

A generatív mesterséges intelligencia által létrehozott rövid videók rejtett karbonlábnyoma: a fenntarthatósági paradoxon vizsgálata a közösségimédia-marketingben

Finta Krisztina^a, Kozma Dorottya Edina^b

Budapesti Metropolitan Egyetem^a, Pannon Egyetem^b

<https://doi.org/10.15170/MM.2026.60.03.01>

A TANULMÁNY CÉLJA

A generatív mesterséges intelligencia (MI) által létrehozott rövid formátumú marketingvideók gyors elterjedése alapvetően átalakítja a digitális tartalomgyártást, ugyanakkor egyre élesebb ellentmondásba kerül a vállalatok Net Zero kötelezettségvállalásaival és az Európai Unió fenntarthatósági jelentéstételi elvárásaival. A tanulmány e fenntarthatósági feszültséget vizsgálja, különös tekintettel a Runway, Pika és Sora típusú videógeneráló rendszerek marketingalkalmazásából származó, jellemzően rejtett karbonkibocsátásra.

ALKALMAZOTT MÓDSZERTAN

A kutatás kétpilléres módszertani megközelítést alkalmaz. Egyrészt strukturált irodalmi áttekintést végez a 2019–2026 között megjelent, az MI-etika, a környezettudomány és a marketing metszéspontján elhelyezkedő szakirodalom alapján, másrészt scenárióalapú karbonmodellezéssel becsüli a generatív videók előállításának környezeti terheit különböző energaintenzitási és hálózati karbonintenzitási forgatókönyvek figyelembevételével az alkalmazott MI-modell architektúrája és energiaadatai függvényében.

LEGFONTOSABB EREDMÉNYEK

Az eredmények igazolják, hogy a videógenerálás átlagosan mintegy harmincszor nagyobb energiaigényű, mint a képgenerálás, és nagyságrendekkel meghaladja a szöveggenerálás energiafelhasználását. A modellezés szerint egy évi 2500 MI-videót előállító kétfős marketingcsapat éves karbonkibocsátása a modellválasztástól és a hálózati energiamixtől függően nagyságrendekben szóródik: közepes modell és átlagos hálózat mellett ~22,6 kg CO₂, a legkedvezőtlenebb esetben (nagy méretű modell, fosszilis hálózat) a becslési sávval együtt akár ~900 kg CO₂. A kutatás rámutat arra, hogy a kibocsátások jelentős része az árnyék MI- (shadow AI-) gyakorlatok és az MI-specifikus fenntarthatósági mutatók hiánya miatt láthatatlan marad a vállalati ESG- és Scope 3-jelentésekben, elősegítve az algoritmikus zöldmosás jelenségét.

GYAKORLATI JAVASLATOK

A jelentéstételi hiányosság kezelésére a tanulmány bevezeti a Carbon Per Mille- (C-CPM-) mutatót, amely a hagyományos marketingteljesítmény-mutatókat karbonintenzitási dimenzióval egészíti ki. Emellett bemutatja, hogy a könnyűsúlyú modellek alkalmazása, a kvantizálás és a karbontudatos renderelési ütemezés együttesen jelentős kibocsátáscsökkentést tesz lehetővé a kimeneti minőség érdemi romlása nélkül. A kutatás ezzel új elméleti és gyakorlati keretet kínál a generatív MI fenntartható alkalmazásának mérésére és irányítására a digitális marketingben.

Kulcsszavak: Zöld MI, algoritmikus zöldmosás, rövid formátumú videómarketing, digitális karbonlábnyom, generatív MI, ESG-jelentéstétel, fenntartható marketing

Köszönetnyilvánítás: Ezt a kutatást a S.M.A.R.T. Nemzetközi Kutatócsoport támogatta.

BEVEZETÉS INTRODUCTION

A kortárs digitális térben a rövid formátumú videók a digitális interakciók és a fogyasztói elköteleződés meghatározó csatornáivá váltak (Luo et al., 2025). Iparági adatok szerint jelenleg a marketingesek számára ezek biztosítják a legmagasabb megtérülést, és a szakemberek 83%-a aktívan alkalmazza őket kampányaiban (HubSpot, 2025). Bár a közbeszéd gyakran egyszerű szórakoztató tartalomként tekint rájuk, valójában komplex, platformspecifikus kommunikációs formák, amelyek jelentős fogyasztói elköteleződést váltanak ki (Schellewald, 2021). Hasznosságuk és szórakoztató jellegük erősíti a fogyasztói bizalmat és a vásárlási hajlandóságot (Luo et al., 2025; Xiao et al., 2023).

A fejlődést jelentősen felgyorsította a mesterséges intelligencia (MI) tartalomgyártásba történő integrálása. Az MI mára a modern marketingstratégiák és a marketingkutatás meghatározó elemévé vált (Mustak et al., 2021), miközben új innováció-menedzsment-dimenziókat is megnyit a vállalati működésben (Kovács és mtsai., 2025). A generatív MI javítja a célzást, personalizációt, tartalomelőállítás és hirdetésoptimalizálási folyamatokat (Gao et al., 2023; Somov et al., 2025; Garg et al., 2024), ugyanakkor etikai és működési kihívásokat is felvet az átláthatóság, a manipuláció és a torzítások tekintetében (Gao et al., 2023; Huang & Rust, 2021; Najafloo et al., 2025; Szeberényi et al., 2025).

