konteks. Metrik harus disertai definisi, sumber, frekuensi, populasi, dan

ambang tindakan. Dengan disiplin ini, organisasi dapat membedakan sinyal yang benar-benar penting dari indikator yang sekadar mudah dikumpulkan.

Pertimbangkan contoh berikut. Dalam pemberian kredit UMKM, model dapat memiliki akurasi tinggi, tetapi tetap tidak bernilai jika data mengabaikan usaha informal, penjelasan tidak dipahami petugas, biaya inferensi terlalu besar, atau tidak ada jalur keberatan bagi pemohon yang ditolak. Yang perlu dicermati bukan hanya keluaran algoritma, tetapi juga siapa yang membaca, tindakan apa yang menyusul, dan apakah hasil aktual dapat kembali menjadi pembelajaran. Tanpa loop umpan balik, organisasi tidak mengetahui apakah prediksi meningkatkan outcome atau sekadar mengubah beban kerja.

Sisi kegagalannya tidak boleh dipandang sebagai pengecualian teknis. Organisasi sering mengoptimalkan satu faktor dan menganggap faktor lain akan mengikuti. Tim data mengejar akurasi tanpa memeriksa alur kerja, tim hukum menulis kebijakan tanpa memahami model, atau pimpinan membeli layanan awan tanpa menghitung ketergantungan pemasok. Kegagalan merupakan informasi tentang kelemahan sistem. Organisasi yang menghukum pelaporan akan kehilangan kesempatan belajar, sedangkan organisasi yang mengubah insiden menjadi perbaikan akan membangun ketahanan. Prinsip ini menuntut budaya tanpa rasa takut sekaligus tanggung jawab yang jelas.

Dari sudut pandang implementasi, Karena itu, ketujuh pilar sebaiknya dinilai sebagai portofolio kapabilitas. Investasi harus diarahkan kepada faktor pembatas yang paling kritis. Model sederhana dengan data baik dan proses manusia yang disiplin sering lebih bernilai daripada model mutakhir dalam ekosistem yang rapuh. Proses yang baik menyediakan jalur normal, jalur pengecualian, dan jalur penghentian. Ia juga menjaga pemisahan tugas antara pembangun, pemilik bisnis, validator, dan auditor agar konflik kepentingan dapat dikendalikan.

Relevansinya bagi pembangunan Indonesia terlihat jelas. Kerangka ini dapat menjadi alat diagnostik bagi kementerian, pemerintah daerah, universitas, rumah sakit, BUMN, dan perusahaan swasta. Ia membantu membedakan kebutuhan infrastruktur nasional dari kebutuhan kompetensi lokal dan kebutuhan tata kelola sektoral. Tantangan tersebut sekaligus peluang untuk membangun inovasi yang berangkat dari kebutuhan nyata. Keunggulan tidak selalu datang dari model terbesar; ia dapat datang dari data lokal yang bermutu, desain sederhana, biaya rendah, dan kepercayaan masyarakat.

Temuan penelitian yang relevan menyatakan bahwa Jöhnk, Weißert, dan Wyrтки (2021) menunjukkan bahwa kesiapan AI mencakup sumber daya, pengetahuan, keselarasan strategis, budaya, dan data. Mikalef dan Gupta (2021) juga menempatkan kapabilitas AI sebagai kombinasi sumber daya berwujud, manusia, dan tidak berwujud. Pelajaran pentingnya ialah bahwa inovasi dan kehati-hatian dapat berjalan bersama. Pengujian yang kuat bukan penghambat, melainkan mekanisme yang memungkinkan skala tumbuh tanpa kehilangan kendali.

Inti manajerialnya adalah keselarasan. Strategi, data, model, infrastruktur, kompetensi, proses, dan akuntabilitas harus menunjuk pada outcome yang sama. Bila satu unit mengejar volume, unit lain mengejar akurasi, dan pengguna mengejar kecepatan, sistem dapat menghasilkan optimasi lokal yang merusak tujuan keseluruhan. Keselarasan memerlukan bahasa bersama dan forum keputusan yang mempertemukan ahli teknis, pemilik proses, pengguna, hukum, keamanan, dan pihak terdampak.

Dari sisi pembelajaran organisasi, kualitas keputusan lebih penting daripada kecepatan peluncuran semata. Setiap eksperimen perlu menghasilkan pengetahuan tentang data, pengguna, proses, risiko, dan biaya. Pengetahuan itu harus dibagikan lintas unit melalui dokumentasi dan forum review, sehingga keberhasilan tidak bergantung pada ingatan satu tim. Ketika bukti baru muncul, asumsi lama harus dapat direvisi tanpa dianggap sebagai kegagalan kepemimpinan. Kemampuan mengubah arah secara tertib justru merupakan tanda kematangan dan strategic flexibility.

3. Pilar Pertama - Data sebagai Bahan Baku dan Representasi Dunia

Bagian ini berangkat dari tesis bahwa Data bukan sekadar kumpulan angka, teks, gambar, atau suara. Data adalah representasi terpilih tentang dunia. Apa yang dicatat, siapa yang tidak terlihat, bagaimana kategori dibuat, dan untuk tujuan apa data dikumpulkan akan membentuk apa yang kemudian dapat dipelajari oleh model. Tesis tersebut menempatkan AI di dalam realitas organisasi, bukan di ruang laboratorium yang steril. Nilai tidak muncul dari prediksi saja, melainkan dari perubahan keputusan dan hasil. Karena perubahan keputusan selalu melibatkan kepentingan, kewenangan, dan kemungkinan kerugian, setiap pilihan teknis sekaligus merupakan pilihan sosial dan manajerial.

Struktur persoalannya mencakup lapisan-lapisan berikut. Dimensi utama data mencakup ketersediaan, kelengkapan, ketepatan, konsistensi, kebaruan, relevansi, provenans, hak penggunaan, keamanan, dan keterwakilan. Dalam AI generatif, mutu korpus dan proses kurasi menentukan bahasa, pengetahuan, gaya, serta bias yang direproduksi. Lapisan tersebut membentuk arsitektur keputusan. Perubahan kecil pada definisi target, hak akses, antarmuka, atau insentif pengguna dapat mengubah dampak meskipun model tidak berubah. Oleh sebab itu, dokumentasi teknis perlu dilengkapi dengan dokumentasi proses dan keputusan.

Narasi kasus dapat menggambarkan hubungan antarfaktor. Model pengenalan penyakit tanaman yang dilatih terutama dari foto daun dengan cahaya studio dapat gagal pada kebun rakyat yang memakai kamera murah, memiliki latar kompleks, dan menghadapi beberapa gangguan sekaligus. Masalahnya bukan sekadar jumlah foto, melainkan kesenjangan antara dunia latihan dan dunia penggunaan. Di sini terlihat bahwa solusi yang lebih sederhana dapat menjadi lebih unggul apabila selaras dengan kondisi penggunaan. Keunggulan praktis mencakup keterandalan, keterjangkauan, penerimaan, dan kemampuan diperbaiki, bukan hanya kecanggihan.

Perhatian khusus diperlukan pada pola kegagalan berikut. Data historis juga membawa sejarah institusi. Jika proses rekrutmen masa lalu mengecilkan peluang kelompok tertentu, model yang belajar dari keputusan tersebut dapat mengubah ketidakadilan lama menjadi skor yang tampak objektif. Risiko jarang berasal dari satu sebab; ia muncul dari kombinasi data, desain, tekanan bisnis, perilaku pengguna, dan kontrol yang lemah. Analisis akar masalah karena itu harus lintas fungsi dan menghindari godaan menyalahkan satu operator.

Agenda tindakan yang mengikuti analisis ini ialah Manajemen data AI perlu mencakup inventaris, klasifikasi sensitivitas, pemilik data, aturan akses, standar mutu, dokumentasi transformasi, jadwal retensi, dan mekanisme penghapusan. Tim harus mampu menjawab dari mana setiap variabel berasal dan bagaimana perubahan definisi memengaruhi hasil. Disiplin tersebut menghubungkan strategi dengan operasi. Ia mencegah proyek terseret oleh hype, tetapi juga mencegah birokrasi

membunuh eksperimen. Kontrol dibuat proporsional: semakin besar dampak, semakin tinggi kebutuhan bukti dan pengawasan.

Pada tingkat kebijakan dan pelayanan, Di Indonesia, perhatian khusus diperlukan pada bahasa daerah, variasi ejaan, praktik informal, wilayah kepulauan, serta kelompok yang jarang terdigitalisasi. Tanpa strategi representasi, AI dapat menjadi sangat baik untuk populasi yang datanya berlimpah dan lemah bagi masyarakat yang paling membutuhkan layanan. Pemerataan perlu menjadi indikator sejak awal, bukan tambahan setelah sistem selesai. Program yang berhasil di kota besar harus diuji ulang sebelum dipakai di daerah dengan bahasa, konektivitas, dan struktur layanan berbeda.

Rujukan akademik mendukung pembacaan ini. Gebru et al. (2021) memperkenalkan datasheets for datasets sebagai dokumentasi asal, komposisi, motivasi, penggunaan, dan keterbatasan data. Pendekatan ini menegaskan bahwa kualitas data harus dapat diaudit, bukan hanya diasumsikan. Dalam praktik, temuan itu perlu diterjemahkan menjadi artefak: datasheet, model card, risk register, evaluation report, log, incident record, dan keputusan tertulis. Artefak membuat pengetahuan tidak hilang ketika orang atau vendor berganti.

Prinsip kehati-hatian yang produktif patut ditekankan. Kehati-hatian bukan menunggu kepastian sempurna, karena inovasi selalu mengandung ketidakpastian. Kehati-hatian berarti membuat ketidakpastian terlihat, mengendalikan skala eksperimen, mengukur konsekuensi, dan menjaga reversibilitas. Ketika dampak rendah, eksperimen dapat cepat; ketika menyangkut keselamatan, hak, atau penghidupan, standar bukti dan pengawasan harus lebih tinggi.

Perspektif pemangku kepentingan juga memperluas kualitas analisis. Pembangun melihat performa; pengguna melihat kemudahan; manajer melihat hasil; auditor melihat bukti; masyarakat melihat keadilan; dan pihak yang dirugikan melihat kemungkinan pemulihan. Tidak satu pun perspektif cukup sendirian. Proses partisipatif bukan berarti semua orang merancang algoritma, melainkan bahwa pengalaman dan kepentingan yang relevan masuk pada waktu ketika keputusan masih dapat diubah. Partisipasi yang terlambat hanya menjadi legitimasi simbolik bagi desain yang telah terkunci.

4. Kualitas Data, Bias, dan Keadilan

Kualitas data bersifat relatif terhadap tujuan. Data yang memadai untuk statistik agregat belum tentu cukup untuk keputusan individual. Demikian pula, akurasi keseluruhan dapat menyembunyikan kesalahan yang terkonsentrasi pada wilayah, jenis kelamin, kelompok usia, bahasa, atau kondisi sosial tertentu. Jika prinsip ini diterima, maka evaluasi tidak boleh berhenti pada pertanyaan 'apakah sistem dapat melakukannya'. Pertanyaan yang lebih lengkap adalah apakah sistem patut melakukannya, dalam kondisi apa, untuk siapa, dengan biaya berapa, siapa yang mengawasi, dan apa

yang terjadi ketika ia salah. Rangkaian pertanyaan tersebut membentuk jembatan antara ilmu komputer, manajemen, hukum, etika, dan kebijakan publik.

Secara analitis, ruang lingkupnya dapat diuraikan sebagai berikut. Pengujian perlu dilakukan terhadap missingness, label noise, duplikasi, kebocoran target, pergeseran distribusi, ketidakseimbangan kelas, dan kualitas anotasi. Analisis juga harus membandingkan tingkat kesalahan antarkelompok serta menilai apakah definisi target mengandung asumsi normatif. Unsur-unsur tersebut tidak sebaiknya diperlakukan sebagai daftar pemeriksaan yang mekanis. Hubungan di antaranya perlu dicari: peningkatan pada satu dimensi mungkin memperburuk dimensi lain, dan penghematan pada tahap awal dapat menimbulkan biaya koreksi yang lebih besar kemudian. Pendekatan yang matang selalu menyatakan trade-off, asumsi, serta batas penerapan.

Sebuah ilustrasi membantu memperjelasnya. Sistem seleksi beasiswa mungkin memprediksi kelulusan dengan baik, tetapi memakai akses internet stabil sebagai sinyal tidak langsung bagi status ekonomi. Jika konteks ini tidak diperiksa, model dapat menghukum mahasiswa potensial dari daerah dengan infrastruktur lemah. Kasus ini menunjukkan bahwa nilai AI bersifat kontekstual. Model yang sama dapat berhasil di satu tempat dan gagal di tempat lain karena perbedaan populasi, alur kerja, tujuan, atau kapasitas. Pilot karena itu bukan sekadar uji perangkat, melainkan uji hipotesis tentang sistem kerja baru.

Risiko utama muncul ketika asumsi tidak terlihat. Upaya menghapus atribut sensitif saja tidak menyelesaikan persoalan, karena kode pos, sekolah, pola belanja, atau jenis perangkat dapat menjadi proksi. Sebaliknya, koreksi statistik tanpa konsultasi pemangku kepentingan dapat menghasilkan ukuran fairness yang tidak sesuai dengan tujuan sosial. Masalah ini sering membesar secara perlahan karena keluaran yang salah tidak selalu langsung menimbulkan keluhan. Kelompok yang dirugikan mungkin tidak mengetahui bahwa AI terlibat, tidak memiliki kanal keberatan, atau tidak mempunyai data pembandingan. Karena itu, ketiadaan insiden yang dilaporkan bukan bukti ketiadaan kerugian.

Implikasi manajerialnya adalah Organisasi perlu mendefinisikan keadilan secara kontekstual, melibatkan ahli domain dan kelompok terdampak, lalu mencatat trade-off yang dipilih. Audit harus dilakukan sebelum peluncuran, selama operasi, dan ketika distribusi data berubah. Keputusan tersebut perlu diterjemahkan ke dalam pemilik, jadwal, anggaran, bukti, dan ambang. Tanpa kelima unsur itu, rekomendasi berubah menjadi aspirasi. Dewan atau pimpinan juga perlu menerima laporan tentang asumsi dan ketidakpastian, bukan hanya keberhasilan proyek.

Konteks nasional dan lokal menambah lapisan penting. Prinsip Bhinneka Tunggal Ika memberi alasan normatif kuat untuk memastikan bahwa kemajuan AI tidak menghapus keragaman. Dataset nasional seharusnya dirancang sebagai infrastruktur publik yang menghormati privasi sekaligus meningkatkan keterwakilan. Kebijakan harus mempertimbangkan bahwa kapasitas tidak merata.

Standar nasional perlu menjaga hak dan interoperabilitas, sedangkan implementasi memberi ruang adaptasi sektoral serta lokal. Pendekatan berlapis ini lebih realistis daripada satu solusi untuk semua.

Landasan ilmiah memperkuat argumen tersebut. Dwork et al. (2012) dan Hardt, Price, dan Srebro (2016) menunjukkan bahwa fairness mempunyai beberapa definisi matematis yang dapat berkonflik. Karena itu, pilihan metrik selalu memerlukan pertimbangan nilai dan konteks kelembagaan. Literatur ini tidak memberi resep tunggal, tetapi memberi cara berpikir: dokumentasikan asumsi, ukur pada konteks penggunaan, libatkan pihak terdampak, dan pertahankan kemampuan koreksi. Dengan demikian, bukti ilmiah menjadi sarana pembelajaran organisasi.

Jika bagian ini dihubungkan kembali dengan kerangka tujuh pilar, terlihat pola sistemik. Mutu satu faktor menentukan beban faktor lain. Data yang lemah memaksa model bekerja lebih keras; model yang rumit menuntut komputasi dan keahlian lebih besar; antarmuka yang buruk meningkatkan risiko manusia; governance yang terlambat memperbesar biaya perubahan. Sebaliknya, dokumentasi, modularitas, dan pembelajaran lintas fungsi menciptakan efek pengungkit. Organisasi tidak harus sempurna sebelum memulai, tetapi harus mengetahui kelemahannya, membatasi ruang risiko, dan membangun jalur peningkatan.

Akhirnya, prinsip proporsionalitas perlu dijaga. Tidak setiap penggunaan AI membutuhkan birokrasi yang sama. Alat untuk menyusun ide internal dapat diberi kontrol ringan, sedangkan sistem yang memengaruhi kesehatan, pendidikan, pekerjaan, kredit, atau hak warga membutuhkan standar lebih tinggi. Diferensiasi ini memungkinkan inovasi tetap bergerak sambil memusatkan sumber daya pengawasan pada tempat yang paling berbahaya. Dengan demikian, governance tidak menjadi rem yang selalu ditekan, melainkan sistem kemudi yang menentukan arah, kecepatan, dan batas aman.

5. Siklus Hidup Data: Dari Perolehan hingga Penghapusan

Pokok persoalan dalam bagian ini adalah Data AI harus dikelola sepanjang siklus hidup, bukan hanya ketika dikumpulkan. Nilai dan risiko berubah saat data digabungkan, dibersihkan, dilabeli, dipakai melatih model, dibagikan kepada mitra, dipakai ulang, diarsipkan, dan akhirnya dihapus. Perspektif tersebut menggeser pembicaraan dari pertanyaan sempit mengenai kemampuan perangkat menjadi pertanyaan manajerial mengenai kesesuaian, keterhubungan, dan konsekuensi. Dalam sistem AI, sebuah komponen tidak pernah benar-benar berdiri sendiri. Ia menerima masukan dari komponen lain, mengubah perilaku organisasi, lalu menghasilkan umpan balik yang dapat memperkuat manfaat maupun memperbesar risiko. Karena itu, analisis perlu memperhatikan proses sebelum model dijalankan, keputusan ketika keluaran digunakan, dan dampak setelah keputusan terjadi.

Ada beberapa dimensi yang harus dibaca secara bersamaan. Tahap perolehan memerlukan dasar hukum dan persetujuan yang jelas; tahap persiapan membutuhkan kontrol mutu; tahap penggunaan memerlukan pembatasan tujuan; tahap berbagi memerlukan kontrak dan keamanan;

sedangkan tahap retensi menuntut evaluasi manfaat terhadap risiko. Masing-masing dapat diukur, tetapi angka tidak pernah berbicara tanpa konteks. Metrik harus disertai definisi, sumber, frekuensi, populasi, dan ambang tindakan. Dengan disiplin ini, organisasi dapat membedakan sinyal yang benar-benar penting dari indikator yang sekadar mudah dikumpulkan.

Pertimbangkan contoh berikut. Universitas yang membangun asisten belajar dari tugas mahasiswa perlu membedakan materi terbuka, karya berhak cipta, data pribadi, nilai akademik, dan percakapan konseling. Semua data tidak boleh masuk ke satu repositori hanya karena secara teknis dapat digabungkan. Yang perlu dicermati bukan hanya keluaran algoritma, tetapi juga siapa yang membaca, tindakan apa yang menyusul, dan apakah hasil aktual dapat kembali menjadi pembelajaran. Tanpa loop umpan balik, organisasi tidak mengetahui apakah prediksi meningkatkan outcome atau sekadar mengubah beban kerja.

Sisi kegagalannya tidak boleh dipandang sebagai pengecualian teknis. Data shadow, salinan lokal, dan ekspor ke layanan eksternal menciptakan risiko yang sering tidak terlihat. Model dapat terus mengingat pola dari data yang telah dihapus dari basis utama, sehingga hak penghapusan dan koreksi menjadi persoalan teknis sekaligus hukum. Kegagalan merupakan informasi tentang kelemahan sistem. Organisasi yang menghukum pelaporan akan kehilangan kesempatan belajar, sedangkan organisasi yang mengubah insiden menjadi perbaikan akan membangun ketahanan. Prinsip ini menuntut budaya tanpa rasa takut sekaligus tanggung jawab yang jelas.

