

AI-Previz i Green-Cloud: analiza pojęć, technologii, dostawców i integracji

Streszczenie zarządcze

AI-Previz w najczęściej spotykanym (branżowym) znaczeniu oznacza użycie narzędzi sztucznej inteligencji do przewizualizacji – czyli tworzenia wczesnych, iteracyjnych reprezentacji scen, ujęć, ruchu kamery, blokingu, stylistyki i/lub elementów VFX jeszcze przed produkcją zdjęciową lub finalną animacją. W praktyce AI-Previz bywa „warstwą przyspieszającą” klasyczny pipeline virtual production: AI wspiera storyboard/animatiki, generuje warianty stylu, automatyzuje część pracy (np. tracking/clean plates/maski/animacja postaci), a następnie wyniki są eksportowane do narzędzi DCC i silników czasu rzeczywistego. Przykłady komercyjne wskazują na rosnącą koncentrację na „kontrolowanym AI” (controllable AI), spójności postaci/stylu oraz interoperacyjności (USD/Unreal/Maya itd.).

Green-Cloud jest terminem wieloznacznym: (a) jako „zielona chmura” w sensie polityk i praktyk ograniczających wpływ chmury i data center na środowisko (energia, woda, odpady, OZE, ciepło odpadowe), (b) jako marketingowa nazwa „ekologicznego” cloud providera lub oferty (np. Oracle używa określenia „green cloud” dla OCI), (c) jako nazwa konkretnych narzędzi badawczych (np. GreenCloud – symulator energoświadomych centrów danych), (d) jako nazwa firm niekoniecznie powiązanych z ESG (np. „GreenCloud VPS”). W ujęciu europejskim „zielona chmura” jest powiązana z celem zwiększania efektywności energetycznej i obiegu zamkniętego w centrach danych; Komisja Europejska wskazuje też na problem braku powszechnie przyjętych definicji i metod oceny efektywności/neutralności klimatycznej centrów danych.

Najbardziej praktyczny punkt wspólny AI-Previz i Green-Cloud to fakt, że AI-Previz – zwłaszcza generatywne wideo/3D oraz skalowalne renderowanie – jest obciążeniem obliczeniowym, które może być przenoszone do chmury i optymalizowane pod kątem emisyjności oraz zużycia energii/wody poprzez wybór regionu, okna czasowego i architektury (np. batch vs interaktywnie). Badania wskazują, że lokalizacja (miks energetyczny regionu) oraz infrastruktura data center mogą powodować wielokrotne (5–10×) różnice w śladzie węglowym, a dobór DC/procesora/architektury modelu może redukować emisje nawet o rzędy wielkości.

Najważniejsze rekomendacje wysokiego poziomu:

1. Traktować AI-Previz jako zestaw workflow, a nie pojedynczy produkt: oddzielić warstwę kreatywną (scenariusz, storyboard, animatiki) od warstwy obliczeniowej (generacja/iteracje/render) i od warstwy integracji (USD/Unreal/DCC).
2. W Green-Cloud oprzeć się na mierzalnych metrykach i standardach: PUE jako metryka infrastruktury (z jasnymi ograniczeniami), carbon intensity (gCO₂e/kWh) jako metryka energii, oraz wskaźniki w stylu SCl do porównywania usług software'owych „na jednostkę funkcjonalną”.

3. Dla integracji AI-Previz × Green-Cloud wdrożyć „carbon-aware orchestration”: planowanie regionu/czasu dla zadań batch oraz śledzenie emisji per projekt/iteracja. Technicznie ułatwiają to m.in. Carbon Aware SDK i narzędzia dostawców (AWS Customer Carbon Footprint Tool, Google Cloud Carbon Footprint).

Definicje i zakres pojęć

AI-Previz jako praktyka i jako klasa narzędzi

Previsualization (previz) w klasycznym ujęciu to etap wizualnego planowania, który pojawia się przed (lub równolegle do) zdjęć/animacji i pomaga w decyzjach dot. ujęć, ruchu kamery, blokingu, scenografii, efektów oraz komunikacji między działami. W ujęciu virtual production „wizualizacja” obejmuje różne podtypy (m.in. previs), w zależności od celu i miejsca w procesie.

AI-Previz (najbardziej użyteczna robocza definicja do wdrożeń) to:

zestaw workflow i narzędzi, w których AI automatyzuje lub przyspiesza tworzenie materiałów przewizualizacyjnych (2D/3D/video) oraz iteracje kreatywne, przy zachowaniu kontroli nad kamerą, ruchem, spójnością stylu/postaci i eksportem do docelowego pipeline.