Az MI-generált videomarketing és a vállalati fenntarthatóság metszéspontjában egy nagyrészt rejtett paradoxon rajzolódik ki. A marketing és a fenntarthatóság közötti feszültség nem új jelenség; a fenntarthatatlan növekedési és fogyasztási minták marketingbeli megjelenése a hazai szakirodalomban is régóta ismert (Dudás, 2013). Miközben a marketingosztályok egyre intenzívebben alkalmaznak energiaigényes generatív MI-eszközöket, az ezekhez kapcsolódó karbonkibocsátás jelentős része nem jelenik meg a vállalatok Net Zero vállalásaiban. A problémát tovább erősíti az úgynevezett árnyék MI (shadow AI), amikor a munkavállalók a központi IT-felügyeletet megkerülve használnak felhőalapú MI-eszközöket, elfedve a tartalomgyártás tényleges karbonlábnyomát (Silic et al., 2025).

A kérdés etikai és szabályozási jelentőségű is. Az Európai Bizottság (2023) a Vállalati Fenntarthatósági Jelentéstételi Irányelv (CSRD) keretében az ESRS E1 standard alapján átfogó Scope 3-kibocsátásjelentést ír elő, amelybe a felhőalapú MI-használat is beletartozhat, ugyanakkor az MI-specifikus kategóriák hiánya jelentős megfeleléségi kihívást jelent a szervezetek számára. E hiányosság

kezelésére a tanulmány a következő kutatási kérdéseket vizsgálja:

K1: Milyen mértékben járul hozzá a generatív MI-eszközök rövid videógyártásban való alkalmazása az elszámolatlan Scope 3-karbonkibocsátáshoz, és hogyan erősíti fel az „árnyék MI” ezt a jelentéstételi hiányosságot?

K2: Hogyan térnek el egymástól a különböző modellarchitektúrák karbonköltségei az MI-videógyártásban, és milyen mértékben képes egy karbonköltség-alapú mutató operacionálizálni a fenntartható marketing célkitűzéseit?

K3: Milyen mértékben képesek csökkenteni a karbontudatos operatív stratégiák – beleértve a megújuló energián alapuló ütemezést és az MI-modelltömörítési technikákat – az MI-videógenerálás környezeti terheit a marketing-hatékonyság feláldozása nélkül?

ELMÉLETI HÁTTÉR THEORETICAL BACKGROUND

A videógeneráló MI energiaigénye *The energy requirements of video-generating AI*

Az MI-rendszerek gyors terjedése technológiai és ökológiai fordulópontot is jelent. A fejlődést alapvetően a Schwartz et al. (2019) által leírt „Vörös MI” (Red AI) szemlélet határozta meg, amely a teljesítménynövelést elsősorban a számítási kapacitás bővítésével éri el. Ennek következményeként egy nagy nyelvi modell fejlesztése és betanítása akár öt személyautó teljes élettartamának megfelelő szén-dioxid-kibocsátással járhat (Strubell et al., 2019), miközben az MI összesített energiaigénye egyre nagyobb kihívást jelent a Net Zero célok elérésében (Pimenow et al., 2024).


A környezeti terhelés azonban egyre inkább az inferenciafázishoz kapcsolódik. Patterson et al. (2022) szerint a modellhasználatból származó működési kibocsátások gyorsabban növekednek, mint a betanításé, Chien et al. (2023) pedig kimutatták, hogy a generatív MI tömeges használatából eredő éves karbonkibocsátás akár huszonötszöröse is lehet a modell betanítási lábnyomának. Az MI-infrastruktúra kibocsátását a hardver energiaigénye és az adatközpontok villamosenergia-hálózatának karbonintenzitása együttesen határozza meg (Kirkpatrick, 2023), ugyanakkor a pontos működési adatok hiánya továbbra is korlátozza az átláthatóságot (Yu et al., 2024).

Az empirikus vizsgálatok egyértelműen igazolják, hogy a vizuális generatív feladatok nagyságrendekkel energiaigényesebbek a szöveggenerálásnál: a képgenerálás közel hatvanszor több energiát igényel

nyel (Luccioni et al., 2024), míg a videógenerálás átlagosan legalább harmincszor energiaigényesebb a képgenerálásnál, és közel kétezerszer a szöveggenerálásnál (Delavande et al., 2025b). A 46 modellt vizsgáló összehasonlító elemzés szerint a videóközpon-tú marketing a digitális szektor korábbi emissziós becslésein túlmutathat, hiszen egyes konfigurációkban a videó- és képgenerálás energiaigénye között

százszoros különbség is előfordulhat (Chung et al., 2026), amely Luccioni et al. (2024) kép–szöveg összehasonlítású eredményeihez hasonló nagyságrendi mintázatot igazol a videó–kép viszonylatban. A szöveg-, kép- és videógenerálás energiaigényének összehasonlítását az 1. ábra szemlélteti logaritmikus skálán.

1. ábra: A generált tartalom energiaigénye a szöveggeneráláshoz viszonyítva (logaritmikus skálán)
Figure 1. Energy demand of generated content compared to text generation (on a logarithmic scale)



Forrás: a szerzők saját szerkesztése Luccioni et al. (2024) és Delavande et al. (2025b) alapján

A rövid videók generálása még tovább fokozza ezt a terhelést, és a legkörnyezetterhelőbb műveletek közé emeli. A mélytanulási modellek inferenciafázisában az energiaigény nagymértékben függ a modellmérettől és a hardver specializációjától, ami komoly terhelést ró a grafikus feldolgozóegységekre (GPU) (Desislavov et al., 2023). Videógenerálás esetén ezt a terhelést tovább növeli. A szövegből videót generáló diffúziós modellek tér-időbeli mechanizmusai lényegesen több lebegőpontos műveletet (FLOP) igényelnek, mint a hagyományos képgenerálás, a karbonlábnyom döntő része (akár 97%-a) magából a diffúziós denoising fázisból ered (Li et al., 2025). A több milliárd paraméteres, szövegből képet generáló (T2I) architektúrákra épülő rendszereket kiegészítő tér-idő modulok és dekóderek a folyamatos mozgás és a magas képminőség érdekében nem lineárisan, hanem hatványozottan növelik az energiafogyasztást (Singer et al., 2022). A Zöld MI (Green AI) pontosan erre a problémára kínál választ: Alzoubi és Mishra (2024) keretrendszere hangsúlyozza, hogy a szoftveres hatékonyság és a hardveres optimalizálás mellett az átlátható mérési

mutatók bevezetése elengedhetetlen a környezeti terhelés csökkentéséhez.