Dari sudut pandang implementasi, Praktik yang sehat mencakup data lineage, versioning, kontrol akses berbasis peran, enkripsi, pseudonimisasi, privacy impact assessment, dan proses persetujuan penggunaan sekunder. Pengadaan vendor harus mengatur lokasi data, pelatihan ulang, subprosesor, insiden, dan pemusnahan. Proses yang baik menyediakan jalur normal, jalur pengecualian, dan jalur penghentian. Ia juga menjaga pemisahan tugas antara pembangun, pemilik bisnis, validator, dan auditor agar konflik kepentingan dapat dikendalikan.

Relevansinya bagi pembangunan Indonesia terlihat jelas. Penerapan Undang-Undang Pelindungan Data Pribadi perlu dihubungkan dengan desain AI sejak awal. Kepatuhan tidak cukup ditempatkan sebagai pemeriksaan akhir setelah model selesai. Tantangan tersebut sekaligus peluang untuk membangun inovasi yang berangkat dari kebutuhan nyata. Keunggulan tidak selalu datang dari model terbesar; ia dapat datang dari data lokal yang bermutu, desain sederhana, biaya rendah, dan kepercayaan masyarakat.

Temuan penelitian yang relevan menyatakan bahwa Floridi dan Taddeo (2016) menempatkan etika data pada keseluruhan ekosistem pengumpulan, analisis, dan penggunaan. Prinsip data minimization dan purpose limitation relevan karena kemampuan inferensi AI dapat menghasilkan informasi sensitif baru dari data yang tampak biasa. Pelajaran pentingnya ialah bahwa inovasi dan

kehati-hatian dapat berjalan bersama. Pengujian yang kuat bukan penghambat, melainkan mekanisme yang memungkinkan skala tumbuh tanpa kehilangan kendali.

Inti manajerialnya adalah keselarasan. Strategi, data, model, infrastruktur, kompetensi, proses, dan akuntabilitas harus menunjuk pada outcome yang sama. Bila satu unit mengejar volume, unit lain mengejar akurasi, dan pengguna mengejar kecepatan, sistem dapat menghasilkan optimasi lokal yang merusak tujuan keseluruhan. Keselarasan memerlukan bahasa bersama dan forum keputusan yang mempertemukan ahli teknis, pemilik proses, pengguna, hukum, keamanan, dan pihak terdampak.

Bagi pengambil keputusan, bagian ini dapat dijadikan bahan refleksi sebelum menyetujui investasi. Apakah manfaat yang dijanjikan mempunyai baseline dan indikator outcome? Apakah ketidakpastian disampaikan secara jujur? Apakah pengguna memiliki waktu dan kewenangan untuk memeriksa? Apakah kelompok terdampak dapat mengoreksi data dan keputusan? Apakah organisasi sanggup memelihara sistem setelah pilot berakhir? Pertanyaan-pertanyaan ini mengubah diskusi dari antusiasme teknologi menjadi tanggung jawab institusional. Jawaban tidak harus selalu sempurna, tetapi harus dibuktikan dan ditinjau ulang.

6. Pilar Kedua - Algoritma dan Model sebagai Mesin Pembelajaran

Algoritma adalah prosedur yang menentukan bagaimana sistem mengolah data, sedangkan model adalah struktur terlatih yang menangkap pola untuk menghasilkan keluaran. Dalam praktik, keduanya mencakup pemilihan arsitektur, fungsi objektif, proses optimasi, teknik regularisasi, dan aturan inferensi. Pernyataan ini penting karena banyak proyek AI dinilai terlalu awal dari penampilan demonstrasi. Keberhasilan sebenarnya baru dapat diketahui ketika sistem menghadapi variasi pengguna, data yang tidak sempurna, tekanan waktu, gangguan infrastruktur, dan tuntutan pertanggungjawaban. Dengan kata lain, kecerdasan teknis harus diterjemahkan menjadi kemampuan institusional. Terjemahan itu membutuhkan desain tujuan, proses, insentif, dan pengawasan yang konsisten.

Struktur persoalannya mencakup lapisan-lapisan berikut. Machine learning terawasi belajar dari label; pembelajaran tak terawasi mencari struktur; reinforcement learning mengoptimalkan tindakan berdasarkan ganjaran; dan model generatif mempelajari distribusi untuk menghasilkan teks, gambar, suara, kode, atau kombinasi multimodal. Lapisan tersebut membentuk arsitektur keputusan. Perubahan kecil pada definisi target, hak akses, antarmuka, atau insentif pengguna dapat mengubah dampak meskipun model tidak berubah. Oleh sebab itu, dokumentasi teknis perlu dilengkapi dengan dokumentasi proses dan keputusan.

Narasi kasus dapat menggambarkan hubungan antarfaktor. Untuk memprediksi permintaan, regresi atau pohon keputusan dapat lebih tepat daripada model bahasa besar. Untuk meringkas dokumen, model generatif mungkin relevan, tetapi perlu retrieval, sitasi, validasi, dan pembatasan domain agar jawaban tidak sekadar fasih. Di sini terlihat bahwa solusi yang lebih sederhana dapat menjadi lebih unggul apabila selaras dengan kondisi penggunaan. Keunggulan praktis mencakup keterandalan, keterjangkauan, penerimaan, dan kemampuan diperbaiki, bukan hanya kecanggihan.

Perhatian khusus diperlukan pada pola kegagalan berikut. Kegagalan terjadi ketika organisasi memilih model berdasarkan popularitas, bukan karakter masalah. Kompleksitas yang tidak perlu meningkatkan biaya, memperlambat penjelasan, memperbesar permukaan serangan, dan menyulitkan pemeliharaan tanpa jaminan nilai tambahan. Risiko jarang berasal dari satu sebab; ia muncul dari kombinasi data, desain, tekanan bisnis, perilaku pengguna, dan kontrol yang lemah. Analisis akar masalah karena itu harus lintas fungsi dan menghindari godaan menyalahkan satu operator.

Agenda tindakan yang mengikuti analisis ini ialah Prinsip model fit-for-purpose meminta perbandingan terhadap baseline sederhana, kriteria penerimaan yang ditetapkan sebelum eksperimen, evaluasi lintas subkelompok, uji stres, dan dokumentasi alasan pemilihan. Model terbaik adalah yang memenuhi kebutuhan dengan risiko dan biaya yang dapat diterima. Disiplin tersebut menghubungkan strategi dengan operasi. Ia mencegah proyek terseret oleh hype, tetapi juga

mencegah birokrasi membunuh eksperimen. Kontrol dibuat proporsional: semakin besar dampak, semakin tinggi kebutuhan bukti dan pengawasan.

Pada tingkat kebijakan dan pelayanan, Kebutuhan lokal mendorong pengembangan model yang memahami Bahasa Indonesia, bahasa daerah, konteks hukum, budaya, dan pengetahuan sektoral. Namun model lokal hanya akan bernilai jika evaluasinya transparan dan tidak bergantung pada klaim pemasaran. Pemerataan perlu menjadi indikator sejak awal, bukan tambahan setelah sistem selesai. Program yang berhasil di kota besar harus diuji ulang sebelum dipakai di daerah dengan bahasa, konektivitas, dan struktur layanan berbeda.

Rujukan akademik mendukung pembacaan ini. LeCun, Bengio, dan Hinton (2015) menjelaskan kemajuan deep learning dalam pembelajaran representasi. Kemajuan itu tidak menghapus kebutuhan desain masalah, karena fungsi objektif tetap merupakan pilihan manusia tentang apa yang harus dioptimalkan. Dalam praktik, temuan itu perlu diterjemahkan menjadi artefak: datasheet, model card, risk register, evaluation report, log, incident record, dan keputusan tertulis. Artefak membuat pengetahuan tidak hilang ketika orang atau vendor berganti.

Prinsip kehati-hatian yang produktif patut ditekankan. Kehati-hatian bukan menunggu kepastian sempurna, karena inovasi selalu mengandung ketidakpastian. Kehati-hatian berarti membuat ketidakpastian terlihat, mengendalikan skala eksperimen, mengukur konsekuensi, dan menjaga reversibilitas. Ketika dampak rendah, eksperimen dapat cepat; ketika menyangkut keselamatan, hak, atau penghidupan, standar bukti dan pengawasan harus lebih tinggi.

Dari sisi pembelajaran organisasi, kualitas keputusan lebih penting daripada kecepatan peluncuran semata. Setiap eksperimen perlu menghasilkan pengetahuan tentang data, pengguna, proses, risiko, dan biaya. Pengetahuan itu harus dibagikan lintas unit melalui dokumentasi dan forum review, sehingga keberhasilan tidak bergantung pada ingatan satu tim. Ketika bukti baru muncul, asumsi lama harus dapat direvisi tanpa dianggap sebagai kegagalan kepemimpinan. Kemampuan mengubah arah secara tertib justru merupakan tanda kematangan dan strategic flexibility.

7. Evaluasi Model: Akurasi Tidak Pernah Cukup

Bagian ini berangkat dari tesis bahwa Evaluasi harus menghubungkan performa teknis dengan konsekuensi keputusan. Akurasi, precision, recall, F1, AUC, calibration, perplexity, atau skor benchmark hanya bermakna jika dikaitkan dengan biaya kesalahan, frekuensi penggunaan, dan kemampuan manusia melakukan intervensi. Tesis tersebut menempatkan AI di dalam realitas organisasi, bukan di ruang laboratorium yang steril. Nilai tidak muncul dari prediksi saja, melainkan dari perubahan keputusan dan hasil. Karena perubahan keputusan selalu melibatkan kepentingan, kewenangan, dan kemungkinan kerugian, setiap pilihan teknis sekaligus merupakan pilihan sosial dan manajerial.

Secara analitis, ruang lingkupnya dapat diuraikan sebagai berikut. Evaluasi komprehensif mencakup validitas, reliabilitas, robustness, fairness, keamanan, privasi, latensi, biaya, explainability, usability, dan dampak operasional. Untuk AI generatif perlu ditambah faithfulness, factuality, toxicity, kualitas sitasi, dan ketahanan terhadap prompt injection. Unsur-unsur tersebut tidak sebaiknya diperlakukan sebagai daftar pemeriksaan yang mekanis. Hubungan di antaranya perlu dicari: peningkatan pada satu dimensi mungkin memperburuk dimensi lain, dan penghematan pada tahap awal dapat menimbulkan biaya koreksi yang lebih besar kemudian. Pendekatan yang matang selalu menyatakan trade-off, asumsi, serta batas penerapan.

Sebuah ilustrasi membantu memperjelasnya. Dalam skrining medis, false negative dapat menunda perawatan, sedangkan false positive dapat menimbulkan kecemasan dan pemeriksaan tambahan. Ambang keputusan tidak boleh dipilih hanya untuk memaksimalkan satu skor; ia harus mencerminkan kapasitas layanan dan tingkat risiko klinis. Kasus ini menunjukkan bahwa nilai AI bersifat kontekstual. Model yang sama dapat berhasil di satu tempat dan gagal di tempat lain karena perbedaan populasi, alur kerja, tujuan, atau kapasitas. Pilot karena itu bukan sekadar uji perangkat, melainkan uji hipotesis tentang sistem kerja baru.

Risiko utama muncul ketika asumsi tidak terlihat. Benchmark leakage, data uji yang terlalu mirip dengan data latih, dan evaluasi oleh model lain dapat memberi rasa aman palsu. Performa juga menurun ketika istilah, kebijakan, harga, penyakit, atau perilaku pengguna berubah. Masalah ini sering membesar secara perlahan karena keluaran yang salah tidak selalu langsung menimbulkan keluhan. Kelompok yang dirugikan mungkin tidak mengetahui bahwa AI terlibat, tidak memiliki kanal keberatan, atau tidak mempunyai data pembandingan. Karena itu, ketiadaan insiden yang dilaporkan bukan bukti ketiadaan kerugian.

Implikasi manajerialnya adalah Setiap model memerlukan evaluation card yang mencatat populasi sasaran, data uji, metrik, ambang, keterbatasan, hasil subkelompok, red-team findings, dan rencana pemantauan. Kriteria penghentian harus jelas bila performa turun di bawah batas. Keputusan tersebut perlu diterjemahkan ke dalam pemilik, jadwal, anggaran, bukti, dan ambang. Tanpa kelima unsur itu, rekomendasi berubah menjadi aspirasi. Dewan atau pimpinan juga perlu menerima laporan tentang asumsi dan ketidakpastian, bukan hanya keberhasilan proyek.

Konteks nasional dan lokal menambah lapisan penting. Benchmark Indonesia harus meliputi ragam pendidikan, daerah, dan bahasa, bukan hanya terjemahan dari tes luar negeri. Evaluasi publik yang dapat direplikasi akan memperkuat pasar dan mengurangi ketergantungan pada klaim vendor. Kebijakan harus mempertimbangkan bahwa kapasitas tidak merata. Standar nasional perlu menjaga hak dan interoperabilitas, sedangkan implementasi memberi ruang adaptasi sektoral serta lokal. Pendekatan berlapis ini lebih realistis daripada satu solusi untuk semua.

Landasan ilmiah memperkuat argumen tersebut. Mitchell et al. (2019) mengusulkan model cards untuk menjelaskan penggunaan, kinerja, dan keterbatasan model. NIST AI RMF juga menempatkan pengukuran sebagai fungsi inti bersama govern, map, dan manage. Literatur ini tidak memberi resep tunggal, tetapi memberi cara berpikir: dokumentasikan asumsi, ukur pada konteks penggunaan, libatkan pihak terdampak, dan pertahankan kemampuan koreksi. Dengan demikian, bukti ilmiah menjadi sarana pembelajaran organisasi.

Jika bagian ini dihubungkan kembali dengan kerangka tujuh pilar, terlihat pola sistemik. Mutu satu faktor menentukan beban faktor lain. Data yang lemah memaksa model bekerja lebih keras; model yang rumit menuntut komputasi dan keahlian lebih besar; antarmuka yang buruk meningkatkan risiko manusia; governance yang terlambat memperbesar biaya perubahan. Sebaliknya, dokumentasi, modularitas, dan pembelajaran lintas fungsi menciptakan efek pengungkit. Organisasi tidak harus sempurna sebelum memulai, tetapi harus mengetahui kelemahannya, membatasi ruang risiko, dan membangun jalur peningkatan.

Perspektif pemangku kepentingan juga memperluas kualitas analisis. Pembangun melihat performa; pengguna melihat kemudahan; manajer melihat hasil; auditor melihat bukti; masyarakat melihat keadilan; dan pihak yang dirugikan melihat kemungkinan pemulihan. Tidak satu pun perspektif cukup sendirian. Proses partisipatif bukan berarti semua orang merancang algoritma, melainkan bahwa pengalaman dan kepentingan yang relevan masuk pada waktu ketika keputusan masih dapat diubah. Partisipasi yang terlambat hanya menjadi legitimasi simbolik bagi desain yang telah terkunci.

8. Explainability, Transparansi, dan Hak untuk Memahami

Penjelasan AI bukan satu benda yang sama untuk semua orang. Data scientist memerlukan diagnosis teknis; manajer membutuhkan alasan bisnis; auditor memerlukan bukti kontrol; pengguna memerlukan alasan yang dapat ditindaklanjuti; dan regulator memerlukan dasar pertanggungjawaban. Jika prinsip ini diterima, maka evaluasi tidak boleh berhenti pada pertanyaan 'apakah sistem dapat melakukannya'. Pertanyaan yang lebih lengkap adalah apakah sistem patut melakukannya, dalam kondisi apa, untuk siapa, dengan biaya berapa, siapa yang mengawasi, dan apa yang terjadi ketika ia salah. Rangkaian pertanyaan tersebut membentuk jembatan antara ilmu komputer, manajemen, hukum, etika, dan kebijakan publik.

Ada beberapa dimensi yang harus dibaca secara bersamaan. Transparansi dapat mencakup asal data, tujuan sistem, jenis model, pihak yang bertanggung jawab, keterbatasan, tingkat keyakinan, dan log keputusan. Explainability dapat bersifat global atau lokal, intrinsik atau post-hoc, teknis atau berbasis contoh. Masing-masing dapat diukur, tetapi angka tidak pernah berbicara tanpa konteks. Metrik harus disertai definisi, sumber, frekuensi, populasi, dan ambang tindakan. Dengan disiplin ini,

organisasi dapat membedakan sinyal yang benar-benar penting dari indikator yang sekadar mudah dikumpulkan.

Pertimbangkan contoh berikut. Pemohon kredit tidak membutuhkan visualisasi ribuan parameter. Ia membutuhkan penjelasan mengapa permohonan ditolak, faktor apa yang dapat diperbaiki, apakah datanya benar, dan bagaimana mengajukan keberatan. Penjelasan harus memulihkan agency, bukan sekadar memenuhi formalitas. Yang perlu dicermati bukan hanya keluaran algoritma, tetapi juga siapa yang membaca, tindakan apa yang menyusul, dan apakah hasil aktual dapat kembali menjadi pembelajaran. Tanpa loop umpan balik, organisasi tidak mengetahui apakah prediksi meningkatkan outcome atau sekadar mengubah beban kerja.

Sisi kegagalannya tidak boleh dipandang sebagai pengecualian teknis. Penjelasan yang tampak meyakinkan dapat tidak setia pada proses model. Terlalu banyak detail juga dapat membingungkan atau membuka informasi keamanan. Karena itu, explainability harus diuji terhadap tujuan, audiens, dan risiko. Kegagalan merupakan informasi tentang kelemahan sistem. Organisasi yang menghukum pelaporan akan kehilangan kesempatan belajar, sedangkan organisasi yang mengubah insiden menjadi perbaikan akan membangun ketahanan. Prinsip ini menuntut budaya tanpa rasa takut sekaligus tanggung jawab yang jelas.

Dari sudut pandang implementasi, Organisasi sebaiknya menetapkan matriks penjelasan: siapa audiensnya, keputusan apa yang dipengaruhi, informasi minimum apa yang wajib tersedia, dan bagaimana penjelasan diverifikasi. Untuk keputusan berisiko tinggi, model yang lebih dapat diinterpretasi sering patut diprioritaskan. Proses yang baik menyediakan jalur normal, jalur pengecualian, dan jalur penghentian. Ia juga menjaga pemisahan tugas antara pembangun, pemilik bisnis, validator, dan auditor agar konflik kepentingan dapat dikendalikan.

Relevansinya bagi pembangunan Indonesia terlihat jelas. Bahasa penjelasan harus sederhana, tersedia dalam format aksesibel, dan memperhatikan literasi digital. Transparansi yang hanya tersedia dalam dokumen teknis berbahasa asing tidak cukup bagi pelayanan publik. Tantangan tersebut sekaligus peluang untuk membangun inovasi yang berangkat dari kebutuhan nyata. Keunggulan tidak selalu datang dari model terbesar; ia dapat datang dari data lokal yang bermutu, desain sederhana, biaya rendah, dan kepercayaan masyarakat.

Temuan penelitian yang relevan menyatakan bahwa Ribeiro, Singh, dan Guestrin (2016) menunjukkan pendekatan penjelasan lokal model-agnostik, sedangkan Rudin (2019) mengingatkan bahwa pada keputusan berisiko tinggi, model yang dapat ditafsirkan dapat lebih tepat daripada menjelaskan kotak hitam setelah fakta. Pelajaran pentingnya ialah bahwa inovasi dan kehati-hatian dapat berjalan bersama. Pengujian yang kuat bukan penghambat, melainkan mekanisme yang memungkinkan skala tumbuh tanpa kehilangan kendali.

Inti manajerialnya adalah keselarasan. Strategi, data, model, infrastruktur, kompetensi, proses, dan akuntabilitas harus menunjuk pada outcome yang sama. Bila satu unit mengejar volume, unit lain mengejar akurasi, dan pengguna mengejar kecepatan, sistem dapat menghasilkan optimasi lokal yang merusak tujuan keseluruhan. Keselarasan memerlukan bahasa bersama dan forum keputusan yang mempertemukan ahli teknis, pemilik proses, pengguna, hukum, keamanan, dan pihak terdampak.