Dowody na formowanie się tej klasy narzędzi widać zarówno w produktach komercyjnych (np. generowanie storyboardów i sekwencji z zachowaniem spójności – Adobe Firefly Boards), jak i w pracach badawczych nacełowanych na kontrolę kamery w generowanym wideo (CinePreGen) czy automatyczne generowanie storyboardu i 3D podglądu z analizy scenariusza (ASAP).

Green-Cloud jako cel, oferta rynkowa i narzędzie badawcze

Green-Cloud (zielona chmura) w sensie polityk publicznych i praktyk branżowych oznacza redukcję wpływu środowiskowego chmury i centrów danych poprzez: wyższą efektywność energetyczną, większy udział energii odnawialnej, ponowne wykorzystanie energii odpadowej (np. ciepła) oraz podejście gospodarki o obiegu zamkniętym. Komisja Europejska wskazuje, że cyfryzacja może zwiększać zużycie energii (szacunki 5–9% globalnego zużycia energii elektrycznej przypisywane technologiom cyfrowym) i że centra danych powinny dążyć do neutralności klimatycznej do 2030 r.

Green-Cloud jako „oferta dostawcy”: termin bywa używany marketingowo. Przykładowo Oracle opisuje OCI jako „green cloud solution” z naciskiem na zasilanie OZE oraz narzędzia do pomiaru/planowania.

GreenCloud (bez myślnika) jako narzędzie badawcze: istnieje również GreenCloud – symulator pakietowy do badań energoświadomych centrów danych i komunikacji, z modelowaniem zużycia energii serwerów, przełączników i łączy, użyteczny do badań alokacji zasobów, schedulingu i optymalizacji.

Ryzyko niejednoznaczności: „GreenCloud” może też być nazwą firm usługowych (np. VPS), które nie muszą mieć mierzalnych praktyk „green”.

Założenie raportu (dalej): dalsza analiza traktuje „Green-Cloud” przede wszystkim jako zestaw *praktyk, metryk i funkcji chmurowych umożliwiających redukcję śladu środowiskowego obciążeń obliczeniowych*, a dopiero wtórnie jako nazwy własne ofert i narzędzi.

Źródła oficjalne, dostawcy i standardy

Dostawcy i narzędzia AI-Previz

Poniższa tabela obejmuje dostawców, dla których dostępne są relatywnie „oficjalne” opisy funkcji (strony producentów, dokumentacja) lub wiarygodne publikacje naukowe.

Dostawca / rozwiązanie	Zakres AI-Previz	Model wdrożenia	Kluczowe elementy techniczne (skrót)	Integracje / eksport
Autodesk Flow Studio (dawniej Wonder Studio)	Automatyzacja elementów VFX i „kontrolowalne” generowanie/edycja CG na bazie ujęć	Cloud/SaaS	„Cloud-based, AI-powered 3D toolset”; edytowalne outputy (m.in. tracking kamery, clean plates, maski); automatyzacja animacji/światła/kompozycji postaci CG w scenie live-action	Integracje z Maya/Blender/Unreal i pipeline opartym o USD; możliwość skalowania renderingu w chmurze
Adobe Firefly Boards (AI storyboard generator)	Storyboard/animatiki/planowanie ujęć z naciskiem na spójność i współpracę	Cloud/SaaS	Generowanie storyboardów z tekstu/skryptu; spójność wyglądu (światło, styl postaci, tło) w sekwencjach; eksport do formatów graficznych/wideo	Integracje ekosystemowe Adobe; eksport paneli/sekwencji
Runway (Gen-3 rodzina modeli)	Szybka generacja wideo do iteracji koncepcji i stylu; potencjalnie elementy „industry customization”	Cloud	Model generacji wideo; współpraca z organizacjami medialnymi nad wersjami „custom”; nacisk na kontrolę stylu i spójność postaci w kontekście customizacji	API/dalsza integracja zależna od implementacji; jako źródło klipów do storyboardu/animatiku
Midjourney	Szybka generacja obrazów (concept frames, moodboardy) oraz krótkie wideo z obrazów	Cloud	Parametry w promptach do kontroli wyniku; dokumentacja opisuje m.in. parametry i funkcje pracy na obrazach/odniesieniach	Eksport assetów; integracja głównie workflow’owa (przenoszenie assetów do narzędzi DCC)