Algoritmikus zöldre mosás és az ESG hiányosságai

Algorithmic greenwashing and ESG shortcomings

A generatív videómodellek kiugróan magas környezeti terhelése ellenére a szervezeteken belül kritikus irányítási probléma, hogy teljes mértékben hiányoznak a mindennapi MI-használatot kísérő fenntarthatósági és elszámoltathatósági mérőszámok (Benbya et al., 2021). Ezt az átláthatatlanságot kihasználva a vállalatok egyre kifinomultabb zöldre mosáshoz folyamodnak, amely a modern vállalati kommunikációban rendszerint a szelektív adatközlésen és a kényelmetlen tények tudatos elhallgatásán alapul (Montgomery et al., 2023).

Ez különösen jellemző az információs és kommunikációs technológiai (IKT) szektorra, ahol a vállalatok előszeretettel festik fenntarthatónak és „zöldnek” digitális fejlesztéseiket, miközben leplezik a háttérben futó adatközpontok és algoritmusok

valós infrastrukturális hatásait (Famularo, 2023). A szóban forgó jelenséget nevezi a tanulmány „algoritmikus zöldremosásnak”. A jelenlegi ESG-keretrendszerek ugyanis sokszor túlságosan általánosak ahhoz, hogy pontosan számbavegyék az MI-technológiák összetett környezeti hatásait (Sætra, 2021). A fennálló fenntarthatósági indexek ráadásul jellemzően összeítik a pozitív és negatív hatásokat, ami lehetővé teszi, hogy a vállalatok a fenntarthatóság látszatát keltsék anélkül, hogy ténylegesen magukévá tennék a környezeti értékeket (Horváth, 2023).

A GHG Protokoll értelmezése szerint a SaaS-alapú MI-videógenerálás a végfelhasználó szervezet számára ésszerűen a Scope 3, 1-es kategóriájú kibocsátási források közé sorolható (vásárolt áruk és szolgáltatások), és lényegesség esetén az ESRS E1-6 szerinti Scope 3-közzétételben is releváns tényező lehet (WRI & WBCSD, 2011). A jelenlegi szabályozási és mérési hiányosságok miatt a Scope 3-jelentésekben az MI-videógenerálásból eredő kibocsátás sokszor nem jelenik meg külön tételként, ami megnehezíti annak megítélését, hogy a vállalati Net Zero-vállalások mennyiben tükrözik a teljes digitális lábnyomot (Sætra, 2021). A helyzet megoldása a szabályozói nyomás mellett olyan célirányos mérőeszközöket is igényel, amelyek a környezeti költségeket a pénzügyi mutatókkal azonos döntési súllyal ruházzák fel – erre tesz kísérletet a *Zöld marketing mutatók és irányelvek (K2, K3)* fejezetben bevezetett Carbon Per Mille- (C-CPM-) mutató.

MÓDSZERTAN **METHODOLOGY**

A tanulmány kétpilléres módszertani keretrendszerre épül: strukturált irodalmi áttekintésre és szcenárióalapú karbonmodellezésre.


Strukturált irodalmi áttekintés **Structured literature review**

A probléma elméleti megalapozásához strukturált irodalmi áttekintést alkalmaztunk, amely lehetővé teszi a gyorsan fejlődő, interdiszciplináris területek – jelen esetben a mesterséges intelligencia, a környezettudomány és a marketingstratégia – legújabb eredményeinek szintetizálását (Snyder, 2019). Az áttekintés célja a „Vörös MI”, a tartalomgyártás és az algoritmikus zöldremosás fogalmi összefüggéseinek feltárása volt.

Az irodalomkutatást a Scopus, a Web of Science és a Google Scholar adatbázisokban végeztük 2026 januárjában, az alábbi kulcsszó-kombinációk alkalmazásával: (,generative AI’ OR ,AI video generation’) AND (,carbon footprint’ OR ,energy consumption’ OR ,sustainability’) AND (,marketing’ OR ,social media’). A keresést a 2019 és 2026 között megjelent publikációkra szűkítettük. A kezdeti 152 tételes forráslistából cím, absztrakt és teljes szöveges relevancia alapján 37 forrást tartottunk meg. Kizártuk azokat a munkákat, amelyek az MI energiafogyasztását kizárólag hardverinfrastrukturális szinten tárgyalták, a végfelhasználói szervezeti vonatkozások nélkül. Az irodalom áttekintési és választási logikát a 2. ábra szemlélteti.

2. ábra: A strukturált irodalmi áttekintés tematikus metszéspontja és a beválogatási folyamat
($n=152 \rightarrow n=37$)

Figure 2. The thematic intersection of the structured literature review and the study selection process
($n = 152 \rightarrow n = 37$)



Forrás: a szerzők saját szerkesztése

Az irodalmi áttekintés magján túl a tanulmány további kontextuális forrásokat is felhasznál – köztük fogyasztói magatartással, marketing-ke-retrendszerekkel, szabályozási standardokkal és szervezeti irányítással foglalkozó munkákat –, amelyek célzott hivatkozáskereséssel azonosítottunk, és amelyek nem képezték részét az eredeti strukturált protokollnak. A mintába tartozó 37 tételt az irodalomjegyzékben csillag (*) jelöli, a többi forrás célzott hivatkozáskereséssel bevont kontextuális mű.