Akhirnya, prinsip proporsionalitas perlu dijaga. Tidak setiap penggunaan AI membutuhkan birokrasi yang sama. Alat untuk menyusun ide internal dapat diberi kontrol ringan, sedangkan sistem yang memengaruhi kesehatan, pendidikan, pekerjaan, kredit, atau hak warga membutuhkan standar lebih tinggi. Diferensiasi ini memungkinkan inovasi tetap bergerak sambil memusatkan sumber daya pengawasan pada tempat yang paling berbahaya. Dengan demikian, governance tidak menjadi rem yang selalu ditekan, melainkan sistem kemudi yang menentukan arah, kecepatan, dan batas aman.

9. Foundation Models dan AI Generatif

Pokok persoalan dalam bagian ini adalah Foundation models mengubah ekonomi pengembangan AI karena satu model dasar dapat diadaptasi untuk banyak tugas. Kemampuan ini mempercepat inovasi, tetapi juga mengonsentrasikan risiko: kesalahan, bias, kerentanan, dan ketergantungan dapat diwariskan ke banyak aplikasi sekaligus. Perspektif tersebut menggeser pembicaraan dari pertanyaan sempit mengenai kemampuan perangkat menjadi pertanyaan manajerial mengenai kesesuaian, keterhubungan, dan konsekuensi. Dalam sistem AI, sebuah komponen tidak pernah benar-benar berdiri sendiri. Ia menerima masukan dari komponen lain, mengubah perilaku organisasi, lalu menghasilkan umpan balik yang dapat memperkuat manfaat maupun memperbesar risiko. Karena itu, analisis perlu memperhatikan proses sebelum model dijalankan, keputusan ketika keluaran digunakan, dan dampak setelah keputusan terjadi.

Struktur persoalannya mencakup lapisan-lapisan berikut. AI generatif bekerja melalui prediksi pola dan token, bukan akses langsung kepada kebenaran. Kualitas keluaran dipengaruhi oleh pretraining, alignment, prompt, retrieval, tools, konteks, sampling, dan guardrails. Agen AI menambahkan kemampuan merencanakan dan bertindak. Lapisan tersebut membentuk arsitektur keputusan. Perubahan kecil pada definisi target, hak akses, antarmuka, atau insentif pengguna dapat mengubah dampak meskipun model tidak berubah. Oleh sebab itu, dokumentasi teknis perlu dilengkapi dengan dokumentasi proses dan keputusan.

Narasi kasus dapat menggambarkan hubungan antarfaktor. Asisten kebijakan dapat membantu mencari dokumen dan menyusun alternatif, tetapi jawabannya perlu ditambatkan pada sumber resmi. Retrieval-augmented generation, pembatasan corpus, dan sitasi dapat mengurangi halusinasi, namun tidak menggantikan verifikasi ahli. Di sini terlihat bahwa solusi yang lebih sederhana dapat

menjadi lebih unggul apabila selaras dengan kondisi penggunaan. Keunggulan praktis mencakup keterandalan, keterjangkauan, penerimaan, dan kemampuan diperbaiki, bukan hanya kecanggihan.

Perhatian khusus diperlukan pada pola kegagalan berikut. Bahaya muncul ketika kefasihan disalahartikan sebagai pemahaman. Model dapat menghasilkan rujukan palsu, mengabaikan perubahan regulasi, membocorkan instruksi sistem, atau mengikuti prompt berbahaya. Automasi yang terlalu jauh memperbesar dampak satu kesalahan. Risiko jarang berasal dari satu sebab; ia muncul dari kombinasi data, desain, tekanan bisnis, perilaku pengguna, dan kontrol yang lemah. Analisis akar masalah karena itu harus lintas fungsi dan menghindari godaan menyalahkan satu operator.

Agenda tindakan yang mengikuti analisis ini ialah Penggunaan generatif perlu dikelompokkan menurut risiko. Brainstorming internal berbeda dari diagnosis medis atau keputusan hak warga. Organisasi harus menentukan data apa yang boleh dimasukkan, kapan human review wajib, bagaimana sumber dicatat, dan tindakan apa yang dilarang. Disiplin tersebut menghubungkan strategi dengan operasi. Ia mencegah proyek terseret oleh hype, tetapi juga mencegah birokrasi membunuh eksperimen. Kontrol dibuat proporsional: semakin besar dampak, semakin tinggi kebutuhan bukti dan pengawasan.

Pada tingkat kebijakan dan pelayanan, Indonesia memiliki peluang membangun model dan corpus berbahasa lokal untuk pendidikan, budaya, hukum, pertanian, dan layanan publik. Kedaulatan pengetahuan mengharuskan partisipasi komunitas, perlindungan hak, serta pembagian manfaat yang adil. Pemerataan perlu menjadi indikator sejak awal, bukan tambahan setelah sistem selesai. Program yang berhasil di kota besar harus diuji ulang sebelum dipakai di daerah dengan bahasa, konektivitas, dan struktur layanan berbeda.

Rujukan akademik mendukung pembacaan ini. Bender et al. (2021) mengingatkan risiko skala, data, dan makna pada model bahasa besar. Kaplan et al. (2020) serta Hoffmann et al. (2022) menunjukkan hubungan skala model, data, dan komputasi, sekaligus menegaskan pentingnya keseimbangan sumber daya. Dalam praktik, temuan itu perlu diterjemahkan menjadi artefak: datasheet, model card, risk register, evaluation report, log, incident record, dan keputusan tertulis. Artefak membuat pengetahuan tidak hilang ketika orang atau vendor berganti.

Prinsip kehati-hatian yang produktif patut ditekankan. Kehati-hatian bukan menunggu kepastian sempurna, karena inovasi selalu mengandung ketidakpastian. Kehati-hatian berarti membuat ketidakpastian terlihat, mengendalikan skala eksperimen, mengukur konsekuensi, dan menjaga reversibilitas. Ketika dampak rendah, eksperimen dapat cepat; ketika menyangkut keselamatan, hak, atau penghidupan, standar bukti dan pengawasan harus lebih tinggi.

Bagi pengambil keputusan, bagian ini dapat dijadikan bahan refleksi sebelum menyetujui investasi. Apakah manfaat yang dijanjikan mempunyai baseline dan indikator outcome? Apakah

ketidakpastian disampaikan secara jujur? Apakah pengguna memiliki waktu dan kewenangan untuk memeriksa? Apakah kelompok terdampak dapat mengoreksi data dan keputusan? Apakah organisasi sanggup memelihara sistem setelah pilot berakhir? Pertanyaan-pertanyaan ini mengubah diskusi dari antusiasme teknologi menjadi tanggung jawab institusional. Jawaban tidak harus selalu sempurna, tetapi harus dibuktikan dan ditinjau ulang.

10. Pilar Ketiga - Komputasi dan Infrastruktur

Komputasi adalah kemampuan material yang memungkinkan model dilatih dan dijalankan. Ia mencakup CPU, GPU, accelerator, memori, penyimpanan, pusat data, jaringan, cloud, edge devices, perangkat lunak, observability, keamanan, dan pasokan energi. Pernyataan ini penting karena banyak proyek AI dinilai terlalu awal dari penampilan demonstrasi. Keberhasilan sebenarnya baru dapat diketahui ketika sistem menghadapi variasi pengguna, data yang tidak sempurna, tekanan waktu, gangguan infrastruktur, dan tuntutan pertanggungjawaban. Dengan kata lain, kecerdasan teknis harus diterjemahkan menjadi kemampuan institusional. Terjemahan itu membutuhkan desain tujuan, proses, insentif, dan pengawasan yang konsisten.

Secara analitis, ruang lingkupnya dapat diuraikan sebagai berikut. Keputusan infrastruktur memengaruhi latensi, throughput, reliabilitas, skalabilitas, biaya, privasi, dan ketergantungan pemasok. Training dan inference mempunyai profil berbeda. Model kecil di edge dapat lebih tepat untuk lokasi terpencil daripada layanan awan yang selalu terhubung. Unsur-unsur tersebut tidak sebaiknya diperlakukan sebagai daftar pemeriksaan yang mekanis. Hubungan di antaranya perlu dicari: peningkatan pada satu dimensi mungkin memperburuk dimensi lain, dan penghematan pada tahap awal dapat menimbulkan biaya koreksi yang lebih besar kemudian. Pendekatan yang matang selalu menyatakan trade-off, asumsi, serta batas penerapan.

Sebuah ilustrasi membantu memperjelasnya. Sistem deteksi ikan di kapal kecil tidak dapat mengandalkan koneksi stabil. Model terkompresi yang berjalan di perangkat lokal, melakukan sinkronisasi saat jaringan tersedia, dan tahan terhadap kelembapan dapat lebih bernilai daripada model besar di pusat data. Kasus ini menunjukkan bahwa nilai AI bersifat kontekstual. Model yang sama dapat berhasil di satu tempat dan gagal di tempat lain karena perbedaan populasi, alur kerja, tujuan, atau kapasitas. Pilot karena itu bukan sekadar uji perangkat, melainkan uji hipotesis tentang sistem kerja baru.

Risiko utama muncul ketika asumsi tidak terlihat. Infrastruktur yang dirancang hanya untuk demo gagal menghadapi beban puncak, gangguan layanan, pemulihan bencana, pembaruan model, dan serangan. Biaya inferensi yang kecil per transaksi dapat menjadi besar ketika volume meningkat. Masalah ini sering membesar secara perlahan karena keluaran yang salah tidak selalu langsung menimbulkan keluhan. Kelompok yang dirugikan mungkin tidak mengetahui bahwa AI terlibat, tidak memiliki kanal keberatan, atau tidak mempunyai data pembandingan. Karena itu, ketiadaan insiden yang dilaporkan bukan bukti ketiadaan kerugian.

Implikasi manajerialnya adalah Arsitektur harus dipilih berdasarkan service-level objective, sensitivitas data, kebutuhan lokasi, volume, energi, dan exit strategy. FinOps untuk AI perlu mengukur biaya per tugas yang berhasil, bukan hanya biaya server. Keputusan tersebut perlu diterjemahkan ke dalam pemilik, jadwal, anggaran, bukti, dan ambang. Tanpa kelima unsur itu, rekomendasi berubah

menjadi aspirasi. Dewan atau pimpinan juga perlu menerima laporan tentang asumsi dan ketidakpastian, bukan hanya keberhasilan proyek.

Konteks nasional dan lokal menambah lapisan penting. Geografi kepulauan menuntut desain hybrid cloud-edge, pusat data yang resilien, konektivitas yang merata, dan kemampuan operasi di lingkungan bandwidth terbatas. Infrastruktur AI harus dipandang sebagai bagian dari pembangunan digital nasional. Kebijakan harus mempertimbangkan bahwa kapasitas tidak merata. Standar nasional perlu menjaga hak dan interoperabilitas, sedangkan implementasi memberi ruang adaptasi sektoral serta lokal. Pendekatan berlapis ini lebih realistis daripada satu solusi untuk semua.

Landasan ilmiah memperkuat argumen tersebut. Kemajuan deep learning terkait erat dengan peningkatan komputasi dan perangkat keras khusus. Namun Stanford AI Index 2026 juga menekankan meningkatnya biaya ekonomi dan lingkungan, sehingga kapasitas tidak dapat dinilai dari kecepatan saja. Literatur ini tidak memberi resep tunggal, tetapi memberi cara berpikir: dokumentasikan asumsi, ukur pada konteks penggunaan, libatkan pihak terdampak, dan pertahankan kemampuan koreksi. Dengan demikian, bukti ilmiah menjadi sarana pembelajaran organisasi.

Jika bagian ini dihubungkan kembali dengan kerangka tujuh pilar, terlihat pola sistemik. Mutu satu faktor menentukan beban faktor lain. Data yang lemah memaksa model bekerja lebih keras; model yang rumit menuntut komputasi dan keahlian lebih besar; antarmuka yang buruk meningkatkan risiko manusia; governance yang terlambat memperbesar biaya perubahan. Sebaliknya, dokumentasi, modularitas, dan pembelajaran lintas fungsi menciptakan efek pengungkit. Organisasi tidak harus sempurna sebelum memulai, tetapi harus mengetahui kelemahannya, membatasi ruang risiko, dan membangun jalur peningkatan.

Dari sisi pembelajaran organisasi, kualitas keputusan lebih penting daripada kecepatan peluncuran semata. Setiap eksperimen perlu menghasilkan pengetahuan tentang data, pengguna, proses, risiko, dan biaya. Pengetahuan itu harus dibagikan lintas unit melalui dokumentasi dan forum review, sehingga keberhasilan tidak bergantung pada ingatan satu tim. Ketika bukti baru muncul, asumsi lama harus dapat direvisi tanpa dianggap sebagai kegagalan kepemimpinan. Kemampuan mengubah arah secara tertib justru merupakan tanda kematangan dan strategic flexibility.

11. Skala, Efisiensi, Energi, dan Green AI

Bagian ini berangkat dari tesis bahwa Skala memberi kemampuan, tetapi tidak identik dengan efisiensi. Organisasi perlu menilai apakah peningkatan parameter atau komputasi benar-benar meningkatkan manfaat bagi pengguna, atau hanya memindahkan biaya ke anggaran, lingkungan, dan ketergantungan infrastruktur. Tesis tersebut menempatkan AI di dalam realitas organisasi, bukan di ruang laboratorium yang steril. Nilai tidak muncul dari prediksi saja, melainkan dari perubahan

keputusan dan hasil. Karena perubahan keputusan selalu melibatkan kepentingan, kewenangan, dan kemungkinan kerugian, setiap pilihan teknis sekaligus merupakan pilihan sosial dan manajerial.

Ada beberapa dimensi yang harus dibaca secara bersamaan. Efisiensi dapat dicapai melalui model selection, distillation, quantization, pruning, caching, batching, routing, penggunaan model kecil, pemilihan pusat data, serta pengaturan waktu beban. Pengukuran sebaiknya mencakup energi, emisi, air, perangkat, dan umur pakai. Masing-masing dapat diukur, tetapi angka tidak pernah berbicara tanpa konteks. Metrik harus disertai definisi, sumber, frekuensi, populasi, dan ambang tindakan. Dengan disiplin ini, organisasi dapat membedakan sinyal yang benar-benar penting dari indikator yang sekadar mudah dikumpulkan.

Pertimbangkan contoh berikut. Chatbot layanan kampus mungkin tidak memerlukan model terbesar untuk menjawab jadwal, prosedur, dan FAQ. Arsitektur yang mengarahkan pertanyaan sederhana ke model kecil dan kasus sulit ke model lebih besar dapat menurunkan biaya tanpa mengurangi kualitas. Yang perlu dicermati bukan hanya keluaran algoritma, tetapi juga siapa yang membaca, tindakan apa yang menyusul, dan apakah hasil aktual dapat kembali menjadi pembelajaran. Tanpa loop umpan balik, organisasi tidak mengetahui apakah prediksi meningkatkan outcome atau sekadar mengubah beban kerja.

Sisi kegagalannya tidak boleh dipandang sebagai pengecualian teknis. Efek rebound dapat terjadi: biaya per inferensi turun, tetapi penggunaan melonjak sehingga konsumsi total meningkat. Klaim hijau juga menyesatkan bila hanya menghitung listrik operasi dan mengabaikan pembuatan perangkat atau sumber energi. Kegagalan merupakan informasi tentang kelemahan sistem. Organisasi yang menghukum pelaporan akan kehilangan kesempatan belajar, sedangkan organisasi yang mengubah insiden menjadi perbaikan akan membangun ketahanan. Prinsip ini menuntut budaya tanpa rasa takut sekaligus tanggung jawab yang jelas.

Dari sudut pandang implementasi, KPI AI perlu memasukkan kualitas per unit energi dan biaya, bukan hanya skor benchmark. Pengadaan harus meminta transparansi konsumsi, lokasi pemrosesan, efisiensi hardware, dan komitmen energi bersih. Proses yang baik menyediakan jalur normal, jalur pengecualian, dan jalur penghentian. Ia juga menjaga pemisahan tugas antara pembangun, pemilik bisnis, validator, dan auditor agar konflik kepentingan dapat dikendalikan.

Relevansinya bagi pembangunan Indonesia terlihat jelas. Strategi AI nasional sebaiknya selaras dengan transisi energi. Pusat data dapat mendorong investasi energi terbarukan, tetapi tanpa perencanaan juga dapat menambah beban jaringan dan persaingan air di wilayah tertentu. Tantangan tersebut sekaligus peluang untuk membangun inovasi yang berangkat dari kebutuhan nyata. Keunggulan tidak selalu datang dari model terbesar; ia dapat datang dari data lokal yang bermutu, desain sederhana, biaya rendah, dan kepercayaan masyarakat.

Temuan penelitian yang relevan menyatakan bahwa Strubell, Ganesh, dan McCallum (2019) mengukur biaya finansial dan lingkungan pelatihan NLP. Schwartz et al. (2020) mengajukan Green AI yang menghargai efisiensi sebagai hasil ilmiah, bukan hanya akurasi. Pelajaran pentingnya ialah bahwa inovasi dan kehati-hatian dapat berjalan bersama. Pengujian yang kuat bukan penghambat, melainkan mekanisme yang memungkinkan skala tumbuh tanpa kehilangan kendali.

Inti manajerialnya adalah keselarasan. Strategi, data, model, infrastruktur, kompetensi, proses, dan akuntabilitas harus menunjuk pada outcome yang sama. Bila satu unit mengejar volume, unit lain mengejar akurasi, dan pengguna mengejar kecepatan, sistem dapat menghasilkan optimasi lokal yang merusak tujuan keseluruhan. Keselarasan memerlukan bahasa bersama dan forum keputusan yang mempertemukan ahli teknis, pemilik proses, pengguna, hukum, keamanan, dan pihak terdampak.

Perspektif pemangku kepentingan juga memperluas kualitas analisis. Pembangun melihat performa; pengguna melihat kemudahan; manajer melihat hasil; auditor melihat bukti; masyarakat melihat keadilan; dan pihak yang dirugikan melihat kemungkinan pemulihan. Tidak satu pun perspektif cukup sendirian. Proses partisipatif bukan berarti semua orang merancang algoritma, melainkan bahwa pengalaman dan kepentingan yang relevan masuk pada waktu ketika keputusan masih dapat diubah. Partisipasi yang terlambat hanya menjadi legitimasi simbolik bagi desain yang telah terkunci.

12. Kedaulatan Komputasi, Cloud, dan Ketergantungan Vendor

AI modern dibangun dalam rantai pasok global yang meliputi chip, cloud, model, framework, data, dan layanan keamanan. Ketergantungan ini dapat mempercepat adopsi, tetapi juga menimbulkan risiko harga, penghentian layanan, perubahan kebijakan, yurisdiksi, dan keterbatasan interoperabilitas. Jika prinsip ini diterima, maka evaluasi tidak boleh berhenti pada pertanyaan 'apakah sistem dapat melakukannya'. Pertanyaan yang lebih lengkap adalah apakah sistem patut melakukannya, dalam kondisi apa, untuk siapa, dengan biaya berapa, siapa yang mengawasi, dan apa yang terjadi ketika ia salah. Rangkaian pertanyaan tersebut membentuk jembatan antara ilmu komputer, manajemen, hukum, etika, dan kebijakan publik.

Struktur persoalannya mencakup lapisan-lapisan berikut. Kedaulatan tidak selalu berarti membuat semua komponen sendiri. Ia berarti memiliki pilihan, kemampuan menilai, kemampuan berpindah, kontrol atas data penting, dan kapasitas menjaga layanan ketika hubungan pemasok berubah. Lapisan tersebut membentuk arsitektur keputusan. Perubahan kecil pada definisi target, hak akses, antarmuka, atau insentif pengguna dapat mengubah dampak meskipun model tidak berubah. Oleh sebab itu, dokumentasi teknis perlu dilengkapi dengan dokumentasi proses dan keputusan.