ASAP (system badawczy)	Automatyzacja storyboardu i previz z analizy scenariusza	Prototyp badawczy	Parsing scenariusza (postaci, dialog, akcje, emocje) → generacja storyboardu 2D, preview 3D i scenariusza VR; generacja gestów/ruchów/ekspresji wirtualnych postaci	Opis badawczy (brak komercyjnej dystrybucji w artykule)
CinePreG en (system badawczy)	Kontrolowalne planowanie kamery w generowanym wideo „pody previz”	Prototyp badawczy	Połączenie silnika (game engine) dyfuzji; kontrola ruchów kamery (pan/tilt/push/dolly itd.); użycie danych „ground truth” z silnika (np. depth/motion) do lepszej kontroli generacji	Koncepcja integracji engine ↔ model generatywny; wprost pod previz
„ai-previz” jako nazwa usługi studyjnej	Możliwa interpretacja terminu jako nazwy oferty usługowej	Usługa	Opis jako AI-powered storyboardy, spójność postaci/lokacji (deklaracja marketingowa)	Zależne od dostawcy usługi

Dostawcy i inicjatywy Green-Cloud

W tej tabeli zestawiono: (1) wskaźniki efektywności infrastruktury (PUE), (2) narzędzia do raportowania emisji klienta, (3) elementy „carbon-aware” oraz (4) deklaracje dot. energii odnawialnej / CFE (jeśli dostępne w źródłach).

Dostawca / inicjatywa	Metryki i efektywność	Narzędzia/produkty „green” dla klientów	Energia odnawialna / CFE (przykłady)	Uwagi dot. porównywalności
Google (Data Centers + Google Cloud)	Średni roczny PUE floty data center: 1.09 (2024)	Google Cloud Carbon Footprint (emisje location-based i market-based); integracje przez API/docs	100% rocznego zużycia energii elektrycznej dopasowane do OZE globalnie (od 2017); globalnie 64% CFE (2024)	PUE nie obejmuje efektywności IT/workload; CFE ≠ „100% w każdej godzinie”
AWS	Globalny PUE: 1.15 (2024)	AWS Customer Carbon Footprint Tool (wgląd w emisje m.in. z/bez zakupów CFE); metodologia jako PDF	Amazon/AWS deklaruje dopasowanie 100% zużytej energii elektrycznej do OZE (osiągnięte w 2023)	Dane o redukcjach „po migracji” często pochodzą z badań sponsorowanych; potrzebna ostrożność interpretacyjna

Microsoft Globalny PUE: 1.17 t (Azure (FY25) i 1.16 + data (FY24); raportuje centers) też WUE	Carbon Aware SDK (GSF) – budowa aplikacji carbon-aware (region/time shifting); sygnały i narzędzia Azure dot. optymalizacji (np. biblioteki)	Cel „100% energii elektrycznej 100% czasu” dopasowanej zakupami zero-carbon do 2030; skala zakontraktowanej CFE: 34 GW w 24 krajach (wg strony MS)	PUE agregowane i zależne od floty; porównywać przy tej samej metodologii i okresie
Oracle OCI (PUE niepodane w przytoczonych źródłach)	OCI „green cloud”; datasheet z pokryciem energii odnawialnej i wskaźnikami środowiskowymi per region (RE%)	Datasheet wskazuje m.in. 92% total renewable electricity (FY2025) i 92% w Europie (FY2025)	Wartości różnią się między stroną marketingową a datasheet (różne okresy/definicje)
OVHcloud Publikuje PUE/WUE/REF: np. OVH Group PUE 1.26, WUE 0.37 L/kWh, REF 92% (okres FY24)	Opisuje KPI środowiskowe i ich interpretację (PUE/WUE/CUE/REF)	REF (renewable energy factor) raportowane per DC i dla grupy (FY24: 92%)	Metodologia PUE/WUE oparta o ISO/IEC 30134 (wskazana w KPI)
UE „zielona chmura” (polityki) nacisk na raportowanie i metryki; cel: bardziej energooszczędne DC, OZE, odzysk ciepła, neutralność CO ₂ do 2030	Instrumenty w stylu EU – Code of Conduct; ekoprojekt dla serwerów; zielone zamówienia publiczne		UE sama wskazuje na lukę definicyjno-metryczną w ocenie efektywności i neutralności klimatycznej DC

Metryki i standardy

PUE (Power Usage Effectiveness) jest jedną z najczęściej cytowanych metryk efektywności energetycznej infrastruktury data center. The Green Grid definiuje PUE jako stosunek całkowitej energii obiektu do energii zużytej przez sprzęt IT (Total Facility Energy / IT Equipment Energy). Jednocześnie Uptime Institute podkreśla, że PUE to metryka „proxy” (przybliżenie) efektywności obiektu, której ograniczenia narastają w kontekście nowych architektur i że PUE nie opisuje wydajności samego IT/workload.