Szenárióalapú karbonmodellezés Scenario-based carbon modelling

Mivel a legnépszerűbb zárt forráskódú rövidví-deó-generáló MI-platformok (például a Runway vagy a Pika) pontos architektúrájára és energiafo-gyasztására vonatkozó adatok jelenleg nem érhetőek el nyilvánosan, a tanulmány pusztán becslések helyett szenárióalapú karbonmodellezést alkalmaz. A számítások alapját az a módszertan adja, amelyet a gépi tanulási modellek hardveres energiafelvételé-nek (GPU-típus, futásidő) és karbonkibocsátásának számszerűsítésére fejlesztettek ki (Lacoste et al., 2019). A paraméterek meghatározásához Luccioni et al. (2024) generatív MI-rendszerekre – különö-sen a többcélú és vizuális modellekre – vonatkozó empirikus összehasonlító méréseit vettük alapul, valamint Delavande et al. (2025b) és Li et al. (2024)

videógeneráló diffúziós modellekre vonatkozó ener-gia- és karbonlábnyom-vizsgálatait, amelyekből az Evideo-paraméter három modellméret-kategóriá-ját (könnyűsúlyú, közepes és nagyméretű modell) származtatjuk. Az explicit technikai becslési sávok kiszámításához és a végleges CO₂-egyenérték (kg) (a továbbiakban röviden: CO₂) meghatározásához a Machine Learning CO₂ Impact Calculator algorit-musát alkalmaztuk (Schmidt et al., é.n.; Lacoste et al., 2019; Anthony et al., 2020).

A karbonmodellezés során elengedhetetlen a szoftveres számítások infrastrukturális hátteré-nek figyelembevétele. Felhőszolgáltatók esetén a helyszínelapú és időspecifikus marginális emisz-sziós adatok alkalmazása meghatározó, mivel az MI-modellek kibocsátása jelentősen eltérhet a ki-szolgáló adatközpontok földrajzi elhelyezkedésétől függően (Dodge et al., 2022). Ennek megfelelően három forgatókönyvet dolgoztunk ki az energiain-tenzitásra vonatkozóan – optimistát, mérsékeltet és pesszimistát –, amelyek eltérő villamosener-gia-mixeket vesznek alapul (megújuló-domináns, vegyes és szén/gáz-domináns régiók). A többsze-náriós megközelítés számol a regionális hálózati intenzitások természetes változékonyságával, és ezáltal biztosítja a módszertani átláthatóságot. A három hálózati forgatókönyvet a videómodellek három E_{video}-kategóriájával (könnyűsúlyú, közepes és nagyméretű modell) kombinálva egy kétdimen-zións szenárióteret kapunk (modellméret × hálózati

karbonintenzitás), amelyben kilenc lehetséges éves kibocsátási forgatókönyvet vizsgálunk; ezek a 2. táblázatban kerülnek összefoglalásra. A regionális és időspecifikus marginális emissziós adatokhoz, valamint a karbontudatos ütemezés elveihez a tanulmány Chien et al. (2023) munkájára támaszkodik, amelynek szempontjai egyúttal a *Zöld marketing mutatók és irányelvek* (K2, K3) fejezetben javasolt mérséklési stratégiák egyik fő pillérét is alkotják.

A hatások szemléltetéséhez egy tipikus kis- és középvállalati (KKV) forgatókönyvet modelleztünk. A scenárióban egy kétfős marketingcsapat napi szinten szövegből videót (T2V) generáló modelleket alkalmaz közösségimédia-kampányokhoz. Alapegységként napi 10 darab MI-videógenerálást határoztunk meg. Ez az érték iparági adatokból vehető le: az aktív közösségi médiát kezelő kisvállalkozások ideálisnak tartott posztolási frekvenciája heti hét alkalom – napi egy videó platformonként –, és a TikTokot professzionálisan kezelő kisvállalkozások 33%-a naponta publikál (Adobe Express, 2025). Három párhuzamos platformon (TikTok, Instagram Reels, YouTube Shorts) ez napi 3–4 közzétett tartalmat jelent. A tesztleleteket, sikertelen próbákat és elvetett anyagokat is figyelembe véve – az Animoto (2026) felmérése alapján az AI-t videóképzítésre használó marketingesek körében jellemző iterációs volumennel számolva – konzervatív becsléssel napi 10 generálással, azaz évi 2500-al kalkulálunk (250 munkanapos évet feltételezve).

EREDMÉNYEK RESULTS

Az elméleti háttér és a módszertan alapján ez a fejezet scenárióalapú modellezéssel válaszolja meg a kutatási kérdéseket (K1–K3): számszerűsíti a rövid videógenerálás környezeti terheit, és javaslatokat fogalmaz meg azok csökkentésére. Az itt közölt értékek egy hipotetikus KKV-scenárió feltáró, két-dimenziós (videómodell-méret $\times$ hálózati karbonintenzitás) becslései; céljuk a nagyságrend és a jelentéstételi hiányosság szemléltetése, nem egy konkrét vállalat tényleges Scope 3 kibocsátásának mérése.