Narasi kasus dapat menggambarkan hubungan antarfaktor. Pemerintah daerah yang membangun sistem layanan dengan API tunggal dapat menghadapi kenaikan biaya atau perubahan model mendadak. Lapisan abstraksi, standar terbuka, dokumentasi, dan model cadangan memberi ruang negosiasi. Di sini terlihat bahwa solusi yang lebih sederhana dapat menjadi lebih unggul apabila selaras dengan kondisi penggunaan. Keunggulan praktis mencakup keterandalan, keterjangkauan, penerimaan, dan kemampuan diperbaiki, bukan hanya kecanggihan.

Perhatian khusus diperlukan pada pola kegagalan berikut. Vendor lock-in tumbuh melalui format proprietary, prompt yang tidak portabel, penyimpanan embedding, ketergantungan identitas, dan kontrak yang tidak mengatur ekspor. Risiko juga muncul jika subvendor tidak teridentifikasi. Risiko jarang berasal dari satu sebab; ia muncul dari kombinasi data, desain, tekanan bisnis, perilaku pengguna, dan kontrol yang lemah. Analisis akar masalah karena itu harus lintas fungsi dan menghindari godaan menyalahkan satu operator.

Agenda tindakan yang mengikuti analisis ini ialah Strategi multi-model tidak harus berarti multi-cloud yang rumit. Organisasi dapat memulai dengan arsitektur modular, hak audit, portability test, escrow untuk komponen kritis, dan klasifikasi beban yang harus tetap berada di dalam negeri. Disiplin tersebut menghubungkan strategi dengan operasi. Ia mencegah proyek terseret oleh hype, tetapi juga mencegah birokrasi membunuh eksperimen. Kontrol dibuat proporsional: semakin besar dampak, semakin tinggi kebutuhan bukti dan pengawasan.

Pada tingkat kebijakan dan pelayanan, Indonesia membutuhkan kapasitas negosiasi kolektif, pusat komputasi untuk riset dan kepentingan publik, serta pengembangan talenta sistem. Kedaulatan yang sehat menggabungkan kerja sama global dengan penguatan kemampuan domestik. Pemerataan perlu menjadi indikator sejak awal, bukan tambahan setelah sistem selesai. Program yang berhasil di kota besar harus diuji ulang sebelum dipakai di daerah dengan bahasa, konektivitas, dan struktur layanan berbeda.

Rujukan akademik mendukung pembacaan ini. AI Index 2026 menempatkan AI sovereignty sebagai tema kebijakan yang semakin penting. OECD juga mendorong investasi riset, infrastruktur, keterampilan, dan ekosistem agar manfaat AI tersebar. Dalam praktik, temuan itu perlu diterjemahkan menjadi artefak: datasheet, model card, risk register, evaluation report, log, incident record, dan keputusan tertulis. Artefak membuat pengetahuan tidak hilang ketika orang atau vendor berganti.

Prinsip kehati-hatian yang produktif patut ditekankan. Kehati-hatian bukan menunggu kepastian sempurna, karena inovasi selalu mengandung ketidakpastian. Kehati-hatian berarti membuat ketidakpastian terlihat, mengendalikan skala eksperimen, mengukur konsekuensi, dan menjaga reversibilitas. Ketika dampak rendah, eksperimen dapat cepat; ketika menyangkut keselamatan, hak, atau penghidupan, standar bukti dan pengawasan harus lebih tinggi.

Akhirnya, prinsip proporsionalitas perlu dijaga. Tidak setiap penggunaan AI membutuhkan birokrasi yang sama. Alat untuk menyusun ide internal dapat diberi kontrol ringan, sedangkan sistem yang memengaruhi kesehatan, pendidikan, pekerjaan, kredit, atau hak warga membutuhkan standar lebih tinggi. Diferensiasi ini memungkinkan inovasi tetap bergerak sambil memusatkan sumber daya pengawasan pada tempat yang paling berbahaya. Dengan demikian, governance tidak menjadi rem yang selalu ditekan, melainkan sistem kemudi yang menentukan arah, kecepatan, dan batas aman.

13. Pilar Keempat - Manusia dan Kompetensi

Pokok persoalan dalam bagian ini adalah Manusia bukan faktor tambahan setelah teknologi selesai. Manusia mendefinisikan masalah, memilih data, membangun model, merancang interaksi, menafsirkan keluaran, menanggung konsekuensi, dan menentukan apakah sistem harus diteruskan, dikoreksi, atau dihentikan. Perspektif tersebut menggeser pembicaraan dari pertanyaan sempit mengenai kemampuan perangkat menjadi pertanyaan manajerial mengenai kesesuaian, keterhubungan, dan konsekuensi. Dalam sistem AI, sebuah komponen tidak pernah benar-benar berdiri sendiri. Ia menerima masukan dari komponen lain, mengubah perilaku organisasi, lalu menghasilkan umpan balik yang dapat memperkuat manfaat maupun memperbesar risiko. Karena itu, analisis perlu memperhatikan proses sebelum model dijalankan, keputusan ketika keluaran digunakan, dan dampak setelah keputusan terjadi.

Secara analitis, ruang lingkupnya dapat diuraikan sebagai berikut. Kompetensi AI meliputi literasi pengguna, keahlian domain, data science, engineering, keamanan, desain interaksi, hukum, etika, pengadaan, audit, dan kepemimpinan perubahan. Kapabilitas tim muncul dari kolaborasi, bukan akumulasi individu pintar. Unsur-unsur tersebut tidak sebaiknya diperlakukan sebagai daftar pemeriksaan yang mekanis. Hubungan di antaranya perlu dicari: peningkatan pada satu dimensi mungkin memperburuk dimensi lain, dan penghematan pada tahap awal dapat menimbulkan biaya koreksi yang lebih besar kemudian. Pendekatan yang matang selalu menyatakan trade-off, asumsi, serta batas penerapan.

Sebuah ilustrasi membantu memperjelasnya. Dalam manajemen hutan, ahli penginderaan jauh dapat menemukan anomali, tetapi petugas lapangan memahami musim, awan, akses, konflik tenurial, dan perilaku lokal. Keputusan terbaik muncul ketika pengetahuan komputasional dan pengalaman lapangan saling mengoreksi. Kasus ini menunjukkan bahwa nilai AI bersifat kontekstual. Model yang sama dapat berhasil di satu tempat dan gagal di tempat lain karena perbedaan populasi, alur kerja, tujuan, atau kapasitas. Pilot karena itu bukan sekadar uji perangkat, melainkan uji hipotesis tentang sistem kerja baru.

Risiko utama muncul ketika asumsi tidak terlihat. Automation bias membuat pengguna terlalu percaya pada rekomendasi; algorithm aversion membuat mereka menolak sistem setelah satu kesalahan. Keduanya tumbuh ketika pelatihan tidak menjelaskan kemampuan, batas, ketidakpastian, dan peran manusia. Masalah ini sering membesar secara perlahan karena keluaran yang salah tidak selalu langsung menimbulkan keluhan. Kelompok yang dirugikan mungkin tidak mengetahui bahwa AI terlibat, tidak memiliki kanal keberatan, atau tidak mempunyai data pembandingan. Karena itu, ketiadaan insiden yang dilaporkan bukan bukti ketiadaan kerugian.

Implikasi manajerialnya adalah Program kompetensi perlu berbasis peran. Dewan direksi membutuhkan governance literacy; manajer membutuhkan use-case dan risk literacy; pengguna

membutuhkan verifikasi; teknisi membutuhkan MLOps dan keamanan; auditor membutuhkan akses bukti. Keputusan tersebut perlu diterjemahkan ke dalam pemilik, jadwal, anggaran, bukti, dan ambang. Tanpa kelima unsur itu, rekomendasi berubah menjadi aspirasi. Dewan atau pimpinan juga perlu menerima laporan tentang asumsi dan ketidakpastian, bukan hanya keberhasilan proyek.

Konteks nasional dan lokal menambah lapisan penting. Pengembangan talenta tidak cukup melalui kursus singkat. Diperlukan jalur pendidikan, komunitas praktik, proyek nyata, sertifikasi yang bermakna, dan mobilitas antara universitas, industri, pemerintah, serta masyarakat. Kebijakan harus mempertimbangkan bahwa kapasitas tidak merata. Standar nasional perlu menjaga hak dan interoperabilitas, sedangkan implementasi memberi ruang adaptasi sektoral serta lokal. Pendekatan berlapis ini lebih realistis daripada satu solusi untuk semua.

Landasan ilmiah memperkuat argumen tersebut. Amershi et al. (2019) menunjukkan bahwa interaksi manusia-AI membutuhkan desain ekspektasi, umpan balik, koreksi, dan kontrol. Shneiderman (2020) menekankan AI yang andal, aman, dan dapat dipercaya dengan kendali manusia yang bermakna. Literatur ini tidak memberi resep tunggal, tetapi memberi cara berpikir: dokumentasikan asumsi, ukur pada konteks penggunaan, libatkan pihak terdampak, dan pertahankan kemampuan koreksi. Dengan demikian, bukti ilmiah menjadi sarana pembelajaran organisasi.

Jika bagian ini dihubungkan kembali dengan kerangka tujuh pilar, terlihat pola sistemik. Mutu satu faktor menentukan beban faktor lain. Data yang lemah memaksa model bekerja lebih keras; model yang rumit menuntut komputasi dan keahlian lebih besar; antarmuka yang buruk meningkatkan risiko manusia; governance yang terlambat memperbesar biaya perubahan. Sebaliknya, dokumentasi, modularitas, dan pembelajaran lintas fungsi menciptakan efek pengungkit. Organisasi tidak harus sempurna sebelum memulai, tetapi harus mengetahui kelemahannya, membatasi ruang risiko, dan membangun jalur peningkatan.

Bagi pengambil keputusan, bagian ini dapat dijadikan bahan refleksi sebelum menyetujui investasi. Apakah manfaat yang dijanjikan mempunyai baseline dan indikator outcome? Apakah ketidakpastian disampaikan secara jujur? Apakah pengguna memiliki waktu dan kewenangan untuk memeriksa? Apakah kelompok terdampak dapat mengoreksi data dan keputusan? Apakah organisasi sanggup memelihara sistem setelah pilot berakhir? Pertanyaan-pertanyaan ini mengubah diskusi dari antusiasme teknologi menjadi tanggung jawab institusional. Jawaban tidak harus selalu sempurna, tetapi harus dibuktikan dan ditinjau ulang.

14. Human-in-the-Loop dan Pembagian Kerja Baru

Human-in-the-loop bukan slogan bahwa manusia berada di akhir proses. Ia harus menjelaskan titik intervensi, kewenangan, waktu, informasi, dan kompetensi. Tanpa desain tersebut, manusia hanya

menjadi stempel formal bagi keputusan mesin. Pernyataan ini penting karena banyak proyek AI dinilai terlalu awal dari penampilan demonstrasi. Keberhasilan sebenarnya baru dapat diketahui ketika sistem menghadapi variasi pengguna, data yang tidak sempurna, tekanan waktu, gangguan infrastruktur, dan tuntutan pertanggungjawaban. Dengan kata lain, kecerdasan teknis harus diterjemahkan menjadi kemampuan institusional. Terjemahan itu membutuhkan desain tujuan, proses, insentif, dan pengawasan yang konsisten.

Ada beberapa dimensi yang harus dibaca secara bersamaan. Pembagian kerja dapat berbentuk AI memberi saran, manusia memutuskan; AI menangani kasus rutin, manusia menangani pengecualian; manusia menetapkan tujuan, AI mengeksekusi; atau manusia dan AI melakukan cross-check. Tingkat otomatisasi harus mengikuti risiko. Masing-masing dapat diukur, tetapi angka tidak pernah berbicara tanpa konteks. Metrik harus disertai definisi, sumber, frekuensi, populasi, dan ambang tindakan. Dengan disiplin ini, organisasi dapat membedakan sinyal yang benar-benar penting dari indikator yang sekadar mudah dikumpulkan.

Pertimbangkan contoh berikut. Pada pemeriksaan klaim asuransi, AI dapat memprioritaskan kasus dan mendeteksi pola mencurigakan. Petugas tetap menilai bukti, menghubungi pihak terkait, dan memastikan bahwa anomali bukan sekadar karakteristik kelompok tertentu. Yang perlu dicermati bukan hanya keluaran algoritma, tetapi juga siapa yang membaca, tindakan apa yang menyusul, dan apakah hasil aktual dapat kembali menjadi pembelajaran. Tanpa loop umpan balik, organisasi tidak mengetahui apakah prediksi meningkatkan outcome atau sekadar mengubah beban kerja.

Sisi kegagalannya tidak boleh dipandang sebagai pengecualian teknis. Jika sistem mengirim terlalu banyak alert, pengguna mengalami fatigue. Jika antarmuka menyembunyikan ketidakpastian, rekomendasi tampak absolut. Jika override selalu dipertanyakan, manusia enggan mengoreksi meskipun memiliki alasan kuat. Kegagalan merupakan informasi tentang kelemahan sistem. Organisasi yang menghukum pelaporan akan kehilangan kesempatan belajar, sedangkan organisasi yang mengubah insiden menjadi perbaikan akan membangun ketahanan. Prinsip ini menuntut budaya tanpa rasa takut sekaligus tanggung jawab yang jelas.

Dari sudut pandang implementasi, Desain harus mencatat override, alasan, outcome, dan pola perbedaan antara manusia dan AI. Data ini menjadi sumber belajar untuk memperbaiki model dan proses. Akuntabilitas tetap pada institusi, bukan dialihkan kepada individu operator. Proses yang baik menyediakan jalur normal, jalur pengecualian, dan jalur penghentian. Ia juga menjaga pemisahan tugas antara pembangun, pemilik bisnis, validator, dan auditor agar konflik kepentingan dapat dikendalikan.

Relevansinya bagi pembangunan Indonesia terlihat jelas. Pada layanan publik, mekanisme keberatan dan akses petugas manusia wajib dipertahankan, terutama bagi warga yang memiliki keterbatasan digital. Efisiensi tidak boleh menghapus hak untuk didengar. Tantangan tersebut

sekaligus peluang untuk membangun inovasi yang berangkat dari kebutuhan nyata. Keunggulan tidak selalu datang dari model terbesar; ia dapat datang dari data lokal yang bermutu, desain sederhana, biaya rendah, dan kepercayaan masyarakat.

Temuan penelitian yang relevan menyatakan bahwa Bainbridge (1983) menjelaskan ironies of automation: semakin sistem otomatis, semakin penting peran manusia pada situasi langka dan sulit, justru ketika keterampilan dapat menurun. Prinsip ini tetap relevan bagi agen AI modern. Pelajaran pentingnya ialah bahwa inovasi dan kehati-hatian dapat berjalan bersama. Pengujian yang kuat bukan penghambat, melainkan mekanisme yang memungkinkan skala tumbuh tanpa kehilangan kendali.

Inti manajerialnya adalah keselarasan. Strategi, data, model, infrastruktur, kompetensi, proses, dan akuntabilitas harus menunjuk pada outcome yang sama. Bila satu unit mengejar volume, unit lain mengejar akurasi, dan pengguna mengejar kecepatan, sistem dapat menghasilkan optimasi lokal yang merusak tujuan keseluruhan. Keselarasan memerlukan bahasa bersama dan forum keputusan yang mempertemukan ahli teknis, pemilik proses, pengguna, hukum, keamanan, dan pihak terdampak.

Dari sisi pembelajaran organisasi, kualitas keputusan lebih penting daripada kecepatan peluncuran semata. Setiap eksperimen perlu menghasilkan pengetahuan tentang data, pengguna, proses, risiko, dan biaya. Pengetahuan itu harus dibagikan lintas unit melalui dokumentasi dan forum review, sehingga keberhasilan tidak bergantung pada ingatan satu tim. Ketika bukti baru muncul, asumsi lama harus dapat direvisi tanpa dianggap sebagai kegagalan kepemimpinan. Kemampuan mengubah arah secara tertib justru merupakan tanda kematangan dan strategic flexibility.

15. Pilar Kelima - Strategi, Proses, Kepemimpinan, dan Nilai Organisasi

Bagian ini berangkat dari tesis bahwa Transformasi AI adalah perubahan organisasi. Ia mengubah aliran informasi, definisi keahlian, ukuran kinerja, relasi antarunit, dan sumber legitimasi keputusan. Tanpa kepemimpinan, proyek terpecah menjadi eksperimen lokal yang tidak dapat diskalakan. Tesis tersebut menempatkan AI di dalam realitas organisasi, bukan di ruang laboratorium yang steril. Nilai tidak muncul dari prediksi saja, melainkan dari perubahan keputusan dan hasil. Karena perubahan keputusan selalu melibatkan kepentingan, kewenangan, dan kemungkinan kerugian, setiap pilihan teknis sekaligus merupakan pilihan sosial dan manajerial.

Struktur persoalannya mencakup lapisan-lapisan berikut. Kepemimpinan perlu membangun visi, portofolio use case, prioritas risiko, struktur keputusan, anggaran, kapasitas belajar, dan komunikasi. Budaya yang diperlukan bukan budaya menerima semua inovasi, melainkan budaya eksperimen disiplin dan keberanian menghentikan proyek yang tidak bernilai. Lapisan tersebut membentuk arsitektur keputusan. Perubahan kecil pada definisi target, hak akses, antarmuka, atau

insentif pengguna dapat mengubah dampak meskipun model tidak berubah. Oleh sebab itu, dokumentasi teknis perlu dilengkapi dengan dokumentasi proses dan keputusan.

Narasi kasus dapat menggambarkan hubungan antarfaktor. Perusahaan distribusi yang menerapkan prediksi persediaan harus menyelaraskan pembelian, gudang, penjualan, keuangan, dan pemasok. Jika insentif tiap unit tetap bertentangan, prediksi yang baik tidak akan mengubah keputusan. Di sini terlihat bahwa solusi yang lebih sederhana dapat menjadi lebih unggul apabila selaras dengan kondisi penggunaan. Keunggulan praktis mencakup keterandalan, keterjangkauan, penerimaan, dan kemampuan diperbaiki, bukan hanya kecanggihan.

Perhatian khusus diperlukan pada pola kegagalan berikut. Ketakutan kehilangan pekerjaan mendorong resistensi dan shadow AI. Sebaliknya, narasi bahwa AI akan menyelesaikan semua masalah menciptakan hype. Keduanya merusak kepercayaan karena mengabaikan trade-off dan pengalaman pekerja. Risiko jarang berasal dari satu sebab; ia muncul dari kombinasi data, desain, tekanan bisnis, perilaku pengguna, dan kontrol yang lemah. Analisis akar masalah karena itu harus lintas fungsi dan menghindari godaan menyalahkan satu operator.

Agenda tindakan yang mengikuti analisis ini ialah Perubahan perlu dirancang melalui partisipasi, pelatihan, redesign pekerjaan, jalur eskalasi, dan pembagian manfaat produktivitas. Komunikasi harus membedakan eksperimen, pilot, dan sistem produksi agar ekspektasi realistis. Disiplin tersebut menghubungkan strategi dengan operasi. Ia mencegah proyek terseret oleh hype, tetapi juga mencegah birokrasi membunuh eksperimen. Kontrol dibuat proporsional: semakin besar dampak, semakin tinggi kebutuhan bukti dan pengawasan.

Pada tingkat kebijakan dan pelayanan, Budaya gotong royong dapat menjadi modal bagi co-design, tetapi hierarki yang kuat dapat menghambat kritik terhadap sistem. Pimpinan perlu melindungi ruang bagi pelapor masalah dan dissent profesional. Pemerataan perlu menjadi indikator sejak awal, bukan tambahan setelah sistem selesai. Program yang berhasil di kota besar harus diuji ulang sebelum dipakai di daerah dengan bahasa, konektivitas, dan struktur layanan berbeda.