Dla oceny „zrównoważoności software’u” rośnie znaczenie SCI (Software Carbon Intensity) rozwijanego przez Green Software Foundation, który opisuje metodologię obliczania intensywności węglowej aplikacji/usługi jako „rate” na jednostkę funkcjonalną. SCI został też ustandaryzowany jako ISO/IEC 21031:2024.

Architektura techniczna i kluczowe funkcje

Architektura AI-Previz

W ujęciu inżynierskim AI-Previz składa się zwykle z czterech warstw:

Warstwa wejść kreatywnych obejmuje scenariusz/outline, brief reżyserski, referencje (moodboardy), dane produkcyjne (lokacje, casting, ograniczenia) oraz – coraz częściej – metadane potrzebne do zachowania spójności (profile postaci, style reference, parametry kamery). Badania typu ASAP pokazują automatyzację „od scenariusza”: system parsuje scenariusz na elementy semantyczne (postaci, dialogi, akcje, emocje) i zasila nimi moduły generujące storyboard/preview.

Warstwa modeli AI jest heterogeniczna: obejmuje LLM-y do analizy i rozbicia scen, modele generatywne obrazu/wideo do tworzenia klatek i animników (np. Runway), modele do spójności postaci/stylu i do sterowania ruchem, oraz modele „utility AI” do rzeczy takich jak segmentacja, tracking i keying. Komercyjnie widać nacisk na „controllable outputs”, np. Flow Studio deklaruje edytowalne outputy (tracking kamery, clean plates, maski), co ułatwia włączenie do pipeline’u VFX i previz.

Warstwa sceny i czasu rzeczywistego to silnik (game engine) i/lub DCC, gdzie przewizualizacja staje się „operacyjna”: można planować ujęcia i kamerę, a docelowo przekazać to na plan zdjęciowy lub do postprodukcji. Badania CinePreGen są symptomatyczne dla ograniczeń generacji wideo „z tekstu”: autorzy wskazują, że brak danych uczących ruch kamery ogranicza kontrolę, dlatego łączą silnik i dyfuzję, aby zapewnić sterowalne ruchy (pan/tilt/dolly itp.) i spójność generacji wspartą danymi „ground truth” (np. depth/motion) z silnika.

Warstwa eksportu i interoperacyjności jest kluczowa, bo previz ma finalnie „żyć dalej” w produkcji. Flow Studio explicite wspiera integracje z Maya/Blender/Unreal oraz USD, co odpowiada rosnącej roli USD jako formatu wymiany scen i assetów.

Architektura Green-Cloud

Green-Cloud w sensie technicznym to nie tylko „hostowanie w chmurze”, ale zestaw mechanizmów, które pozwalają: mierzyć wpływ środowiskowy, optymalizować go w czasie i przestrzeni, oraz raportować w standardach ESG.

Warstwa fizyczna i infrastrukturalna: efektywność data center tradycyjnie opisuje się PUE (pomiar infrastruktury „facility vs IT”). Uptime Institute pokazuje, że średnia branżowa PUE w badaniu 2024 wynosi 1.56, z długim okresem stagnacji oraz zastrzeżeniami co do porównywania. Dostawcy publikują własne PUE (np. Google 1.09, AWS 1.15, Microsoft 1.17), co daje punkt odniesienia, ale nie zastępuje metryk „per workload”.

Warstwa pomiaru emisji: cloud providerzy uruchomili narzędzia do wyliczania emisji klienta na podstawie użycia usług (np. Google Cloud Carbon Footprint, AWS Customer Carbon Footprint Tool). Google podkreśla rozróżnienie location-based i market-based, zgodne z logiką dual reporting Scope 2. AWS wskazuje, że CCFT pozwala oglądać estymacje z/bez zakupów energii bezemisyjnej (carbon-free energy purchases) i dostarcza dane historyczne.

Warstwa „carbon-aware”: to mechanizmy planowania zadań (kiedy i gdzie je wykonać), aby ograniczyć emisje poprzez wybór regionu o niższej emisyjności energii lub wykonanie zadań w czasie większego udziału źródeł niskoemisyjnych. Carbon Aware SDK (GSF) opisuje

podejście: „do more when electricity is clean, less when it does not”, w tym rekomendacje użycia w CI/CD i wdrożeniach.