Az „árnyék MI” jelensége és a KKV-scenárió felállítása

The phenomenon of “shadow AI” and the establishment of the SME scenario

A generatív MI-eszközök vállalati elterjedése egy új és kritikus kockázati tényezőt hozott létre: az „árnyék MI” (shadow AI) jelenségét (Silic et al., 2025), ami hatékonyan vonja ki az ilyen eszközök energiafogyasztását a fenntarthatósági jelentések hatóköréből, így a kapcsolódó kibocsátás elszámolatlan és a

jelenlegi vállalati jelentéstételi rendszerekben elvileg mérhetetlen is. Az árnyék MI ezért sok esetben kimarad a Scope 3-as közzétételből.

Bár a generatív modellek betanítását és karbantartását multinacionális technológiai vállalatok végzik, a kapcsolódó felhőalapú infrastruktúra (SaaS) környezeti terhei közvetlenül a végfelhasználóknál jelentkeznek. A KKV-szektor adja a globális gazdaság gerincét, és az iparági adatok szerint a kis cégek körében a legmagasabb az árnyék MI koncentrációja: a 11–50 főt foglalkoztató vállalatoknál a munkavállalók 27%-a aktívan használ nem engedélyezett MI-eszközöket (Silic et al., 2025). A működési biztonsági adatok szerint ebben a szegmensben átlagosan 269 aktív árnyék MI-alkalmazás jut ezer főre, ami azt jelzi, hogy az egyéni felhasználók jellemzően egyszerre több eszközt is igénybe vesznek (Reco, 2025). Ez az aránytalanul nagy kitettség indokolja, hogy a makroszintű ökológiai hatások megértéséhez a szegmens mikroszintű modellezéséből induljunk ki.

A rejtett karbonlábnyom számszerűsítése

Quantifying the hidden carbon footprint

A módszertani fejezetben meghatározott 2500 generáláshoz kapcsolódó fizikai környezeti teher kiszámításához Budennyy et al. (2022) validált ökológiai lábnyom számítási módszertanát követjük, az alábbi egyszerűsített képlet alapján:

$$\text{CO}_2(\text{kg}) = (E_{\text{video}} \times N) \times \text{PUE} \times \text{CI} \div 1000$$

A változók meghatározása a szakirodalom alapján:

E_{video} : A videógenerálás áramfogyasztása, azaz a generálást kiszolgáló szerver teljes mért energiaigénye (GPU, CPU és memória). A diffúziós modellek energiaigényét elsősorban a felbontás, a videó hossza és a zajsztűrés lépések száma határozza meg (Li et al., 2024), ezért modellenként tág határok között mozog. Delavande et al. (2025b) hét nyílt forráskódú videógeneráló-modell mért energiaadatai alapján a tanulmány három modellméret-kategóriát különböztet meg: könnyűsúlyú modell (AnimateDiff, ~0,14 Wh/videó), közepes méretű architektúra (CogVideoX-5B, ~25,3 Wh/videó) és nagyméretű architektúra (WAN2.1-T2V-14B, ~415 Wh/videó). Ez a közel háromezerszeres szórás a modellméret, a felbontás, a képkockaszám és a denoising-lépések együttes hatását tükrözi. Mivel a zárt, kereskedelmi platformok (Runway, Pika, Sora) nem tesznek közzé energiaadatokat, ezek a nyílt forráskódú értékek az ő proxyjukként szolgálnak. A közepes méretű architektúra tekinthető a mai mainstream SaaS-alapú videógeneráló szolgáltatások (pl. Runway, Pika) legjobb közelítésének, míg a nagyméretű kategó-

ria inkább a csúcsmínőségű, Sora-szintű rendszerek konzervatív felső korlátjaként értelmezhető (Delavande 2025a; Luccioni et al., 2024; Synthetic Labs, 2025).

N: 2500 generálás/év

PUE (Power Usage Effectiveness): Az adatközpontok infrastrukturális és hűtési szorzója; iparági átlaga 1,55 (Uptime Institute, 2022, idézi: Bouza et al., 2023). Mivel az E_{video} önmagában csak az

IT-berendezés (szerver, GPU) tényleges elektromosáram-felvételét méri, a PUE pedig egy külön, az adatközpont működéséhez szükséges kiegészítő energiát (hűtés, tápellátás, épületüzemeltetés) szám-szerűsíti; a két tényező így additív, nem átfedő energiafelhasználást ír le, ezért nem eredményez kettős beszámítást.

A szenárióalapú karbonmodell paramétereit mutatja be az 1. táblázat.

1. táblázat: A szenárióalapú karbonmodell paramétereit

Table 1. Parameters of the scenario-based carbon model

Paraméter	Jelölés	Felvett érték	Forrás
Energiafogyasztás videónként	E_{video}	0,14 / 25,3 / 415 Wh	Delavande et al. (2025b)
Generálások száma évente	N	2500 db/év	szerzők szenáriója (Silic et al., 2025; Reco, 2025)
Adatközpont-hatékonyság	PUE	1,55	Uptime Institute (2022, idézi Bouza et al., 2023)
Hálózati karbonintenzitás	CI	20 / 230 / 400 g CO ₂ /kWh	Dodge et al. (2022)
Becslési sáv	–	±40%	Fischer (2025)

Forrás: a szerzők saját szerkesztése a hivatkozott szakirodalmak alapján

A számítás alapján a csapat éves „árnyék MI”-videógyártásának extra áramfogyasztása a választott modellkategóriától függően rendkívül tág határok között mozog: könnyűsúlyú modell esetén 0,54 kWh/év, közepes esetén 98,04 kWh/év, nagyméretű architektúra esetén pedig 1608,13 kWh/év ($2500 \times E_{\text{video}} \times 1,55$). (1. táblázat) Az ehhez társuló tényleges CO₂-kibocsátás meghatározása azonban komoly akadályokba ütközik. Bár a piacvezető videógeneráló platformok – mint az OpenAI Sora a Microsoft infrastruktúráján, a Google felhőjén futó Veo/Lumiere, illetve a Runway és a Luma (Karaarslan &

Aydın, 2024; Li et al., 2024) – rendelkeznek vállalati fenntarthatósági célkitűzésekkel, az inferenciát kiszolgáló adatközpontok pontos földrajzi helyét és valós idejű energiamixét üzleti titokként kezelik. Ez a strukturális átláthatatlanság (Famularo, 2023) lehetetlenné teszi az egyes felhasználói kérésekhez tartozó hálózati karbonintenzitás pontos meghatározását. A bizonytalanság kezelésére a három modell-kategória éves fogyasztási értékeire egyenként vetítve három eltérő regionális hálózati forgatókönyvet (Dodge et al., 2022) alkalmaztunk, amelyeket a 2. táblázat foglal össze.