Rujukan akademik mendukung pembacaan ini. Jöhnk et al. (2021) menempatkan budaya inovasi, kerja kolaboratif, dan change management sebagai unsur kesiapan AI. Vial (2019) juga melihat transformasi digital sebagai respons strategis terhadap disrupsi, bukan sekadar pemasangan teknologi. Dalam praktik, temuan itu perlu diterjemahkan menjadi artefak: datasheet, model card, risk register, evaluation report, log, incident record, dan keputusan tertulis. Artefak membuat pengetahuan tidak hilang ketika orang atau vendor berganti.

Prinsip kehati-hatian yang produktif patut ditekankan. Kehati-hatian bukan menunggu kepastian sempurna, karena inovasi selalu mengandung ketidakpastian. Kehati-hatian berarti membuat ketidakpastian terlihat, mengendalikan skala eksperimen, mengukur konsekuensi, dan menjaga

reversibilitas. Ketika dampak rendah, eksperimen dapat cepat; ketika menyangkut keselamatan, hak, atau penghidupan, standar bukti dan pengawasan harus lebih tinggi.

Perspektif pemangku kepentingan juga memperluas kualitas analisis. Pembangun melihat performa; pengguna melihat kemudahan; manajer melihat hasil; auditor melihat bukti; masyarakat melihat keadilan; dan pihak yang dirugikan melihat kemungkinan pemulihan. Tidak satu pun perspektif cukup sendirian. Proses partisipatif bukan berarti semua orang merancang algoritma, melainkan bahwa pengalaman dan kepentingan yang relevan masuk pada waktu ketika keputusan masih dapat diubah. Partisipasi yang terlambat hanya menjadi legitimasi simbolik bagi desain yang telah terkunci.

16. AI, Pendidikan, Reskilling, dan Masa Depan Kerja

AI mengotomasi sebagian tugas, mengaugmentasi tugas lain, dan menciptakan pekerjaan baru. Dampaknya tidak hanya ditentukan oleh kemampuan model, tetapi oleh bagaimana organisasi memecah pekerjaan, mengubah proses, menilai kinerja, dan membagikan hasil produktivitas. Jika prinsip ini diterima, maka evaluasi tidak boleh berhenti pada pertanyaan 'apakah sistem dapat melakukannya'. Pertanyaan yang lebih lengkap adalah apakah sistem patut melakukannya, dalam kondisi apa, untuk siapa, dengan biaya berapa, siapa yang mengawasi, dan apa yang terjadi ketika ia salah. Rangkaian pertanyaan tersebut membentuk jembatan antara ilmu komputer, manajemen, hukum, etika, dan kebijakan publik.

Secara analitis, ruang lingkupnya dapat diuraikan sebagai berikut. Keterampilan penting mencakup problem framing, literasi data, prompt dan tool use, verifikasi sumber, penalaran kausal, komunikasi, etika, kreativitas, dan kemampuan bekerja lintas disiplin. Kompetensi manusia bergeser dari menghasilkan semua keluaran menjadi mengarahkan, memeriksa, dan bertanggung jawab. Unsur-unsur tersebut tidak sebaiknya diperlakukan sebagai daftar pemeriksaan yang mekanis. Hubungan di antaranya perlu dicari: peningkatan pada satu dimensi mungkin memperburuk dimensi lain, dan penghematan pada tahap awal dapat menimbulkan biaya koreksi yang lebih besar kemudian. Pendekatan yang matang selalu menyatakan trade-off, asumsi, serta batas penerapan.

Sebuah ilustrasi membantu memperjelasnya. Dosen dapat memakai AI untuk membuat contoh dan umpan balik awal, tetapi tetap perlu merancang tujuan belajar, memeriksa akurasi, menilai proses berpikir, dan menjaga integritas akademik. Kurikulum harus menilai kemampuan menggunakan AI sekaligus kemampuan berpikir tanpa ketergantungan. Kasus ini menunjukkan bahwa nilai AI bersifat kontekstual. Model yang sama dapat berhasil di satu tempat dan gagal di tempat lain karena perbedaan populasi, alur kerja, tujuan, atau kapasitas. Pilot karena itu bukan sekadar uji perangkat, melainkan uji hipotesis tentang sistem kerja baru.

Risiko utama muncul ketika asumsi tidak terlihat. Reskilling yang hanya mengajarkan aplikasi tertentu cepat usang. Larangan total mendorong penggunaan tersembunyi, sedangkan penerimaan tanpa batas mengikis pembelajaran. Ketimpangan akses juga dapat memperbesar kesenjangan pendidikan. Masalah ini sering membesar secara perlahan karena keluaran yang salah tidak selalu langsung menimbulkan keluhan. Kelompok yang dirugikan mungkin tidak mengetahui bahwa AI terlibat, tidak memiliki kanal keberatan, atau tidak mempunyai data pembanding. Karena itu, ketiadaan insiden yang dilaporkan bukan bukti ketiadaan kerugian.

Implikasi manajerialnya adalah Institusi perlu membuat AI literacy continuum, assessment baru, kebijakan atribusi, ruang eksperimen, dan dukungan bagi dosen serta pekerja. Produktivitas harus diukur bersama kualitas, pembelajaran, kesejahteraan, dan kesempatan kerja. Keputusan tersebut perlu diterjemahkan ke dalam pemilik, jadwal, anggaran, bukti, dan ambang. Tanpa kelima unsur itu, rekomendasi berubah menjadi aspirasi. Dewan atau pimpinan juga perlu menerima laporan tentang asumsi dan ketidakpastian, bukan hanya keberhasilan proyek.

Konteks nasional dan lokal menambah lapisan penting. Indonesia perlu menghubungkan pendidikan vokasi, perguruan tinggi, industri, dan pembelajaran sepanjang hayat. Reskilling harus mencapai guru, aparatur daerah, UMKM, tenaga kesehatan, dan pekerja informal, bukan hanya sektor teknologi. Kebijakan harus mempertimbangkan bahwa kapasitas tidak merata. Standar nasional perlu menjaga hak dan interoperabilitas, sedangkan implementasi memberi ruang adaptasi sektoral serta lokal. Pendekatan berlapis ini lebih realistis daripada satu solusi untuk semua.

Landasan ilmiah memperkuat argumen tersebut. Noy dan Zhang (2023) menemukan peningkatan produktivitas pada tugas menulis profesional dengan AI generatif, tetapi manfaat berbeda menurut kemampuan awal dan desain tugas. Acemoglu dan Restrepo (2018) menekankan perlombaan antara otomatisasi dan penciptaan tugas baru. Literatur ini tidak memberi resep tunggal, tetapi memberi cara berpikir: dokumentasikan asumsi, ukur pada konteks penggunaan, libatkan pihak terdampak, dan pertahankan kemampuan koreksi. Dengan demikian, bukti ilmiah menjadi sarana pembelajaran organisasi.

Jika bagian ini dihubungkan kembali dengan kerangka tujuh pilar, terlihat pola sistemik. Mutu satu faktor menentukan beban faktor lain. Data yang lemah memaksa model bekerja lebih keras; model yang rumit menuntut komputasi dan keahlian lebih besar; antarmuka yang buruk meningkatkan risiko manusia; governance yang terlambat memperbesar biaya perubahan. Sebaliknya, dokumentasi, modularitas, dan pembelajaran lintas fungsi menciptakan efek pengungkit. Organisasi tidak harus sempurna sebelum memulai, tetapi harus mengetahui kelemahannya, membatasi ruang risiko, dan membangun jalur peningkatan.

Akhirnya, prinsip proporsionalitas perlu dijaga. Tidak setiap penggunaan AI membutuhkan birokrasi yang sama. Alat untuk menyusun ide internal dapat diberi kontrol ringan, sedangkan sistem

yang memengaruhi kesehatan, pendidikan, pekerjaan, kredit, atau hak warga membutuhkan standar lebih tinggi. Diferensiasi ini memungkinkan inovasi tetap bergerak sambil memusatkan sumber daya pengawasan pada tempat yang paling berbahaya. Dengan demikian, governance tidak menjadi rem yang selalu ditekan, melainkan sistem kemudi yang menentukan arah, kecepatan, dan batas aman.

17. Pilar Keenam - Tata Kelola dan Etika

Pokok persoalan dalam bagian ini adalah Tata kelola AI adalah sistem keputusan yang menentukan siapa boleh membangun, membeli, menggunakan, mengubah, mengawasi, dan menghentikan AI. Etika menyediakan orientasi tentang yang baik dan adil; governance menerjemahkannya menjadi peran, proses, bukti, dan konsekuensi. Perspektif tersebut menggeser pembicaraan dari pertanyaan sempit mengenai kemampuan perangkat menjadi pertanyaan manajerial mengenai kesesuaian, keterhubungan, dan konsekuensi. Dalam sistem AI, sebuah komponen tidak pernah benar-benar berdiri sendiri. Ia menerima masukan dari komponen lain, mengubah perilaku organisasi, lalu menghasilkan umpan balik yang dapat memperkuat manfaat maupun memperbesar risiko. Karena itu, analisis perlu memperhatikan proses sebelum model dijalankan, keputusan ketika keluaran digunakan, dan dampak setelah keputusan terjadi.

Ada beberapa dimensi yang harus dibaca secara bersamaan. Prinsip umum mencakup kemanfaatan, nonmaleficence, otonomi, keadilan, transparansi, privasi, keamanan, robustness, dan akuntabilitas. Namun prinsip harus diubah menjadi kontrol konkret seperti klasifikasi risiko, impact assessment, dokumentasi, audit, monitoring, dan incident response. Masing-masing dapat diukur, tetapi angka tidak pernah berbicara tanpa konteks. Metrik harus disertai definisi, sumber, frekuensi, populasi, dan ambang tindakan. Dengan disiplin ini, organisasi dapat membedakan sinyal yang benar-benar penting dari indikator yang sekadar mudah dikumpulkan.

Pertimbangkan contoh berikut. Sistem rekomendasi bantuan sosial memerlukan tujuan yang sah, kualitas data, pengujian kelompok, penjelasan, jalur koreksi, keamanan, dan pengawasan independen. Karena menyangkut hak warga, efisiensi administratif tidak dapat menjadi satu-satunya ukuran. Yang perlu dicermati bukan hanya keluaran algoritma, tetapi juga siapa yang membaca, tindakan apa yang menyusul, dan apakah hasil aktual dapat kembali menjadi pembelajaran. Tanpa loop umpan balik, organisasi tidak mengetahui apakah prediksi meningkatkan outcome atau sekadar mengubah beban kerja.

Sisi kegagalannya tidak boleh dipandang sebagai pengecualian teknis. Ethics washing terjadi ketika organisasi mempublikasikan prinsip tetapi tidak mengubah insentif, anggaran, tenggat, atau kewenangan. Dewan etik tanpa akses teknis dan tanpa hak menghentikan sistem hanya menjadi simbol. Kegagalan merupakan informasi tentang kelemahan sistem. Organisasi yang menghukum pelaporan akan kehilangan kesempatan belajar, sedangkan organisasi yang mengubah insiden menjadi perbaikan akan membangun ketahanan. Prinsip ini menuntut budaya tanpa rasa takut sekaligus tanggung jawab yang jelas.

Dari sudut pandang implementasi, Governance perlu proporsional terhadap risiko. Penggunaan rendah risiko dapat mengikuti kontrol ringan; penggunaan berdampak tinggi memerlukan review multidisiplin, dokumentasi lebih dalam, validasi independen, human oversight, dan mekanisme

pemulihan. Proses yang baik menyediakan jalur normal, jalur pengecualian, dan jalur penghentian. Ia juga menjaga pemisahan tugas antara pembangun, pemilik bisnis, validator, dan auditor agar konflik kepentingan dapat dikendalikan.

Relevansinya bagi pembangunan Indonesia terlihat jelas. Surat Edaran Menkominfo No. 9 Tahun 2023 memberi panduan etika, sementara pada 2026 pemerintah memfinalisasi regulasi dan peta jalan AI. Tantangannya adalah menghubungkan prinsip nasional dengan kapasitas implementasi sektoral dan daerah. Tantangan tersebut sekaligus peluang untuk membangun inovasi yang berangkat dari kebutuhan nyata. Keunggulan tidak selalu datang dari model terbesar; ia dapat datang dari data lokal yang bermutu, desain sederhana, biaya rendah, dan kepercayaan masyarakat.

Temuan penelitian yang relevan menyatakan bahwa OECD AI Principles menekankan pertumbuhan inklusif, nilai berpusat pada manusia, transparansi, robustness, keamanan, dan akuntabilitas. NIST AI RMF menyusun fungsi govern, map, measure, dan manage untuk menjadikan risiko dapat dikelola. Pelajaran pentingnya ialah bahwa inovasi dan kehati-hatian dapat berjalan bersama. Pengujian yang kuat bukan penghambat, melainkan mekanisme yang memungkinkan skala tumbuh tanpa kehilangan kendali.

Inti manajerialnya adalah keselarasan. Strategi, data, model, infrastruktur, kompetensi, proses, dan akuntabilitas harus menunjuk pada outcome yang sama. Bila satu unit mengejar volume, unit lain mengejar akurasi, dan pengguna mengejar kecepatan, sistem dapat menghasilkan optimasi lokal yang merusak tujuan keseluruhan. Keselarasan memerlukan bahasa bersama dan forum keputusan yang mempertemukan ahli teknis, pemilik proses, pengguna, hukum, keamanan, dan pihak terdampak.

Bagi pengambil keputusan, bagian ini dapat dijadikan bahan refleksi sebelum menyetujui investasi. Apakah manfaat yang dijanjikan mempunyai baseline dan indikator outcome? Apakah ketidakpastian disampaikan secara jujur? Apakah pengguna memiliki waktu dan kewenangan untuk memeriksa? Apakah kelompok terdampak dapat mengoreksi data dan keputusan? Apakah organisasi sanggup memelihara sistem setelah pilot berakhir? Pertanyaan-pertanyaan ini mengubah diskusi dari antusiasme teknologi menjadi tanggung jawab institusional. Jawaban tidak harus selalu sempurna, tetapi harus dibuktikan dan ditinjau ulang.

18. Akuntabilitas, Audit, dan Manajemen Insiden

Akuntabilitas berarti kemampuan menjelaskan keputusan, menunjukkan bukti kehati-hatian, menerima konsekuensi, dan melakukan pemulihan. Ia tidak tercapai hanya dengan menuliskan nama penanggung jawab; orang tersebut harus memiliki kewenangan, informasi, dan sumber daya. Pernyataan ini penting karena banyak proyek AI dinilai terlalu awal dari penampilan demonstrasi. Keberhasilan sebenarnya baru dapat diketahui ketika sistem menghadapi variasi pengguna, data yang

tidak sempurna, tekanan waktu, gangguan infrastruktur, dan tuntutan pertanggungjawaban. Dengan kata lain, kecerdasan teknis harus diterjemahkan menjadi kemampuan institusional. Terjemahan itu membutuhkan desain tujuan, proses, insentif, dan pengawasan yang konsisten.

Struktur persoalannya mencakup lapisan-lapisan berikut. Audit AI mencakup data, model, proses, antarmuka, vendor, keamanan, outcome, dan dampak sosial. Audit internal mendukung perbaikan berkelanjutan; audit independen meningkatkan kredibilitas. Keduanya memerlukan log dan dokumentasi yang dapat ditelusuri. Lapisan tersebut membentuk arsitektur keputusan. Perubahan kecil pada definisi target, hak akses, antarmuka, atau insentif pengguna dapat mengubah dampak meskipun model tidak berubah. Oleh sebab itu, dokumentasi teknis perlu dilengkapi dengan dokumentasi proses dan keputusan.

Narasi kasus dapat menggambarkan hubungan antarfaktor. Jika chatbot kesehatan memberi saran berbahaya, organisasi harus mengetahui versi model, prompt, konteks, sumber, pengguna, guardrail, dan tindakan lanjutan. Tanpa observability, insiden tidak dapat direkonstruksi dan pelajaran tidak dapat diambil. Di sini terlihat bahwa solusi yang lebih sederhana dapat menjadi lebih unggul apabila selaras dengan kondisi penggunaan. Keunggulan praktis mencakup keterandalan, keterjangkauan, penerimaan, dan kemampuan diperbaiki, bukan hanya kecanggihan.

Perhatian khusus diperlukan pada pola kegagalan berikut. Blame shifting kepada vendor atau pengguna mengabaikan tanggung jawab institusi yang memilih dan menempatkan sistem. Insiden juga dapat disembunyikan karena tim takut proyek dihentikan atau reputasi rusak. Risiko jarang berasal dari satu sebab; ia muncul dari kombinasi data, desain, tekanan bisnis, perilaku pengguna, dan kontrol yang lemah. Analisis akar masalah karena itu harus lintas fungsi dan menghindari godaan menyalahkan satu operator.

Agenda tindakan yang mengikuti analisis ini ialah Organisasi membutuhkan taxonomy insiden, kanal pelaporan, severity levels, tim respons, prosedur containment, komunikasi, analisis akar masalah, kompensasi, dan mekanisme pembaruan. Near miss perlu dicatat sebelum menjadi kerugian. Disiplin tersebut menghubungkan strategi dengan operasi. Ia mencegah proyek terseret oleh hype, tetapi juga mencegah birokrasi membunuh eksperimen. Kontrol dibuat proporsional: semakin besar dampak, semakin tinggi kebutuhan bukti dan pengawasan.

Pada tingkat kebijakan dan pelayanan, Ekosistem nasional dapat mengembangkan registri insiden anonim dan pusat pembelajaran lintas sektor. Pendekatan ini mengubah kegagalan menjadi pengetahuan publik tanpa menghilangkan tanggung jawab. Pemerataan perlu menjadi indikator sejak awal, bukan tambahan setelah sistem selesai. Program yang berhasil di kota besar harus diuji ulang sebelum dipakai di daerah dengan bahasa, konektivitas, dan struktur layanan berbeda.

Rujukan akademik mendukung pembacaan ini. Raji et al. (2020) mengusulkan kerangka audit algoritmik internal end-to-end. Model cards dan datasheets melengkapi audit dengan bukti tentang

data dan model, tetapi tetap harus dihubungkan dengan dampak setelah deployment. Dalam praktik, temuan itu perlu diterjemahkan menjadi artefak: datasheet, model card, risk register, evaluation report, log, incident record, dan keputusan tertulis. Artefak membuat pengetahuan tidak hilang ketika orang atau vendor berganti.

Prinsip kehati-hatian yang produktif patut ditekankan. Kehati-hatian bukan menunggu kepastian sempurna, karena inovasi selalu mengandung ketidakpastian. Kehati-hatian berarti membuat ketidakpastian terlihat, mengendalikan skala eksperimen, mengukur konsekuensi, dan menjaga reversibilitas. Ketika dampak rendah, eksperimen dapat cepat; ketika menyangkut keselamatan, hak, atau penghidupan, standar bukti dan pengawasan harus lebih tinggi.

Dari sisi pembelajaran organisasi, kualitas keputusan lebih penting daripada kecepatan peluncuran semata. Setiap eksperimen perlu menghasilkan pengetahuan tentang data, pengguna, proses, risiko, dan biaya. Pengetahuan itu harus dibagikan lintas unit melalui dokumentasi dan forum review, sehingga keberhasilan tidak bergantung pada ingatan satu tim. Ketika bukti baru muncul, asumsi lama harus dapat direvisi tanpa dianggap sebagai kegagalan kepemimpinan. Kemampuan mengubah arah secara tertib justru merupakan tanda kematangan dan strategic flexibility.