Warstwa modelowania i symulacji: w Green-Cloud jako obszarze badawczym istnieją narzędzia pozwalające testować energoświadome algorytmy schedulingu/alokacji bez kosztownej infrastruktury. GreenCloud (symulator) modeluje zużycie energii serwerów i sieci oraz zachowania komunikacyjne w data center, umożliwiając badania nad oszczędnością energii.

Tabela porównawcza architektur

Wymiar	AI-Previz	Green-Cloud	Konsekwencja dla integracji
Obiekt optymalizacji	Czas iteracji kreatywnej, kontrola ujęcia, spójność stylu/postaci, szybkie prototypowanie	Energia/emisje/woda/odpady oraz raportowanie i optymalizacja infrastruktury/workload	Potrzebny wspólny „system metryk” (np. per prompt/iteracja, per projekt)
Charakter obciążeń	Mieszanka: interaktywne (sesje reżyserskie) + batch (warianty, render, generacja assetów)	Typowo batch-friendly (time/region shifting), ale z wyjątkami (SLA, latency)	Klasyfikacja zadań na „must-be-now” vs „can-wait” jest kluczowa
Dane i IP	Scenariusze, wizerunki, referencje, assety – wysokie ryzyko prawne/IP	Telemetria użycia zasobów i emisji; dane regionów energii; raporty ESG	Wymagane rygory DLP, szyfrowanie, audyt, kontrola dostępu
Interoperacyjność	USD/dane sceny, eksport do DCC/engine	API do emisji, integracja CI/CD, monitoring	Łączenie przez orkiestrację (K8s/queue) i metadane (tagowanie projektów)

Wpływ energetyczny i strategie zrównoważonego rozwoju

Metryki bazowe i ich ograniczenia

PUE: The Green Grid definiuje PUE formalnie jako *Total Facility Energy / IT Equipment Energy*. PUE mówi, ile „narzutu infrastrukturalnego” (chłodzenie, zasilanie pomocnicze itd.) przypada na energię IT, ale nie mówi nic o tym, czy sama praca IT została wykonana efektywnie.

Uptime Institute podkreśla, że PUE nie obejmuje energy performance IT systems i że porównywanie między obiektami wymaga ostrożności.

Carbon intensity (intensywność emisji energii elektrycznej): typowo wyrażana w gCO₂e/kWh. EEA opisuje intensywność emisji w kontekście produkcji energii elektrycznej jako relację emisji do wygenerowanej energii. W praktyce dla obciążeń chmurowych kluczowe jest, że ta intensywność zmienia się silnie w zależności od regionu i czasu.

kWh na operację ML: nie istnieje jedna „standardowa” operacja. W praktyce sensowne jest raportowanie w trzech klasach: (1) energia na trening job, (2) energia na

inferencję/request/prompt, (3) energia na jednostkę produktu (np. „przygotowanie 1 minuty animatiku w 1080p”). Google w pracy o pomiarze wpływu inferencji pokazuje, że bez jednoznacznych granic pomiaru wyniki mogą różnić się o rzędy wielkości.

Porównanie PUE dostawców i „narzutu infrastruktury”

Dla orientacyjnego porównania PUE (przy świadomości ograniczeń) zestawiamy wartości deklarowane dla dużych flot oraz średnią branżową (Uptime).

Podmiot / flota	PUOkres / uwagi E
Google Data Centers (global fleet)	1.0Średni roczny PUE floty w 2024 9
AWS data centers (global)	1.1Globalny PUE raportowany za 2024 5
Microsoft datacenters (global)	1.1FY25 (07/2024–06/2025) 7
OVHcloud (OVH Group)	1.2KPI FY24 (01/09/2023–31/08/2024); metodologia ISO/IEC 630134-2 wskazana w KPI
Średnia branżowa (Uptime survey)	1.5W badaniu 2024 Uptime: average PUE 1.56 6

Wizualizacja (wykres słupkowy PUE):

PUE – porównanie wybranych flot (mniej = lepiej)Google (2024)AWS (2024)Microsoft (FY25)OVH (FY24)Średnia branżowa (2024)1.71.651.61.551.51.451.41.351.31.251.21.151.11.051PUE

Pokaż kod

Interpretacja wprost dla „narzutu”: przy PUE=1.09 narzut infrastrukturalny to ~0.09 jednostki energii na 1 jednostkę energii IT, podczas gdy przy PUE=1.56 narzut to ~0.56. To różnica, która istotnie zmienia koszt energetyczny tej samej pracy IT, co jest szczególnie ważne dla energochłonnych workflow (rendering, generacja wideo, inferencja na GPU).