2. táblázat: A KKV árnyék MI-videógyártás éves karbonkibocsátási forgatókönyvei (hálózati karbonintenzitás × modellméret)

Table 2. Annual carbon emission scenarios for shadow AI video production in SMEs (grid carbon intensity × model size)

Forgatókönyv	Hálózati karbonintenzitás (CI)	Modellkategória	Becsült éves kibocsátás [±40%]
Optimista – Megújuló energia dominál	~20 g CO ₂ /kWh	könnyűsúlyú	0,01 kg CO ₂ [0,007-0,015 kg CO ₂]
		közepes méretű	1,96 kg CO ₂ [1,177-2,745 kg CO ₂]
		nagyméretű	32,16 kg CO ₂ [19,298-45,028 kg CO ₂]
Mérsékelt – Átlagos hálózati intenzitás	~230 g CO ₂ /kWh	könnyűsúlyú	0,13 kg CO ₂ [0,075-0,175 kg CO ₂]
		közepes méretű	22,55 kg CO ₂ [13,529-31,569 kg CO ₂]
		nagyméretű	369,87 kg CO ₂ [221,921-517,817 kg CO ₂]
Pesszimista – Fosszilis energia (pl. szén) dominál	~400 g CO ₂ /kWh	könnyűsúlyú	0,22 kg CO ₂ [0,130-0,304 kg CO ₂]
		közepes méretű	39,22 kg CO ₂ [23,529-54,901 kg CO ₂]
		nagyméretű	643,25 kg CO ₂ [385,950-900,550 kg CO ₂]

Megjegyzés: A hálózati karbonintenzitás (CI) értékei Dodge et al. (2022) regionális forgatókönyvein alapulnak (alacsony ~20 g CO₂/kWh, mérsékelt ~230 g CO₂/kWh, magas ~400 g CO₂/kWh). A pesszimista érték konzervatív alsó becslés, mivel a teljes mértékben szénre támaszkodó hálózatok karbonintenzitása elérheti a 600–900 g CO₂/kWh tartományt is; ennek hatását a becslést éves kibocsátásokhoz társított ±40%-os sávok részben tükrözik. A táblázatban szereplő éves kibocsátási értékek a Delavande et al. (2025b) által mért videógenerálási energiafogyasztási adatokból származó E_{video}-értékekre és a szerzők saját számításaira épülnek.

Forrás: a szerzők saját szerkesztése

Mivel a kibocsátás lineárisan skálázódik az E_{video}-val és a hálózati karbonintenzitással, a mérsékelt hálózati forgatókönyvben (~230 g CO₂/kWh) a becslést éves érték a könnyűsúlyú modell esetében ~0,13 kg CO₂-tól a nagyméretű architektúra esetében ~370 kg CO₂-ig terjed, miközben a közepes méretű modell ~22,6 kg CO₂/év értéket ad (Delavande et al., 2025b). Ez megerősíti, hogy a modellválasztás a karbonlábnyom egyik domináns mozgatórugója. Ha a közepes E_{video}-kategóriát tekintjük a tipikus, mainstream kereskedelmi text-to-video-szolgáltatások ésszerű proxyjának, akkor egy kétfős marketingcsapat évi 2500 generálással a mérsékelt hálózati forgatókönyvben nagyságrendileg 22–23 kg CO₂ éves kibocsátást produkál – ez az érték jól értelmezhető középértéket kínál a szélesebb 0,01–900 kg CO₂ becslési tartományon belül.

Az MI-energiamérő szoftverek és a statikus modellek becslései akár 40%-os hibahatárral is dolgozhatnak (Fischer, 2025), ezért a végeredményt ±40%-os technikai becslési sávval (érzékenységi

stresszteszt) egészítjük ki, amelyet mindhárom hálózati forgatókönyv és mindhárom modellkategória esetében feltüntetünk. A pesszimista modellbecslés esetén – nagyméretű modell és magas hálózati karbonintenzitás mellett – egyetlen kis marketingcsapat árnyék MI-tevékenysége évente 643 kg CO₂ körüli láthatatlan kibocsátást generálhat, amely a hibahattárral számolva akár ~900 kg CO₂-ig is felkúszhat, ami adott esetben teljes egészében hiányozhat a vállalat ESG-jelentéseiből.

Zöldmarketing-célkitűzések és irányelvek

Green marketing objectives and guidelines

A karbonutadatos marketing megvalósítása olyan mutatókat igényel, amelyek a környezeti hatást az üzleti elemzések nyelvére fordítják le (Alzoubi & Mishra, 2024). Erre a célra vezeti be a tanulmány a Carbon Per Mille- (C-CPM-) mutatót. Az elne-

vezés szándékosan idézi a hagyományos Cost Per Mille (CPM) szerkezetét – a „C”-előtag az elemzői felületeken egyértelműen megkülönbözteti a két mutatót –, ezáltal a tartalomgyártás karbonköltségét

a tényleges elérésekhez köti, és a fenntarthatósági szempontokat a pénzügyi mutatókkal azonos döntési szintre emeli. A két mutató közötti különbséget és összefüggéseket a 3. ábra foglalja össze.