19. Keamanan, Privasi, dan Ketahanan Operasional

Bagian ini berangkat dari tesis bahwa AI memperluas permukaan serangan karena sistem menerima input kompleks, berinteraksi dengan data sensitif, memakai komponen pihak ketiga, dan kadang dapat menjalankan alat. Keamanan harus mencakup kerahasiaan, integritas, ketersediaan, keselamatan, dan penyalahgunaan. Tesis tersebut menempatkan AI di dalam realitas organisasi, bukan di ruang laboratorium yang steril. Nilai tidak muncul dari prediksi saja, melainkan dari perubahan keputusan dan hasil. Karena perubahan keputusan selalu melibatkan kepentingan, kewenangan, dan kemungkinan kerugian, setiap pilihan teknis sekaligus merupakan pilihan sosial dan manajerial.

Secara analitis, ruang lingkupnya dapat diuraikan sebagai berikut. Ancaman meliputi data poisoning, model theft, prompt injection, jailbreak, adversarial examples, membership inference, supply-chain compromise, insecure plugins, dan output berbahaya. Agen AI menambah risiko karena dapat mengambil tindakan berantai. Unsur-unsur tersebut tidak sebaiknya diperlakukan sebagai daftar pemeriksaan yang mekanis. Hubungan di antaranya perlu dicari: peningkatan pada satu dimensi mungkin memperburuk dimensi lain, dan penghematan pada tahap awal dapat menimbulkan biaya koreksi yang lebih besar kemudian. Pendekatan yang matang selalu menyatakan trade-off, asumsi, serta batas penerapan.

Sebuah ilustrasi membantu memperjelasnya. Asisten internal yang terhubung ke email dan dokumen dapat menerima instruksi tersembunyi dari lampiran dan mengirim data ke pihak lain.

Pembatasan hak, sandbox, allowlist tools, konfirmasi manusia, dan monitoring diperlukan. Kasus ini menunjukkan bahwa nilai AI bersifat kontekstual. Model yang sama dapat berhasil di satu tempat dan gagal di tempat lain karena perbedaan populasi, alur kerja, tujuan, atau kapasitas. Pilot karena itu bukan sekadar uji perangkat, melainkan uji hipotesis tentang sistem kerja baru.

Risiko utama muncul ketika asumsi tidak terlihat. Guardrail pada antarmuka tidak cukup jika akses backend terlalu luas. Red teaming sekali sebelum peluncuran juga tidak cukup karena model, data, dan teknik serangan berubah. Masalah ini sering membesar secara perlahan karena keluaran yang salah tidak selalu langsung menimbulkan keluhan. Kelompok yang dirugikan mungkin tidak mengetahui bahwa AI terlibat, tidak memiliki kanal keberatan, atau tidak mempunyai data pembandingan. Karena itu, ketiadaan insiden yang dilaporkan bukan bukti ketiadaan kerugian.

Implikasi manajerialnya adalah AI security perlu diintegrasikan ke secure development lifecycle: threat modeling, least privilege, secrets management, dependency scanning, adversarial testing, logging, fallback, patching, dan disaster recovery. Hak akses harus mengikuti tugas minimum. Keputusan tersebut perlu diterjemahkan ke dalam pemilik, jadwal, anggaran, bukti, dan ambang. Tanpa kelima unsur itu, rekomendasi berubah menjadi aspirasi. Dewan atau pimpinan juga perlu menerima laporan tentang asumsi dan ketidakpastian, bukan hanya keberhasilan proyek.

Konteks nasional dan lokal menambah lapisan penting. Sektor publik dan infrastruktur kritis memerlukan standar lebih tinggi, latihan insiden, dan koordinasi antarlembaga. Keterbatasan talenta keamanan harus diatasi melalui pusat keahlian bersama. Kebijakan harus mempertimbangkan bahwa kapasitas tidak merata. Standar nasional perlu menjaga hak dan interoperabilitas, sedangkan implementasi memberi ruang adaptasi sektoral serta lokal. Pendekatan berlapis ini lebih realistis daripada satu solusi untuk semua.

Landasan ilmiah memperkuat argumen tersebut. NIST AI RMF menempatkan safe, secure, resilient, privacy-enhanced, dan valid sebagai karakteristik AI tepercaya. OECD juga meminta risiko dinilai dan dikelola sepanjang siklus hidup sistem. Literatur ini tidak memberi resep tunggal, tetapi memberi cara berpikir: dokumentasikan asumsi, ukur pada konteks penggunaan, libatkan pihak terdampak, dan pertahankan kemampuan koreksi. Dengan demikian, bukti ilmiah menjadi sarana pembelajaran organisasi.

Jika bagian ini dihubungkan kembali dengan kerangka tujuh pilar, terlihat pola sistemik. Mutu satu faktor menentukan beban faktor lain. Data yang lemah memaksa model bekerja lebih keras; model yang rumit menuntut komputasi dan keahlian lebih besar; antarmuka yang buruk meningkatkan risiko manusia; governance yang terlambat memperbesar biaya perubahan. Sebaliknya, dokumentasi, modularitas, dan pembelajaran lintas fungsi menciptakan efek pengungkit. Organisasi tidak harus sempurna sebelum memulai, tetapi harus mengetahui kelemahannya, membatasi ruang risiko, dan membangun jalur peningkatan.

Perspektif pemangku kepentingan juga memperluas kualitas analisis. Pembangun melihat performa; pengguna melihat kemudahan; manajer melihat hasil; auditor melihat bukti; masyarakat melihat keadilan; dan pihak yang dirugikan melihat kemungkinan pemulihan. Tidak satu pun perspektif cukup sendirian. Proses partisipatif bukan berarti semua orang merancang algoritma, melainkan bahwa pengalaman dan kepentingan yang relevan masuk pada waktu ketika keputusan masih dapat diubah. Partisipasi yang terlambat hanya menjadi legitimasi simbolik bagi desain yang telah terkunci.

20. Studi Kasus Terpadu: Kesehatan, Pendidikan, Pemerintahan, dan UMKM

Nilai kerangka tujuh pilar terlihat ketika diterapkan pada sektor berbeda. Tidak ada satu urutan yang selalu sama, tetapi setiap sektor harus menghubungkan data, model, komputasi, manusia, dan governance dengan konsekuensi khususnya. Jika prinsip ini diterima, maka evaluasi tidak boleh berhenti pada pertanyaan 'apakah sistem dapat melakukannya'. Pertanyaan yang lebih lengkap adalah apakah sistem patut melakukannya, dalam kondisi apa, untuk siapa, dengan biaya berapa, siapa yang mengawasi, dan apa yang terjadi ketika ia salah. Rangkaian pertanyaan tersebut membentuk jembatan antara ilmu komputer, manajemen, hukum, etika, dan kebijakan publik.

Ada beberapa dimensi yang harus dibaca secara bersamaan. Kesehatan menekankan keselamatan dan validasi klinis; pendidikan menekankan pembelajaran dan integritas; pemerintahan menekankan hak, transparansi, dan pemerataan; UMKM menekankan biaya, kemudahan, dan kecepatan manfaat. Masing-masing dapat diukur, tetapi angka tidak pernah berbicara tanpa konteks. Metrik harus disertai definisi, sumber, frekuensi, populasi, dan ambang tindakan. Dengan disiplin ini, organisasi dapat membedakan sinyal yang benar-benar penting dari indikator yang sekadar mudah dikumpulkan.

Pertimbangkan contoh berikut. Bayangkan platform pendamping UMKM yang menggabungkan pencatatan transaksi, prediksi arus kas, rekomendasi stok, dan bantuan pemasaran. Ia memerlukan data sederhana namun konsisten, model yang memahami musim lokal, aplikasi murah, pelatihan pengguna, serta aturan agar data tidak dipakai untuk menekan pedagang. Yang perlu dicermati bukan hanya keluaran algoritma, tetapi juga siapa yang membaca, tindakan apa yang menyusul, dan apakah hasil aktual dapat kembali menjadi pembelajaran. Tanpa loop umpan balik, organisasi tidak mengetahui apakah prediksi meningkatkan outcome atau sekadar mengubah beban kerja.

Sisi kegagalannya tidak boleh dipandang sebagai pengecualian teknis. Solusi lintas sektor gagal bila hanya menyalin antarmuka. Tingkat toleransi kesalahan berbeda. Kesalahan slogan pemasaran tidak sama dengan kesalahan dosis obat atau penolakan layanan sosial. Kegagalan merupakan informasi tentang kelemahan sistem. Organisasi yang menghukum pelaporan akan kehilangan kesempatan belajar, sedangkan organisasi yang mengubah insiden menjadi perbaikan akan membangun ketahanan. Prinsip ini menuntut budaya tanpa rasa takut sekaligus tanggung jawab yang jelas.

Dari sudut pandang implementasi, Portofolio use case harus diberi skor nilai, kelayakan, risiko, data readiness, integration effort, dan kemampuan pemilik proses. Mulailah dari manfaat jelas dan risiko terkendali, lalu tingkatkan kompleksitas setelah kapabilitas tumbuh. Proses yang baik menyediakan jalur normal, jalur pengecualian, dan jalur penghentian. Ia juga menjaga pemisahan

tugas antara pembangun, pemilik bisnis, validator, dan auditor agar konflik kepentingan dapat dikendalikan.

Relevansinya bagi pembangunan Indonesia terlihat jelas. Prioritas nasional dapat mencakup kesehatan primer, pembelajaran adaptif, pertanian dan perikanan, mitigasi bencana, layanan administrasi, serta produktivitas UMKM. Setiap program perlu indikator inklusivitas dan dampak wilayah. Tantangan tersebut sekaligus peluang untuk membangun inovasi yang berangkat dari kebutuhan nyata. Keunggulan tidak selalu datang dari model terbesar; ia dapat datang dari data lokal yang bermutu, desain sederhana, biaya rendah, dan kepercayaan masyarakat.

Temuan penelitian yang relevan menyatakan bahwa Topol (2019) menekankan potensi konvergensi kecerdasan manusia dan AI dalam kesehatan, sedangkan Kelly et al. (2019) menunjukkan bahwa implementasi klinis membutuhkan validasi, regulasi, integrasi alur kerja, dan penerimaan pengguna. Pelajaran pentingnya ialah bahwa inovasi dan kehati-hatian dapat berjalan bersama. Pengujian yang kuat bukan penghambat, melainkan mekanisme yang memungkinkan skala tumbuh tanpa kehilangan kendali.

Inti manajerialnya adalah keselarasan. Strategi, data, model, infrastruktur, kompetensi, proses, dan akuntabilitas harus menunjuk pada outcome yang sama. Bila satu unit mengejar volume, unit lain mengejar akurasi, dan pengguna mengejar kecepatan, sistem dapat menghasilkan optimasi lokal yang merusak tujuan keseluruhan. Keselarasan memerlukan bahasa bersama dan forum keputusan yang mempertemukan ahli teknis, pemilik proses, pengguna, hukum, keamanan, dan pihak terdampak.

Akhirnya, prinsip proporsionalitas perlu dijaga. Tidak setiap penggunaan AI membutuhkan birokrasi yang sama. Alat untuk menyusun ide internal dapat diberi kontrol ringan, sedangkan sistem yang memengaruhi kesehatan, pendidikan, pekerjaan, kredit, atau hak warga membutuhkan standar lebih tinggi. Diferensiasi ini memungkinkan inovasi tetap bergerak sambil memusatkan sumber daya pengawasan pada tempat yang paling berbahaya. Dengan demikian, governance tidak menjadi rem yang selalu ditekan, melainkan sistem kemudi yang menentukan arah, kecepatan, dan batas aman.

21. Model Kematangan AI Organisasi

Pokok persoalan dalam bagian ini adalah Kematangan AI bukan jumlah proyek, melainkan kemampuan menghasilkan nilai secara berulang, aman, dan dapat dipertanggungjawabkan. Organisasi dapat berkembang dari eksperimen ad hoc menuju operasi yang terstandar, terukur, terintegrasi, dan adaptif. Perspektif tersebut menggeser pembicaraan dari pertanyaan sempit mengenai kemampuan perangkat menjadi pertanyaan manajerial mengenai kesesuaian, keterhubungan, dan konsekuensi. Dalam sistem AI, sebuah komponen tidak pernah benar-benar berdiri sendiri. Ia menerima masukan dari komponen lain, mengubah perilaku organisasi, lalu

menghasilkan umpan balik yang dapat memperkuat manfaat maupun memperbesar risiko. Karena itu, analisis perlu memperhatikan proses sebelum model dijalankan, keputusan ketika keluaran digunakan, dan dampak setelah keputusan terjadi.

Struktur persoalannya mencakup lapisan-lapisan berikut. Pada tingkat awal, data tersebar dan pilot bergantung pada individu. Tingkat berkembang memiliki tim inti dan standar minimum. Tingkat terkelola memiliki portofolio, MLOps, governance, dan monitoring. Tingkat adaptif menghubungkan pembelajaran lintas sistem dengan strategi. Lapisan tersebut membentuk arsitektur keputusan. Perubahan kecil pada definisi target, hak akses, antarmuka, atau insentif pengguna dapat mengubah dampak meskipun model tidak berubah. Oleh sebab itu, dokumentasi teknis perlu dilengkapi dengan dokumentasi proses dan keputusan.

Narasi kasus dapat menggambarkan hubungan antarfaktor. Universitas pada tingkat awal mungkin memiliki banyak dosen memakai AI sendiri-sendiri. Untuk naik tingkat, universitas perlu kebijakan data, infrastruktur bersama, pelatihan, dukungan pedagogis, evaluasi dampak, dan proses persetujuan aplikasi berisiko. Di sini terlihat bahwa solusi yang lebih sederhana dapat menjadi lebih unggul apabila selaras dengan kondisi penggunaan. Keunggulan praktis mencakup keterandalan, keterjangkauan, penerimaan, dan kemampuan diperbaiki, bukan hanya kecanggihan.

Perhatian khusus diperlukan pada pola kegagalan berikut. Maturity theater terjadi ketika organisasi mengadopsi istilah, komite, dan dashboard tanpa mengubah hasil. Sebaliknya, standardisasi terlalu dini dapat mematikan eksperimen. Kematangan harus menyeimbangkan kontrol dan pembelajaran. Risiko jarang berasal dari satu sebab; ia muncul dari kombinasi data, desain, tekanan bisnis, perilaku pengguna, dan kontrol yang lemah. Analisis akar masalah karena itu harus lintas fungsi dan menghindari godaan menyalahkan satu operator.

Agenda tindakan yang mengikuti analisis ini ialah Assessment dilakukan per faktor dengan bukti. Skor rendah pada data mungkin memerlukan master data; skor rendah pada manusia memerlukan redesign pekerjaan; skor rendah pada governance memerlukan risk classification dan audit trail. Disiplin tersebut menghubungkan strategi dengan operasi. Ia mencegah proyek terseret oleh hype, tetapi juga mencegah birokrasi membunuh eksperimen. Kontrol dibuat proporsional: semakin besar dampak, semakin tinggi kebutuhan bukti dan pengawasan.

Pada tingkat kebijakan dan pelayanan, Model kematangan membantu membedakan bantuan untuk pemerintah pusat, daerah, universitas, rumah sakit, BUMN, dan UMKM. Kebijakan dapat memberi jalur bertahap, bukan standar seragam yang sulit dipenuhi. Pemerataan perlu menjadi indikator sejak awal, bukan tambahan setelah sistem selesai. Program yang berhasil di kota besar harus diuji ulang sebelum dipakai di daerah dengan bahasa, konektivitas, dan struktur layanan berbeda.

Rujukan akademik mendukung pembacaan ini. Literatur kesiapan dan kapabilitas AI menunjukkan bahwa nilai muncul dari konfigurasi sumber daya, keselarasan strategis, budaya, data, pengetahuan, dan proses, bukan dari aset teknologi yang berdiri sendiri (Jöhnk et al., 2021; Mikalef & Gupta, 2021). Dalam praktik, temuan itu perlu diterjemahkan menjadi artefak: datasheet, model card, risk register, evaluation report, log, incident record, dan keputusan tertulis. Artefak membuat pengetahuan tidak hilang ketika orang atau vendor berganti.

Prinsip kehati-hatian yang produktif patut ditekankan. Kehati-hatian bukan menunggu kepastian sempurna, karena inovasi selalu mengandung ketidakpastian. Kehati-hatian berarti membuat ketidakpastian terlihat, mengendalikan skala eksperimen, mengukur konsekuensi, dan menjaga reversibilitas. Ketika dampak rendah, eksperimen dapat cepat; ketika menyangkut keselamatan, hak, atau penghidupan, standar bukti dan pengawasan harus lebih tinggi.

Bagi pengambil keputusan, bagian ini dapat dijadikan bahan refleksi sebelum menyetujui investasi. Apakah manfaat yang dijanjikan mempunyai baseline dan indikator outcome? Apakah ketidakpastian disampaikan secara jujur? Apakah pengguna memiliki waktu dan kewenangan untuk memeriksa? Apakah kelompok terdampak dapat mengoreksi data dan keputusan? Apakah organisasi sanggup memelihara sistem setelah pilot berakhir? Pertanyaan-pertanyaan ini mengubah diskusi dari antusiasme teknologi menjadi tanggung jawab institusional. Jawaban tidak harus selalu sempurna, tetapi harus dibuktikan dan ditinjau ulang.

22. Peta Jalan Implementasi: Dari Masalah ke Nilai

Implementasi AI yang sehat dimulai dengan problem discovery, dilanjutkan feasibility dan risk assessment, desain data, baseline, pilot, evaluasi, deployment terbatas, monitoring, dan scale-up. Setiap tahap harus mempunyai keputusan go, revise, atau stop. Pernyataan ini penting karena banyak proyek AI dinilai terlalu awal dari penampilan demonstrasi. Keberhasilan sebenarnya baru dapat diketahui ketika sistem menghadapi variasi pengguna, data yang tidak sempurna, tekanan waktu, gangguan infrastruktur, dan tuntutan pertanggungjawaban. Dengan kata lain, kecerdasan teknis harus diterjemahkan menjadi kemampuan institusional. Terjemahan itu membutuhkan desain tujuan, proses, insentif, dan pengawasan yang konsisten.

Secara analitis, ruang lingkupnya dapat diuraikan sebagai berikut. Problem discovery memetakan pengguna dan outcome; feasibility menilai data dan integrasi; risk assessment menilai dampak; pilot menguji asumsi; deployment membangun operasi; monitoring mengamati drift, biaya, insiden, dan manfaat. Unsur-unsur tersebut tidak sebaiknya diperlakukan sebagai daftar pemeriksaan yang mekanis. Hubungan di antaranya perlu dicari: peningkatan pada satu dimensi mungkin memperburuk dimensi lain, dan penghematan pada tahap awal dapat menimbulkan biaya

koreksi yang lebih besar kemudian. Pendekatan yang matang selalu menyatakan trade-off, asumsi, serta batas penerapan.

Sebuah ilustrasi membantu memperjelasnya. Program 100 hari dapat memilih dua use case: satu produktivitas internal berisiko rendah dan satu layanan inti dengan pilot terbatas. Tim menetapkan baseline sebelum AI, sehingga manfaat dapat dibandingkan secara jujur. Kasus ini menunjukkan bahwa nilai AI bersifat kontekstual. Model yang sama dapat berhasil di satu tempat dan gagal di tempat lain karena perbedaan populasi, alur kerja, tujuan, atau kapasitas. Pilot karena itu bukan sekadar uji perangkat, melainkan uji hipotesis tentang sistem kerja baru.

Risiko utama muncul ketika asumsi tidak terlihat. Pilot purgatory terjadi ketika eksperimen tidak pernah masuk operasi karena tidak ada pemilik proses, anggaran integrasi, data pipeline, atau keputusan risiko. Scale-up prematur terjadi ketika demo langsung diperluas sebelum kontrol tersedia. Masalah ini sering membesar secara perlahan karena keluaran yang salah tidak selalu langsung menimbulkan keluhan. Kelompok yang dirugikan mungkin tidak mengetahui bahwa AI terlibat, tidak memiliki kanal keberatan, atau tidak mempunyai data pembandingan. Karena itu, ketiadaan insiden yang dilaporkan bukan bukti ketiadaan kerugian.