Carbon intensity i energia na inferencję: dane empiryczne i rozrzut

Jednym z najbardziej „twardych” przykładów danych liczbowych o energii na inferencję jest publikacja Google o pomiarach środowiskowego wpływu dostarczania AI na dużą skalę. Autorzy pokazują, że medianowy prompt tekstowy w Gemini Apps w maju 2025 zużywa 0.24 Wh energii (czyli 0.00024 kWh), generuje 0.03 gCO₂e i konsumuje 0.26 mL wody (metryki po stronie dostarczania/usługi, z szeroką granicą pomiaru obejmującą m.in. narzut data center).

Jednocześnie ta sama publikacja zestawia, jak bardzo w literaturze i deklaracjach różnią się estymacje energii „per prompt” (zależnie od granicy pomiaru, modelu, batch size, sprzętu). W przykładach przywołuje m.in. modelowe estymacje EcoLogits 1.83–6.95 Wh dla małego promptu (50 output tokens) czy liczby dla innych systemów.

Tabela syntetyczna (uwaga: różne granice pomiaru → nieporównywać bezpośrednio jako „kto lepszy”, raczej jako obraz rozrzutu):

Źródło / metryka	Energia na prompt	Ekwiwalent kWh	Notatka dot. porównywalności
Google (Gemini Apps, median prompt, maj 2025)	0.24 Wh	0.00024 kWh	Pomiar „comprehensive/full-stack” w środowisku produkcyjnym
EcoLogits (50 output tokens – estymacja)	1.83–6.95 Wh	0.00183–0.00695 kWh	Modelowe estymacje; silnie zależne od założeń i PUE

Dodatkowo ta sama praca Google explicite pokazuje intensywność emisji energii (gCO₂e/kWh) w ujęciu location-based (LB) vs market-based (MB) dla własnych centrów danych: dla 2023 LB 366 gCO₂e/kWh, a po uwzględnieniu zakupów CFE net MB 135 gCO₂e/kWh; dla 2024 LB 345 gCO₂e/kWh i net MB 94 gCO₂e/kWh. To praktyczny przykład, jak „carbon intensity” zależy od metodologii raportowania Scope 2 (LB vs MB).

W praktyce wdrożeniowej oznacza to, że:

- dla Green-Cloud trzeba raportować dwutorowo (LB i MB), zgodnie z logiką GHG Protocol Scope 2;
- dla AI-Previz warto mierzyć energię i CO₂e per „funkcjonalny artefakt” (np. minuta animatiku / iteracja sceny / wariant storyboardu) – idea spójna z SCI i z postulatami systematycznego raportowania energii w ML.

Strategie redukcji: gdzie AI-Previz i Green-Cloud „realnie się spotykają”

Najbardziej nośne dzwignie redukcji wpływu środowiskowego (wspólne dla AI-Previz i Green-Cloud) to:

Efektywność infrastruktury i chłodzenia: różnice PUE między flotami są duże, a branżowa średnia (1.56) wciąż istotnie wyższa od najlepszych flot hyperscale.

Dobór regionu i czasu wykonywania: badania treningu dużych sieci podkreślają, że lokalizacja i udział energii bezemisyjnej mogą różnić emisje wielokrotnie nawet w obrębie jednego kraju/organizacji i że planowanie „gdzie i kiedy” trenować model jest istotną dźwignią.

Efektywność modelu i sprzętu: jako przykłady podejść AI do poprawy efektywności serwowania w praktyce produkcyjnej Google wymienia m.in. architektury typu Mixture-of-Experts, kwantyzację, optymalizację serving i własny sprzęt; wskazuje też, że PUE floty (1.09) jest elementem całkowitej efektywności.

Studia przypadków i opinie użytkowników

AI-Previz: wdrożenia rynkowe i dowody z badań

Case studies komercyjne często mają charakter „kreatywny” i jakościowy (czas iteracji, komunikacja, aprobaty klienta). Przykładowo Together Agency opisuje wykorzystanie AI-Previz jako narzędzia, które pozwala lepiej „zobaczyć wizję” i przejść od statycznych

materiałów do bardziej filmowej prezentacji dla klienta (case Highbet), co jest typowym argumentem previz: redukcja niepewności i skrócenie pętli feedbacku.

Znacznie bardziej rygorystyczne dowody dotyczące „użyteczności” AI-Previz dostarcza literatura badawcza. CinePreGen raportuje ewaluację (user study) wskazującą na lepszą kontrolę i iteracyjność w projektowaniu ujęć dzięki połączeniu game engine i dyfuzji oraz interfejsowi kontroli kamery, odpowiadając na lukę: generatory wideo mają problem z planowaniem kamery. Z kolei ASAP pokazuje automatyzację wielu formatów wyjścia (storyboard 2D, preview 3D, VR) na bazie rozumienia scenariusza i zachowań wirtualnych aktorów, co celuje w redukcję kosztu i specjalistycznej pracy w tradycyjnym previz.