3. ábra: A Carbon Per Mille- (C-CPM-) mutató a hagyományos Cost Per Mille (CPM) logikájára építve

Figure 3. The Carbon Per Mille (C-CPM) metric based on the logic of the traditional Cost Per Mille (CPM) metric



Forrás: a szerzők saját szerkesztése

Formálisan a mutató a következőképpen definiálható:

$$C - CPM = \left(\frac{CO_2 \text{ (g)}}{\text{Megjelenések}} \right) \times 1000$$

ahol a $CO_2(g)$ a tartalmi elem előállítás során keletkezett teljes karbonkibocsátást jelöli gramm-ban, a Megjelenések pedig a leadott nézetek össze-sített számát. A mutató mértékegysége tehát $g \text{ CO}_2e / 1000 \text{ megjelenés}$. A C-CPM és a pénzügyi CPM eltérő mértékegységű mutatók, ezért nem közvetlenül összehasonlíthatók, de ugyanazon a dashboardon, egymás mellett értékelhetők.

A mutató működése egy konkrét példán szemléltethető. Mérsékelt hálózati forgatókönyv (~230 $g \text{ CO}_2/kWh$) és nagyméretű videómodell (WAN2.1-T2V-14B, ~415 $Wh/videó$) esetén egy 10 másodperces videó előállítása

$$0,415 \text{ kWh} \times 1,55 \text{ (PUE)} \times 230 \text{ g CO}_2/kWh = 147,95 \text{ g CO}_2$$

kibocsátással jár. Ha ez a tartalom a kampány során 50 000 megjelenést ér el, a C-CPM értéke:

$$\left(\frac{147,95 \text{ g}}{50000} \right) \times 1000 = 2,96 \text{ g CO}_2$$

ezer megjelenésenként. Az így kapott érték közvetlenül összevethető a kampány hagyományos CPM-mutatójával: a kampány-menedzser ugyanazon a dashboardon, ezer megjelenésre vetítve látja a tartalom pénzügyi és környezeti költségét, és e két szempont mentén rangsorolhatja a kreatívokat vagy a modellbeállításokat. Ugyanezen mérsékelt hálózati forgatókönyv mellett egy közepes méretű modell esetén a C-CPM ~0,18 $g \text{ CO}_2$, egy könnyűsúlyú esetén pedig ~0,001 $g \text{ CO}_2$, azaz ugyanahhoz a kampányhatáshoz jóval

alacsonyabb karbonköltség társul. Egy könnyűsúlyú modellre és karbontudatos ütemezésre váltva a karbonköltség – és ezzel a C-CPM – nagyságrenddel csökkenthető a megjelenések érdemi vesztesége nélkül (lásd a 3. táblázat csökkentési stratégiáit). Az ilyen átlátható fenntarthatósági jelentéstétel integrálása támogatja a CSRD-megfelelést, és hosszú távú versenyelőnyt is biztosít azáltal, hogy a vállalati értékeket mérhető környezeti elszámoltathatósággal kapcsolja össze (Eccles et al., 2014).

A K3 megválaszolásához a csökkentési lehetőségeket számszerűen is megvizsgáljuk. Delavande et al. (2025b) keresztemodell-összehasonlítása szerint már a modellválasztás is akár háromszoros energiakülönbséget generálhat. A felbontás és a képkockaszám négyzetes skálázása miatt ezek felezése önmagában körülbelül négyszeres energiamegtakarítást jelent, ami a tesztelési és vázlatkészítési fázisokban azonnal alkalmazható (Delavande et al., 2025b; Li et al., 2024). A modelltömörítési technikák, különösen a kvantizálás, szintén számottevő lehetőséget rejtenek: a numerikus pontosság FP32-ről INT8-ra csökkentése akár 50–67%-os energiamegtakarítást eredményezhet a kimeneti minőség érzékelhető romlása nélkül (Vergallo et al., 2025; Khan et al., 2025).

A karbontudatos ütemezés – vagyis a nem időkritikus renderelések megújulóenergia-felesleg időszakára való halasztása – rövid feladatoknál egyes régiókban 30–80%-os kibocsátáscsökkentést is eredményezhet, míg hosszabb futásidejű munkáknál a nyereség kisebb (Dodge et al., 2022). A három stratégia együttes alkalmazásával (modellválasztás, kimeneti paraméterek optimalizálása, karbontudatos ütemezés) a KKV-szcenárióban modellezett

pesszimista érték (~643 kg CO₂/év) akár évi 10–30 kg CO₂-ra, azaz mintegy 95–98%-kal mérsékelhető, ami az algoritmikus zöldremosás mértékét is csökkenti. A stratégiák a kimeneti minőség érzékelhető romlása nélkül alkalmazhatók (Vergallo et al., 2025; Khan et al., 2025) – a felbontáscsökkentés a víz-

latfázisra korlátozódik, az ütemezés pedig pusztán időbeli eltolás –; a kampányteljesítményre gyakorolt hatás közvetlen mérése azonban további empirikus kutatást igényel. A három stratégia adatait a 3. táblázat foglalja össze.