Implikasi manajerialnya adalah Stage gate perlu memeriksa ketujuh pilar. Tidak ada deployment jika data tidak sah, model tidak memenuhi ambang, infrastruktur tidak resilien, pengguna belum siap, atau governance belum menyetujui. Dokumentasi keputusan mencegah pengulangan kesalahan. Keputusan tersebut perlu diterjemahkan ke dalam pemilik, jadwal, anggaran, bukti, dan ambang. Tanpa kelima unsur itu, rekomendasi berubah menjadi aspirasi. Dewan atau pimpinan juga perlu menerima laporan tentang asumsi dan ketidakpastian, bukan hanya keberhasilan proyek.

Konteks nasional dan lokal menambah lapisan penting. Peta jalan nasional dapat memakai pola sandbox sektoral, pusat keahlian, procurement guideline, benchmark lokal, dataset publik aman, dan dukungan implementasi daerah. Program harus mengukur kapasitas yang tertinggal, bukan hanya jumlah aplikasi. Kebijakan harus mempertimbangkan bahwa kapasitas tidak merata. Standar nasional perlu menjaga hak dan interoperabilitas, sedangkan implementasi memberi ruang adaptasi sektoral serta lokal. Pendekatan berlapis ini lebih realistis daripada satu solusi untuk semua.

Landasan ilmiah memperkuat argumen tersebut. NIST AI RMF menawarkan logika berulang govern-map-measure-manage. Kerangka ini sejalan dengan pendekatan implementasi bertahap, karena risiko dipahami, diukur, ditangani, dan ditinjau kembali sepanjang siklus hidup. Literatur ini tidak memberi resep tunggal, tetapi memberi cara berpikir: dokumentasikan asumsi, ukur pada konteks penggunaan, libatkan pihak terdampak, dan pertahankan kemampuan koreksi. Dengan demikian, bukti ilmiah menjadi sarana pembelajaran organisasi.

Jika bagian ini dihubungkan kembali dengan kerangka tujuh pilar, terlihat pola sistemik. Mutu satu faktor menentukan beban faktor lain. Data yang lemah memaksa model bekerja lebih keras;

model yang rumit menuntut komputasi dan keahlian lebih besar; antarmuka yang buruk meningkatkan risiko manusia; governance yang terlambat memperbesar biaya perubahan. Sebaliknya, dokumentasi, modularitas, dan pembelajaran lintas fungsi menciptakan efek pengungkit. Organisasi tidak harus sempurna sebelum memulai, tetapi harus mengetahui kelemahannya, membatasi ruang risiko, dan membangun jalur peningkatan.

Dari sisi pembelajaran organisasi, kualitas keputusan lebih penting daripada kecepatan peluncuran semata. Setiap eksperimen perlu menghasilkan pengetahuan tentang data, pengguna, proses, risiko, dan biaya. Pengetahuan itu harus dibagikan lintas unit melalui dokumentasi dan forum review, sehingga keberhasilan tidak bergantung pada ingatan satu tim. Ketika bukti baru muncul, asumsi lama harus dapat direvisi tanpa dianggap sebagai kegagalan kepemimpinan. Kemampuan mengubah arah secara tertib justru merupakan tanda kematangan dan strategic flexibility.

23. Indikator Kinerja dan Balanced Scorecard AI

Bagian ini berangkat dari tesis bahwa Keberhasilan AI tidak boleh diukur hanya dari jumlah model, pengguna, atau penghematan waktu. Indikator harus menangkap nilai, kualitas, adopsi, risiko, pembelajaran, pemerataan, dan keberlanjutan. Tesis tersebut menempatkan AI di dalam realitas organisasi, bukan di ruang laboratorium yang steril. Nilai tidak muncul dari prediksi saja, melainkan dari perubahan keputusan dan hasil. Karena perubahan keputusan selalu melibatkan kepentingan, kewenangan, dan kemungkinan kerugian, setiap pilihan teknis sekaligus merupakan pilihan sosial dan manajerial.

Ada beberapa dimensi yang harus dibaca secara bersamaan. Perspektif nilai mencakup outcome dan ROI; pengguna mencakup kepuasan dan akses; proses mencakup akurasi, latensi, uptime, dan override; risiko mencakup insiden, fairness, privasi, dan keamanan; kapabilitas mencakup kompetensi, reuse, dan waktu belajar. Masing-masing dapat diukur, tetapi angka tidak pernah berbicara tanpa konteks. Metrik harus disertai definisi, sumber, frekuensi, populasi, dan ambang tindakan. Dengan disiplin ini, organisasi dapat membedakan sinyal yang benar-benar penting dari indikator yang sekadar mudah dikumpulkan.

Pertimbangkan contoh berikut. Sistem ringkasan rapat mungkin menghemat waktu, tetapi KPI juga perlu mengukur kesalahan fakta, kebocoran informasi, koreksi pengguna, dan apakah keputusan menjadi lebih jelas. Produktivitas semu terjadi bila waktu hemat dipakai untuk memperbaiki kesalahan. Yang perlu dicermati bukan hanya keluaran algoritma, tetapi juga siapa yang membaca, tindakan apa yang menyusul, dan apakah hasil aktual dapat kembali menjadi pembelajaran. Tanpa loop umpan balik, organisasi tidak mengetahui apakah prediksi meningkatkan outcome atau sekadar mengubah beban kerja.

Sisi kegagalannya tidak boleh dipandang sebagai pengecualian teknis. Goodhart's law mengingatkan bahwa ketika metrik menjadi target, ia dapat berhenti menjadi ukuran yang baik. Tim dapat mengejar volume otomatisasi sambil memindahkan beban ke pengguna atau kelompok yang tidak terukur. Kegagalan merupakan informasi tentang kelemahan sistem. Organisasi yang menghukum pelaporan akan kehilangan kesempatan belajar, sedangkan organisasi yang mengubah insiden menjadi perbaikan akan membangun ketahanan. Prinsip ini menuntut budaya tanpa rasa takut sekaligus tanggung jawab yang jelas.

Dari sudut pandang implementasi, Dashboard AI harus memasang leading dan lagging indicators, agregat dan subkelompok, teknis dan sosial. Setiap indikator perlu pemilik, definisi, sumber data, frekuensi, ambang, dan tindakan jika menyimpang. Proses yang baik menyediakan jalur normal, jalur pengecualian, dan jalur penghentian. Ia juga menjaga pemisahan tugas antara pembangun, pemilik bisnis, validator, dan auditor agar konflik kepentingan dapat dikendalikan.

Relevansinya bagi pembangunan Indonesia terlihat jelas. Program publik perlu melaporkan dampak lintas wilayah, kelompok rentan, aksesibilitas, dan kualitas pelayanan. Penghematan anggaran harus dibandingkan dengan biaya koreksi, pengawasan, dan eksternalitas. Tantangan tersebut sekaligus peluang untuk membangun inovasi yang berangkat dari kebutuhan nyata. Keunggulan tidak selalu datang dari model terbesar; ia dapat datang dari data lokal yang bermutu, desain sederhana, biaya rendah, dan kepercayaan masyarakat.

Temuan penelitian yang relevan menyatakan bahwa NIST menekankan pengukuran risiko dan trustworthiness, sedangkan model cards memberi contoh pelaporan kinerja terpilah. Dalam manajemen, balanced measurement mencegah satu indikator menguasai tujuan organisasi. Pelajaran pentingnya ialah bahwa inovasi dan kehati-hatian dapat berjalan bersama. Pengujian yang kuat bukan penghambat, melainkan mekanisme yang memungkinkan skala tumbuh tanpa kehilangan kendali.

Inti manajerialnya adalah keselarasan. Strategi, data, model, infrastruktur, kompetensi, proses, dan akuntabilitas harus menunjuk pada outcome yang sama. Bila satu unit mengejar volume, unit lain mengejar akurasi, dan pengguna mengejar kecepatan, sistem dapat menghasilkan optimasi lokal yang merusak tujuan keseluruhan. Keselarasan memerlukan bahasa bersama dan forum keputusan yang mempertemukan ahli teknis, pemilik proses, pengguna, hukum, keamanan, dan pihak terdampak.

Perspektif pemangku kepentingan juga memperluas kualitas analisis. Pembangun melihat performa; pengguna melihat kemudahan; manajer melihat hasil; auditor melihat bukti; masyarakat melihat keadilan; dan pihak yang dirugikan melihat kemungkinan pemulihan. Tidak satu pun perspektif cukup sendirian. Proses partisipatif bukan berarti semua orang merancang algoritma, melainkan bahwa pengalaman dan kepentingan yang relevan masuk pada waktu ketika keputusan

masih dapat diubah. Partisipasi yang terlambat hanya menjadi legitimasi simbolik bagi desain yang telah terkunci.

24. Pilar Ketujuh - Ekosistem Inovasi dan Kedaulatan AI Indonesia

Indonesia tidak harus memilih antara memakai teknologi global dan membangun kemampuan sendiri. Strategi yang realistis memanfaatkan model global sambil memperkuat data, talenta, komputasi, riset, industri, standar, dan governance domestik. Jika prinsip ini diterima, maka evaluasi tidak boleh berhenti pada pertanyaan 'apakah sistem dapat melakukannya'. Pertanyaan yang lebih lengkap adalah apakah sistem patut melakukannya, dalam kondisi apa, untuk siapa, dengan biaya berapa, siapa yang mengawasi, dan apa yang terjadi ketika ia salah. Rangkaian pertanyaan tersebut membentuk jembatan antara ilmu komputer, manajemen, hukum, etika, dan kebijakan publik.

Struktur persoalannya mencakup lapisan-lapisan berikut. Agenda nasional mencakup infrastruktur komputasi bersama, corpus Bahasa Indonesia dan bahasa daerah, program talenta, insentif riset, dukungan startup, pengadaan publik, keamanan, diplomasi digital, dan regulasi berbasis risiko. Lapisan tersebut membentuk arsitektur keputusan. Perubahan kecil pada definisi target, hak akses, antarmuka, atau insentif pengguna dapat mengubah dampak meskipun model tidak berubah. Oleh sebab itu, dokumentasi teknis perlu dilengkapi dengan dokumentasi proses dan keputusan.

Narasi kasus dapat menggambarkan hubungan antarfaktor. Konsorsium universitas dapat membangun dataset dan benchmark terbuka untuk pertanian tropis, kesehatan primer, kebencanaan, dan administrasi. Pemerintah menyediakan tata kelola dan komputasi; industri mendukung implementasi; komunitas memastikan relevansi. Di sini terlihat bahwa solusi yang lebih sederhana dapat menjadi lebih unggul apabila selaras dengan kondisi penggunaan. Keunggulan praktis mencakup keterandalan, keterjangkauan, penerimaan, dan kemampuan diperbaiki, bukan hanya kecanggihan.

Perhatian khusus diperlukan pada pola kegagalan berikut. Kebijakan yang hanya mengejar simbol model nasional berisiko mengabaikan ekosistem. Sebaliknya, ketergantungan penuh pada impor membuat nilai tambah, data, dan kemampuan tawar keluar dari negeri. Risiko jarang berasal dari satu sebab; ia muncul dari kombinasi data, desain, tekanan bisnis, perilaku pengguna, dan kontrol yang lemah. Analisis akar masalah karena itu harus lintas fungsi dan menghindari godaan menyalahkan satu operator.

Agenda tindakan yang mengikuti analisis ini ialah Prioritas harus dipilih berdasarkan public value dan comparative advantage. Investasi besar perlu disertai target penggunaan, evaluasi independen, interoperabilitas, dan pembukaan manfaat bagi institusi kecil. Disiplin tersebut menghubungkan strategi dengan operasi. Ia mencegah proyek terseret oleh hype, tetapi juga mencegah birokrasi membunuh eksperimen. Kontrol dibuat proporsional: semakin besar dampak, semakin tinggi kebutuhan bukti dan pengawasan.

Pada tingkat kebijakan dan pelayanan, Pada Juli 2026, pemerintah menyatakan sedang memfinalisasi regulasi Peta Jalan Kecerdasan Artifisial Indonesia 2026-2029. Momentum ini perlu dipakai untuk menyatukan inovasi, hak warga, daya saing, keamanan, dan pemerataan dalam agenda yang dapat dilaksanakan. Pemerataan perlu menjadi indikator sejak awal, bukan tambahan setelah sistem selesai. Program yang berhasil di kota besar harus diuji ulang sebelum dipakai di daerah dengan bahasa, konektivitas, dan struktur layanan berbeda.

Rujukan akademik mendukung pembacaan ini. OECD AI Principles yang diperbarui pada 2024 menekankan inovasi terpercaya, hak asasi, keselamatan, privasi, integritas informasi, dan akuntabilitas. Prinsip ini dapat menjadi rujukan, tetapi harus diterjemahkan ke konteks kelembagaan Indonesia. Dalam praktik, temuan itu perlu diterjemahkan menjadi artefak: datasheet, model card, risk register, evaluation report, log, incident record, dan keputusan tertulis. Artefak membuat pengetahuan tidak hilang ketika orang atau vendor berganti.

Prinsip kehati-hatian yang produktif patut ditekankan. Kehati-hatian bukan menunggu kepastian sempurna, karena inovasi selalu mengandung ketidakpastian. Kehati-hatian berarti membuat ketidakpastian terlihat, mengendalikan skala eksperimen, mengukur konsekuensi, dan menjaga reversibilitas. Ketika dampak rendah, eksperimen dapat cepat; ketika menyangkut keselamatan, hak, atau penghidupan, standar bukti dan pengawasan harus lebih tinggi.

Akhirnya, prinsip proporsionalitas perlu dijaga. Tidak setiap penggunaan AI membutuhkan birokrasi yang sama. Alat untuk menyusun ide internal dapat diberi kontrol ringan, sedangkan sistem yang memengaruhi kesehatan, pendidikan, pekerjaan, kredit, atau hak warga membutuhkan standar lebih tinggi. Diferensiasi ini memungkinkan inovasi tetap bergerak sambil memusatkan sumber daya pengawasan pada tempat yang paling berbahaya. Dengan demikian, governance tidak menjadi rem yang selalu ditekan, melainkan sistem kemudi yang menentukan arah, kecepatan, dan batas aman.

25. Masa Depan: AI Agentik, Multimodal, dan Ilmu Pengetahuan

Pokok persoalan dalam bagian ini adalah Arah AI bergerak dari model yang menjawab menuju sistem yang mengamati, merencanakan, memakai alat, berkomunikasi dengan agen lain, dan mengambil tindakan. Multimodalitas menghubungkan teks, gambar, suara, video, sensor, dan robotika. Perspektif tersebut menggeser pembicaraan dari pertanyaan sempit mengenai kemampuan perangkat menjadi pertanyaan manajerial mengenai kesesuaian, keterhubungan, dan konsekuensi. Dalam sistem AI, sebuah komponen tidak pernah benar-benar berdiri sendiri. Ia menerima masukan dari komponen lain, mengubah perilaku organisasi, lalu menghasilkan umpan balik yang dapat memperkuat manfaat maupun memperbesar risiko. Karena itu, analisis perlu memperhatikan proses sebelum model dijalankan, keputusan ketika keluaran digunakan, dan dampak setelah keputusan terjadi.

Secara analitis, ruang lingkupnya dapat diuraikan sebagai berikut. Kemampuan baru dapat mempercepat riset, desain, diagnosis, simulasi, dan layanan. Namun autonomy meningkatkan horizon kesalahan, efek berantai, dan kesulitan atribusi. Evaluasi perlu beralih dari jawaban tunggal menuju perilaku sepanjang waktu. Unsur-unsur tersebut tidak sebaiknya diperlakukan sebagai daftar pemeriksaan yang mekanis. Hubungan di antaranya perlu dicari: peningkatan pada satu dimensi mungkin memperburuk dimensi lain, dan penghematan pada tahap awal dapat menimbulkan biaya koreksi yang lebih besar kemudian. Pendekatan yang matang selalu menyatakan trade-off, asumsi, serta batas penerapan.

Sebuah ilustrasi membantu memperjelasnya. Agen penelitian dapat mencari literatur, menulis kode, menjalankan eksperimen, dan merangkum hasil. Ilmuwan tetap harus memeriksa asumsi, validitas metode, provenance, replikasi, dan apakah agen mengoptimalkan metrik yang salah. Kasus ini menunjukkan bahwa nilai AI bersifat kontekstual. Model yang sama dapat berhasil di satu tempat dan gagal di tempat lain karena perbedaan populasi, alur kerja, tujuan, atau kapasitas. Pilot karena itu bukan sekadar uji perangkat, melainkan uji hipotesis tentang sistem kerja baru.

Risiko utama muncul ketika asumsi tidak terlihat. Illusion of understanding muncul ketika keluaran yang koheren membuat pengguna merasa telah memahami fenomena. Ketergantungan pada alat serupa juga dapat menyempitkan keragaman pertanyaan dan menciptakan monokultur ilmiah. Masalah ini sering membesar secara perlahan karena keluaran yang salah tidak selalu langsung menimbulkan keluhan. Kelompok yang dirugikan mungkin tidak mengetahui bahwa AI terlibat, tidak memiliki kanal keberatan, atau tidak mempunyai data pembandingan. Karena itu, ketiadaan insiden yang dilaporkan bukan bukti ketiadaan kerugian.

Implikasi manajerialnya adalah Governance agen harus membatasi tujuan, alat, anggaran, data, waktu, dan ruang tindakan; mewajibkan konfirmasi untuk tindakan penting; serta menyediakan sandbox, log, dan kill switch. Evaluasi harus memperhatikan emergent behavior. Keputusan tersebut perlu diterjemahkan ke dalam pemilik, jadwal, anggaran, bukti, dan ambang. Tanpa kelima unsur itu, rekomendasi berubah menjadi aspirasi. Dewan atau pimpinan juga perlu menerima laporan tentang asumsi dan ketidakpastian, bukan hanya keberhasilan proyek.

Konteks nasional dan lokal menambah lapisan penting. Indonesia dapat memanfaatkan AI untuk sains biodiversitas, kelautan, kehutanan, iklim tropis, dan kebencanaan. Keunggulan muncul bila data lokal, keahlian ilmiah, dan komputasi disatukan dalam kolaborasi terbuka yang etis. Kebijakan harus mempertimbangkan bahwa kapasitas tidak merata. Standar nasional perlu menjaga hak dan interoperabilitas, sedangkan implementasi memberi ruang adaptasi sektoral serta lokal. Pendekatan berlapis ini lebih realistis daripada satu solusi untuk semua.

Landasan ilmiah memperkuat argumen tersebut. Rahwan et al. (2019) meminta ilmu perilaku mesin lintas disiplin. Krenn et al. (2022) membahas AI sebagai mitra penemuan ilmiah, sekaligus

pentingnya membedakan prediksi yang berguna dari pemahaman ilmiah yang dapat dijelaskan. Literatur ini tidak memberi resep tunggal, tetapi memberi cara berpikir: dokumentasikan asumsi, ukur pada konteks penggunaan, libatkan pihak terdampak, dan pertahankan kemampuan koreksi. Dengan demikian, bukti ilmiah menjadi sarana pembelajaran organisasi.

Jika bagian ini dihubungkan kembali dengan kerangka tujuh pilar, terlihat pola sistemik. Mutu satu faktor menentukan beban faktor lain. Data yang lemah memaksa model bekerja lebih keras; model yang rumit menuntut komputasi dan keahlian lebih besar; antarmuka yang buruk meningkatkan risiko manusia; governance yang terlambat memperbesar biaya perubahan. Sebaliknya, dokumentasi, modularitas, dan pembelajaran lintas fungsi menciptakan efek pengungkit. Organisasi tidak harus sempurna sebelum memulai, tetapi harus mengetahui kelemahannya, membatasi ruang risiko, dan membangun jalur peningkatan.