Green-Cloud: praktyki wdrożeniowe i perspektywa regulacyjna

W Green-Cloud „wdrożeniem” bywa nie tylko migracja do chmury, ale uruchomienie pomiaru i sterowania emisyjnością. Dostawcy udostępniają mechanizmy raportowania śladu węglowego klienta (np. Google Cloud Carbon Footprint z emisjami location-based/market-based, AWS CCFT z rozróżnieniem „z/bez” zakupów CFE).

Perspektywa unijna wnosi element „wymuszenia” mierzalności: Komisja Europejska wskazuje, że centra danych mają stać się bardziej energooszczędne i wykorzystywać więcej OZE, a równolegle trwają działania dot. instrumentów i raportowania.

Na poziomie operacyjnym przykładem transparentności metryk jest publikowanie KPI per data center (PUE/WUE/REF) przez OVHcloud wraz z odniesieniem do norm ISO (ISO/IEC 30134), co pozwala lepiej rozmawiać o porównywalności pomiarów.

Integracja AI-Previz z Green-Cloud: korzyści, ryzyka i wymagania

Teza integracyjna

AI-Previz generuje rosnące obciążenia GPU/CPU (generacja wideo, wariantowanie storyboardu, automatyzacje VFX, render), które łatwo „przeskalować” w chmurze. Green-Cloud dostarcza natomiast instrumentarium do mierzenia i sterowania wpływem takich obciążeń (emisje/energia), w szczególności poprzez:

- region/time shifting dla zadań batch (carbon-aware),
- PUE i inne KPI (infrastruktura),
- raportowanie emisji na podstawie zużycia usług (cloud carbon tools).

Korzyści

Redukcja emisji i kosztu energetycznego „per iteracja” dzięki przeniesieniu batchowych zadań AI-Previz do regionów o niższej emisyjności energii lub wyższym udziale CFE/OZE. Literatura o emisjach treningu dużych modeli wskazuje, że lokalizacja i energia bezemisyjna istotnie zmieniają CO₂e.

Skalowanie bez „przedzakupu” zasobów: usługi cloud-based (np. Flow Studio) podkreślają, że użytkownik nie jest ograniczony własnym sprzętem i może delegować przetwarzanie do chmury.

Lepsza mierzalność i raportowanie: Green-Cloud narzędzia (Google Cloud Carbon Footprint, AWS CCFT) pozwalają powiązać użycie z estymacjami emisji, a SCI daje metodologię do „normalizacji” na jednostkę funkcjonalną.

Ryzyka i ograniczenia

Latencja i „creative flow”: zadania interaktywne (sesje reżyserskie) nie zawsze mogą czekać na „zielone okno”. To wymusza architekturę hybrydową (interaktywne lokalnie/edge, batch w green cloud), jak na diagramie.

Porównywalność metryk i ryzyko greenwashingu: PUE nie jest metryką produktywności IT, a emisje Scope 2 mają różne metody (LB/MB). Nawet w publikacjach o AI inference autorzy podkreślają, że różnice w granicy pomiaru utrudniają porównania i prowadzą do rozrzutu o rzędy wielkości.

Dane/IP/zgody: AI-Previz bywa budowany na wrażliwych danych (scenariusze, wizerunki, projekty). Wymaga to silnego governance’u: klasyfikacji danych, ograniczeń eksportu, kontroli modeli i logowania.

Wymagania techniczne i operacyjne

Techniczne minimum:

- Orkiestracja batch (queue + worker) i możliwość opóźniania zadań, aby skorzystać z carbon-aware schedulingu.
- Metadane „projekt/shot/wersja” (tagowanie) do przypisywania energii i emisji do artefaktów previz.
- Kanał raportowania emisji: integracja z narzędziami dostawcy (np. API w Google Cloud Carbon Footprint) lub własne obliczenia zgodne z SCI.

Operacyjne minimum:

- Uzgodniona definicja „jednostki funkcjonalnej” dla KPI (np. 1 iteracja storyboardu / 1 minuta animatiku / 1 prompt do generacji ujęcia). To kluczowe, by KPI miały sens porównawczy.
- Proces „GreenOps/FinOps” do decyzji: kiedy priorytetem jest czas, a kiedy emisje.

Rekomendacje wdrożeniowe, roadmapa, KPI oraz luki badawcze

KPI rekomendowane dla programu AI-Previz × Green-Cloud

Zalecany zestaw KPI (mierzalny, możliwy do automatyzacji):

- PUE (informacyjnie, na poziomie wyboru dostawcy/regionu), ale nie jako jedyne KPI.

- Carbon intensity energii dla regionu (gCO₂e/kWh) oraz raportowanie Scope 2 w dual reporting (LB/MB) tam, gdzie możliwe.
- kWh oraz gCO₂e na jednostkę funkcjonalną AI-Previz (SCI-like): np. kWh/min animatiku, kWh/shot-variant, gCO₂e/projekt. (Metodologicznie spójne z SCI).
- Udział zadań batch wykonanych „carbon-aware” (np. % jobów przesuniętych do niskiej emisyjności).
- KPI kreatywne/produkcyjne: czas do pierwszego animatiku, liczba iteracji do akceptacji, odsetek ujęć wymagających reworku w postprodukcji (to „biznesowy sens” previz).

Roadmapa wdrożeniowa

Tabela roadmapy zakłada brak limitu budżetu, ale nacisk na rygor metryk, bezpieczeństwo i iteracyjne wdrożenie.

Horyzont	Cele techniczne	Cele operacyjne	Zasoby (szacunek)	KPI wyjściowe
Krótkoterminowo	Zbudować referencyjny pipeline AI-Previz (MVP) z rozdziałem interaktywne vs batch; uruchomić podstawową telemetrię energii/CO ₂ e per job	Uzgodnić definicję jednostki funkcjonalnej; polityka danych (IP, DLP)	1× Pipeline TD, 1× ML/GenAI engineer, 1× DevOps, 0.5× Security/Compliance	kWh/artefakt (baseline), czas iteracji, % zadań mierzalnych
Średnioterminowo	Wdrożyć carbon-aware scheduling (region/time) dla batch na bazie Carbon Aware SDK; zintegrować raportowanie dostawcy (np. Google/AWS) do dashboardu	Ustanowić proces GreenOps/FinOps: reguły opóźniania zadań, SLA kreatywne	+1× Data/BI, +0.5× Sustainability analyst	% batch carbon-aware; spadek gCO ₂ e/artefakt vs baseline; raport LB/MB
Długoterminowo	Optymalizacje zaawansowane: wybór dostawcy/regionu per typ zadania; automatyczne „routing” do najbardziej efektywnej infrastruktury; normalizacja według SCI	Audyt zewnętrzny metryk; ciągłe doskonalenie; włączenie wymogów UE/klientów	Zależnie od skali (2–4 dodatkowe FTE w platform/core)	SCI-like score/usługa; rework rate; zgodność raportowa ESG, trend redukcji

Luki badawcze i pytania do dalszej analizy

Standaryzacja granic pomiaru dla AI-Previz: publikacja Google o inferencji pokazuje, że brak zgodnej granicy pomiaru powoduje rozrzut metryk energii per prompt nawet o rzędy

wielkości. W AI-Previz (film/VFX) problem jest większy, bo „operacją” nie jest prompt, tylko iteracja kreatywna obejmująca miks generacji, renderu, transferu assetów.

Otwarte pytania:

- Jak zdefiniować jednostkę funkcjonalną AI-Previz, aby była stabilna między projektami i dawała się mapować na SCI (np. „1 minuta animatiku w 1080p o określonym stylu i liczbie ujęć”)?
- Jak porównywać obciążenia generatywne między dostawcami/regionami przy różnej metodologii Scope 2 (LB/MB) i różnym PUE/WUE?
- Jak ująć w KPI elementy kreatywne (jakość ujęć, spójność) oraz ryzyko reworku, aby uniknąć optymalizacji „tylko pod CO₂”?
- W jakim stopniu carbon-aware scheduling wpływa na praktykę produkcyjną (terminy, współpraca) i gdzie jest punkt przegięcia, gdy opóźnianie zadań szkodzi jakości/tworzeniu?
- Jakie minimum transparentności powinno być wymagane od narzędzi AI-Previz (np. export logów energii, informacja o granicy pomiaru) analogicznie do postulatów systematycznego raportowania energii w ML?

Wreszcie, w kontekście UE, istotna „luka systemowa” to brak powszechnie przyjętych definicji i metod oceny efektywności energetycznej i neutralności klimatycznej centrów danych (wskazana przez Komisję), co utrudnia porównania i audyt łańcuchów dostaw cyfrowych.