Bagi pengambil keputusan, bagian ini dapat dijadikan bahan refleksi sebelum menyetujui investasi. Apakah manfaat yang dijanjikan mempunyai baseline dan indikator outcome? Apakah ketidakpastian disampaikan secara jujur? Apakah pengguna memiliki waktu dan kewenangan untuk memeriksa? Apakah kelompok terdampak dapat mengoreksi data dan keputusan? Apakah organisasi sanggup memelihara sistem setelah pilot berakhir? Pertanyaan-pertanyaan ini mengubah diskusi dari antusiasme teknologi menjadi tanggung jawab institusional. Jawaban tidak harus selalu sempurna, tetapi harus dibuktikan dan ditinjau ulang.

26. Kesimpulan: AI yang Bernilai, Andal, dan Bertanggung Jawab

Tujuh pilar utama AI menunjukkan bahwa keberhasilan bukan milik model semata. Data menentukan apa yang dapat dipelajari; algoritma menentukan bagaimana pola dibentuk; komputasi menentukan kemungkinan operasional; manusia menentukan tujuan dan makna; governance menentukan batas dan legitimasi. Pernyataan ini penting karena banyak proyek AI dinilai terlalu awal dari penampilan demonstrasi. Keberhasilan sebenarnya baru dapat diketahui ketika sistem menghadapi variasi pengguna, data yang tidak sempurna, tekanan waktu, gangguan infrastruktur, dan tuntutan pertanggungjawaban. Dengan kata lain, kecerdasan teknis harus diterjemahkan menjadi kemampuan institusional. Terjemahan itu membutuhkan desain tujuan, proses, insentif, dan pengawasan yang konsisten.

Ada beberapa dimensi yang harus dibaca secara bersamaan. Ketujuh pilar harus kuat secara seimbang. Kelemahan data tidak dapat diselesaikan hanya dengan model besar. Kelemahan kompetensi tidak dapat diselesaikan dengan antarmuka sederhana. Ketiadaan akuntabilitas tidak dapat diselesaikan dengan disclaimer. Masing-masing dapat diukur, tetapi angka tidak pernah berbicara tanpa konteks. Metrik harus disertai definisi, sumber, frekuensi, populasi, dan ambang tindakan. Dengan disiplin ini, organisasi dapat membedakan sinyal yang benar-benar penting dari indikator yang sekadar mudah dikumpulkan.

Pertimbangkan contoh berikut. Organisasi yang berhasil akan memperlakukan AI sebagai disiplin manajemen: memilih masalah bernilai, membangun bukti, mengelola risiko, melibatkan pengguna, belajar dari insiden, dan menghentikan sistem yang tidak layak. Yang perlu dicermati bukan hanya keluaran algoritma, tetapi juga siapa yang membaca, tindakan apa yang menyusul, dan apakah hasil aktual dapat kembali menjadi pembelajaran. Tanpa loop umpan balik, organisasi tidak mengetahui apakah prediksi meningkatkan outcome atau sekadar mengubah beban kerja.

Sisi kegagalannya tidak boleh dipandang sebagai pengecualian teknis. Kegagalan terbesar bukan hanya keluaran salah, melainkan institusi yang tidak mampu mengenali, mengoreksi, dan mempertanggungjawabkannya. Kecepatan tanpa pembelajaran akan memperbesar skala kesalahan. Kegagalan merupakan informasi tentang kelemahan sistem. Organisasi yang menghukum pelaporan akan kehilangan kesempatan belajar, sedangkan organisasi yang mengubah insiden menjadi perbaikan akan membangun ketahanan. Prinsip ini menuntut budaya tanpa rasa takut sekaligus tanggung jawab yang jelas.

Dari sudut pandang implementasi, Pertanyaan penutup bagi pimpinan ialah: apakah kita memiliki data yang sah dan representatif; model yang sesuai dan teruji; infrastruktur yang efisien dan resilien; manusia yang kompeten dan berdaya; serta governance yang nyata? Proses yang baik menyediakan jalur normal, jalur pengecualian, dan jalur penghentian. Ia juga menjaga pemisahan

tugas antara pembangun, pemilik bisnis, validator, dan auditor agar konflik kepentingan dapat dikendalikan.

Relevansinya bagi pembangunan Indonesia terlihat jelas. Indonesia mempunyai kesempatan membentuk jalur AI yang inklusif, kontekstual, dan berdaulat. Jalur itu memerlukan investasi jangka panjang pada pendidikan, riset, data publik, infrastruktur, industri, serta institusi yang menjaga hak dan kepercayaan. Tantangan tersebut sekaligus peluang untuk membangun inovasi yang berangkat dari kebutuhan nyata. Keunggulan tidak selalu datang dari model terbesar; ia dapat datang dari data lokal yang bermutu, desain sederhana, biaya rendah, dan kepercayaan masyarakat.

Temuan penelitian yang relevan menyatakan bahwa Pesan berbagai kerangka mutakhir konsisten: inovasi dan tanggung jawab bukan lawan. AI yang tepercaya justru menciptakan dasar bagi adopsi berkelanjutan, pembelajaran organisasi, dan manfaat sosial yang lebih luas. Pelajaran pentingnya ialah bahwa inovasi dan kehati-hatian dapat berjalan bersama. Pengujian yang kuat bukan penghambat, melainkan mekanisme yang memungkinkan skala tumbuh tanpa kehilangan kendali.

Inti manajerialnya adalah keselarasan. Strategi, data, model, infrastruktur, kompetensi, proses, dan akuntabilitas harus menunjuk pada outcome yang sama. Bila satu unit mengejar volume, unit lain mengejar akurasi, dan pengguna mengejar kecepatan, sistem dapat menghasilkan optimasi lokal yang merusak tujuan keseluruhan. Keselarasan memerlukan bahasa bersama dan forum keputusan yang mempertemukan ahli teknis, pemilik proses, pengguna, hukum, keamanan, dan pihak terdampak.

Dari sisi pembelajaran organisasi, kualitas keputusan lebih penting daripada kecepatan peluncuran semata. Setiap eksperimen perlu menghasilkan pengetahuan tentang data, pengguna, proses, risiko, dan biaya. Pengetahuan itu harus dibagikan lintas unit melalui dokumentasi dan forum review, sehingga keberhasilan tidak bergantung pada ingatan satu tim. Ketika bukti baru muncul, asumsi lama harus dapat direvisi tanpa dianggap sebagai kegagalan kepemimpinan. Kemampuan mengubah arah secara tertib justru merupakan tanda kematangan dan strategic flexibility.

Glossarium

Istilah berikut digunakan dalam artikel untuk menjaga konsistensi pengertian. Definisi disederhanakan agar mudah digunakan dalam konteks manajemen, kebijakan, pendidikan, dan implementasi organisasi.

Istilah	Pengertian
AI agentik	Sistem AI yang dapat merencanakan, memakai alat, dan mengambil rangkaian tindakan untuk mencapai tujuan.
Akurasi	Proporsi prediksi yang benar; tidak selalu cukup untuk data tidak seimbang atau keputusan berisiko.
Algoritma	Prosedur komputasional untuk mengolah data, belajar, atau menghasilkan keputusan.
Algorithm aversion	Kecenderungan manusia menolak algoritma setelah melihat kesalahan, meskipun secara keseluruhan algoritma dapat berguna.
Automation bias	Kecenderungan terlalu menerima rekomendasi otomatis dan mengurangi pemeriksaan mandiri.
Benchmark	Dataset dan prosedur standar untuk membandingkan performa model.
Bias	Penyimpangan sistematis pada data, model, proses, atau outcome yang dapat menghasilkan ketidakadilan.
Calibration	Kesesuaian antara tingkat keyakinan model dan frekuensi kebenaran aktual.
Cloud computing	Penyediaan komputasi, penyimpanan, dan layanan melalui infrastruktur jarak jauh.
Data drift	Perubahan distribusi data masukan dibandingkan data ketika model dikembangkan.
Data lineage	Catatan asal, transformasi, perpindahan, dan penggunaan data.
Datasheet for datasets	Dokumentasi terstruktur mengenai motivasi, komposisi, proses, penggunaan, dan keterbatasan dataset.
Deep learning	Pembelajaran mesin berbasis jaringan saraf berlapis yang mempelajari representasi kompleks.
Distillation	Teknik mentransfer kemampuan model besar ke model yang lebih kecil.
Edge computing	Pemrosesan dekat sumber data atau perangkat pengguna untuk menurunkan latensi dan ketergantungan jaringan.
Embedding	Representasi numerik berdimensi banyak untuk teks, gambar, atau objek lain.
Explainability	Kemampuan menyediakan penjelasan yang relevan mengenai perilaku atau keluaran model.
Fairness	Keadilan dalam proses dan outcome AI; definisinya bergantung pada konteks dan dapat melibatkan trade-off.
Foundation model	Model skala besar yang dilatih luas dan dapat diadaptasi untuk banyak tugas.

Istilah	Pengertian
Generative AI	AI yang menghasilkan konten baru seperti teks, gambar, suara, video, atau kode.
Governance AI	Struktur peran, keputusan, proses, kontrol, dan akuntabilitas untuk mengelola AI.
Green AI	Pendekatan yang menilai efisiensi energi, biaya, dan dampak lingkungan bersama performa.
Guardrail	Pembatas teknis atau prosedural untuk mencegah perilaku AI yang tidak diinginkan.
Halusinasi	Keluaran generatif yang fasih tetapi tidak didukung fakta atau sumber yang benar.
Human-in-the-loop	Desain yang menempatkan intervensi manusia bermakna pada titik tertentu dalam proses AI.
Inference	Proses menggunakan model terlatih untuk menghasilkan prediksi atau keluaran.
Latensi	Waktu yang dibutuhkan sistem untuk merespons permintaan.
Machine learning	Metode yang memungkinkan sistem mempelajari pola dari data untuk tugas tertentu.
MLOps	Praktik untuk mengembangkan, menerapkan, memantau, dan memelihara model secara terkelola.
Model card	Dokumentasi penggunaan, performa, batas, pertimbangan etika, dan hasil evaluasi model.
Model drift	Penurunan relevansi atau kinerja model akibat perubahan hubungan antara data dan outcome.
Multimodal	Kemampuan AI memproses atau menghasilkan beberapa jenis data seperti teks, gambar, dan suara.
Observability	Kemampuan memahami kondisi internal sistem melalui log, metrik, trace, dan bukti lain.
Precision	Proporsi prediksi positif yang benar.
Prompt injection	Serangan yang menyisipkan instruksi agar model mengabaikan tujuan atau aturan yang semestinya.
Quantization	Pengurangan presisi numerik model untuk menurunkan kebutuhan memori dan komputasi.
Recall	Proporsi kasus positif aktual yang berhasil ditemukan model.
Red teaming	Pengujian adversarial terstruktur untuk menemukan kegagalan, kerentanan, dan penyalahgunaan.
Retrieval-augmented generation	Pendekatan yang memberi model generatif dokumen terpilih saat menjawab.
Robustness	Kemampuan sistem mempertahankan kinerja ketika input, kondisi, atau gangguan berubah.
Shadow AI	Penggunaan alat AI tanpa persetujuan atau visibilitas organisasi.
Sistem sosioteknis	Sistem yang hasilnya dibentuk oleh interaksi teknologi, manusia, proses, dan institusi.

Istilah	Pengertian
Training	Proses mengoptimalkan parameter model berdasarkan data dan tujuan tertentu.
Transparency	Keterbukaan yang relevan mengenai tujuan, data, model, proses, keterbatasan, dan tanggung jawab.
Vendor lock-in	Ketergantungan yang membuat perpindahan dari pemasok menjadi sulit atau mahal.

Daftar Pustaka

Daftar pustaka disusun menurut gaya APA edisi ke-7. DOI dicantumkan dalam format URL <https://doi.org/...> apabila tersedia.

- Acemoglu, D., & Restrepo, P. (2018). The race between man and machine: Implications of technology for growth, factor shares, and employment. *American Economic Review*, 108(6), 1488-1542. <https://doi.org/10.1257/aer.20160696>
- Amershi, S., Weld, D., Vorvoreanu, M., Fourney, A., Nushi, B., Collisson, P., Suh, J., Iqbal, S., Bennett, P. N., Inkpen, K., Teevan, J., Kikin-Gil, R., & Horvitz, E. (2019). Guidelines for human-AI interaction. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems* (pp. 1-13). ACM. <https://doi.org/10.1145/3290605.3300233>
- Bainbridge, L. (1983). Ironies of automation. *Automatica*, 19(6), 775-779. [https://doi.org/10.1016/0005-1098\(83\)90046-8](https://doi.org/10.1016/0005-1098(83)90046-8)
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency* (pp. 610-623). ACM. <https://doi.org/10.1145/3442188.3445922>
- Brynjolfsson, E., & Mitchell, T. (2017). What can machine learning do? Workforce implications. *Science*, 358(6370), 1530-1534. <https://doi.org/10.1126/science.aap8062>
- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, P. V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. D. (2021). Artificial intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57, 101994. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>
- Dwork, C., Hardt, M., Pitassi, T., Reingold, O., & Zemel, R. (2012). Fairness through awareness. In *Proceedings of the 3rd Innovations in Theoretical Computer Science Conference* (pp. 214-226). ACM. <https://doi.org/10.1145/2090236.2090255>
- Floridi, L., & Cowls, J. (2019). A unified framework of five principles for AI in society. *Harvard Data Science Review*, 1(1). <https://doi.org/10.1162/99608f92.8cd550d1>
- Floridi, L., Cowls, J., Beltrametti, M., Chatila, R., Chazerand, P., Dignum, V., Luetge, C., Madelin, R., Pagallo, U., Rossi, F., Schafer, B., Valcke, P., & Vayena, E. (2018). AI4People—An ethical framework for a good AI society. *Minds and Machines*, 28, 689-707. <https://doi.org/10.1007/s11023-018-9482-5>
- Floridi, L., & Taddeo, M. (2016). What is data ethics? *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2083), 20160360. <https://doi.org/10.1098/rsta.2016.0360>
- Gebru, T., Morgenstern, J., Vecchione, B., Vaughan, J. W., Wallach, H., Daumé III, H., & Crawford, K. (2021). Datasheets for datasets. *Communications of the ACM*, 64(12), 86-92. <https://doi.org/10.1145/3458723>
- Hardt, M., Price, E., & Srebro, N. (2016). Equality of opportunity in supervised learning. *Advances in Neural Information Processing Systems*, 29. <https://doi.org/10.48550/arXiv.1610.02413>
- Hoffmann, J., Borgeaud, S., Mensch, A., Buchatskaya, E., Cai, T., Rutherford, E., de Las Casas, D., Hendricks, L. A., Welbl, J., Clark, A., Hennigan, T., Noland, E., Millican, K., van den Driessche, G., Damoc, B., Guy, A., Osindero, S., Simonyan, K., Elsen, E., ... Sifre, L. (2022). Training compute-optimal large language models. *arXiv*. <https://doi.org/10.48550/arXiv.2203.15556>
- Jöhnk, J., Weißert, M., & Wyrski, K. (2021). Ready or not, AI comes—An interview study of organizational AI readiness factors. *Business & Information Systems Engineering*, 63, 5-20. <https://doi.org/10.1007/s12599-020-00676-7>

- Kaplan, J., McCandlish, S., Henighan, T., Brown, T. B., Chess, B., Child, R., Gray, S., Radford, A., Wu, J., & Amodei, D. (2020). Scaling laws for neural language models. arXiv. <https://doi.org/10.48550/arXiv.2001.08361>
- Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2019). Key challenges for delivering clinical impact with artificial intelligence. BMC Medicine, 17, Article 195. <https://doi.org/10.1186/s12916-019-1426-2>
- Kementerian Komunikasi dan Digital Republik Indonesia. (2026, July 18). Peran aktif Indonesia membangun fondasi WAICO pada informal preparatory session. <https://www.komdigi.go.id/>
- Kementerian Komunikasi dan Informatika Republik Indonesia. (2023). Surat Edaran Menteri Komunikasi dan Informatika Nomor 9 Tahun 2023 tentang Etika Kecerdasan Artifisial. https://jdih.komdigi.go.id/produk_hukum/view/id/883
- Krenn, M., Pollice, R., Guo, S. Y., Aldeghi, M., Cervera-Lierta, A., Friederich, P., dos Passos Gomes, G., Häse, F., Jinich, A., Nigam, A., Yao, Z., & Aspuru-Guzik, A. (2022). On scientific understanding with artificial intelligence. Nature Reviews Physics, 4, 761-769. <https://doi.org/10.1038/s42254-022-00518-3>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521, 436-444. <https://doi.org/10.1038/nature14539>
- Mikalef, P., & Gupta, M. (2021). Artificial intelligence capability: Conceptualization, measurement calibration, and empirical study on its impact on organizational creativity and firm performance. Information & Management, 58(3), 103434. <https://doi.org/10.1016/j.im.2021.103434>
- Mitchell, M., Wu, S., Zaldivar, A., Barnes, P., Vasserman, L., Hutchinson, B., Spitzer, E., Raji, I. D., & Gebru, T. (2019). Model cards for model reporting. In Proceedings of the Conference on Fairness, Accountability, and Transparency (pp. 220-229). ACM. <https://doi.org/10.1145/3287560.3287596>
- National Institute of Standards and Technology. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST AI 100-1). U.S. Department of Commerce. <https://doi.org/10.6028/NIST.AI.100-1>
- Noy, S., & Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. Science, 381(6654), 187-192. <https://doi.org/10.1126/science.adh2586>
- OECD. (2024). OECD AI principles: Updated 2024. OECD.AI. <https://oecd.ai/en/ai-principles>
- Rahwan, I., Cebrian, M., Obradovich, N., Bongard, J., Bonnefon, J.-F., Breazeal, C., Crandall, J. W., Christakis, N. A., Couzin, I. D., Jackson, M. O., Jennings, N. R., Kamar, E., Kloumann, I. M., Larochelle, H., Lazer, D., McElreath, R., Mislove, A., Parkes, D. C., Pentland, A., ... Wellman, M. (2019). Machine behaviour. Nature, 568, 477-486. <https://doi.org/10.1038/s41586-019-1138-y>
- Raji, I. D., Smart, A., White, R. N., Mitchell, M., Gebru, T., Hutchinson, B., Smith-Loud, J., Theron, D., & Barnes, P. (2020). Closing the AI accountability gap: Defining an end-to-end framework for internal algorithmic auditing. In Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency (pp. 33-44). ACM. <https://doi.org/10.1145/3351095.3372873>
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). Why should I trust you? Explaining the predictions of any classifier. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 1135-1144). ACM. <https://doi.org/10.1145/2939672.2939778>
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. Nature Machine Intelligence, 1, 206-215. <https://doi.org/10.1038/s42256-019-0048-x>
- Schwartz, R., Dodge, J., Smith, N. A., & Etzioni, O. (2020). Green AI. Communications of the ACM, 63(12), 54-63. <https://doi.org/10.1145/3381831>
- Shneiderman, B. (2020). Human-centered artificial intelligence: Reliable, safe & trustworthy. International Journal of Human-Computer Interaction, 36(6), 495-504. <https://doi.org/10.1080/10447318.2020.1741118>
- Stanford Institute for Human-Centered Artificial Intelligence. (2026). AI Index Report 2026. Stanford University. <https://hai.stanford.edu/ai-index/2026-ai-index-report>

- Strubell, E., Ganesh, A., & McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. In Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics (pp. 3645-3650). Association for Computational Linguistics. <https://doi.org/10.18653/v1/P19-1355>
- Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25, 44-56. <https://doi.org/10.1038/s41591-018-0300-7>
- Vial, G. (2019). Understanding digital transformation: A review and a research agenda. *The Journal of Strategic Information Systems*, 28(2), 118-144. <https://doi.org/10.1016/j.jsis.2019.01.003>