3. táblázat: Karbontudatos csökkentési stratégiák és potenciáljuk
Table 3. Carbon-aware reduction strategies and their potential

Stratégia	Mechanizmus	Megtakarítási potenciál	Forrás
Modellválasztás	könnyűsúlyú vs. nagyméretű modell	akár 3000× energiakülönbség	Delavande et al. (2025b)
Felbontás- és képkockacsökkentés (vázlatfázis)	bármelyik dimenzió felzése	~4× energiamegtakarítás	Delavande et al. (2025b); Li et al. (2024)
Kvantizálás	FP32 → INT8 számábrázolás	50–67% energiamegtakarítás	Vergallo et al. (2025); Khan et al. (2025)
Karbontudatos ütemezés	renderelés alacsony karbonintenzitású időszakban	30–80% csökkentés	Dodge et al. (2022)

Forrás: a szerzők saját szerkesztése

Az első kutatási kérdésnél a KKV-szenário modellezése megerősítette az árnyék MI okozta jelentéstételi rést. Az átláthatatlanságot tovább mélyíti egyrészt az, hogy a zárt forráskódú generatív MI-modellek –mint az OpenAI Sora – infrastrukturális adatait és kiszámítási igényeit a fejlesztők üzleti titokként kezelik (Liu et al., 2024); másrészt az a strukturális sajátosság, hogy a fennálló fenntarthatósági indexek a pozitív és negatív hatásokat egyszerűen összesítik, lehetővé téve a megfelelés látszatának fenntartását valódi környezeti elköteleződés nélkül (Montgomery et al., 2023; Horváth, 2023). Az ellenőrizetlen tevékenységek ESG-jelentésekből való kihagyása az algoritmikus zöldremosás egyik megnyilvánulása – egy olyan jelenség, amelyet a digitális reklámpiacon az interaktív és magával ragadó tartalmak gyors terjedése tovább erősít (Szeberényi et al., 2025).

A második kutatási kérdésre bevezetett Carbon Per Mille- (C-CPM-) mutató közvetlen választ ad a meglévő ESG-keretrendszerek mérési hiányosságaira (Sætra, 2021), és operacionalizálható keretet biztosít a CSRD ESRS E1 szerinti Scope 3-megfelelőséghez – amelybe az Európai Bizottság (2023) irányelvei értelmében a felhőalapú MI-következtetés lényegesség esetén figyelembe veendő. Ahogy van Wynsberghe (2021) megállapítja, a szemléletnek el kell mozdulnia az „MI a fenntarthatóságért” megközelítéstől (amelynek középpontjában az MI mint a fenntarthatósági célok eszköze áll) „az MI fenntarthatósága” felé (amely magának az MI-nek a környezeti terhelését állítja a figyelem kö-

zéppontjába) – a tanulmányban bevezetett C-CPM éppen ezt az elmozdulást teszi mérhetővé.

A harmadik kutatási kérdésnél bemutatott ~98%-os mérséklési potenciál azonban nem reálizálódik magától: a tényleges csökkentés intézményi elköteleződést és erős fenntarthatósági irányítást igényel (Sharma et al., 2026). Technológiai oldalról a paraméterhatékony finomhangolási eljárások – mint például a SimDA (Xing et al., 2023) – és a Zöld MI elveinek szervezeti integrálása együttesen teremtik meg azt az infrastrukturális alapot, amelyre a karbontudatos marketingstratégia építhető (Verdecchia et al., 2023).

A kutatás egy olyan ellentétet dokumentál, amelyben a technológia terjedésének üteme megelőzi a meglévő ökológiai keretrendszerek fejlődését (Lin, 2025; Cows et al., 2021), miközben az MI-eszközök egyidejűleg gyakorlati megoldásokat is kínálnak az energiahatékonyság növelésére és a tudatos fogyasztási minták erősítésére (Bozsik és mtsai, 2025). A szabályozói nyomás – mindenekeelőtt az Európai Zöld Megállapodás klímaselemzőségi céljai és a megújulóenergia-átmenet kihívásai (Horváth, 2020; Szeberényi et al., 2024) – azt jelzi, hogy a korábbi etikai mulasztás gyorsan valós megfelelési kockázattá válik. Ez a karbontudatos marketinggyakorlat elfogadását ökológiai és üzleti szempontból is elkerülhetetlenné teszi.

KÖVETKEZTETÉSEK ÉS JÖVŐBELI KUTATÁSOK CONCLUSIONS AND FUTURE RESEARCH

Összegzés és elméleti hozzájárulás

Summary and theoretical contribution

A digitális marketing rejtett ökológiai költségeinek számszerűsítésével a kutatás rámutatott, hogy egy kis csapat árnyék MI-használata éves szinten 22,55 kg (méréselt scenárió) és akár 900,55 kg CO₂ (pesszimista felső becslés) közötti kibocsátást eredményezhet. Ezek az eredmények megmutatják, hogyan rontják az ellenőrizetlen digitális tevékenységek a szélesebb körű vállalati Net Zero kötelezett-séggvállalásokat.

A tanulmány legfőbb elméleti hozzájárulása a Carbon Per Mille- (C-CPM-) mutató, amely a hagyományos ezres költségmutatók terminológiájára építve összekapcsolja a marketingteljesítményt az ökológiai felelősségvállalással. Analitikai rendszerekbe építve a marketingbefektetések megtérülése pénzügyi és környezeti alapon is optimalizálhatóvá válik, támogatva a CSRD-megfelelőséget.

Vezetői és gyakorlati következtetések Managerial and Practical Implications

A tanulmány konkrét és azonnal alkalmazható következtetéseket kínál marketingszakemberek, ügynőkegvezetők és vállalati megfeleléségi csapatok számára egyaránt. Az árnyék MI-vakfolt azonosítása mindenekelőtt a belső IT-irányítás azonnali felülvizsgálatát teszi szükségessé: a marketingosztályoknak fel kell térképezniük a decentralizált, nem engedélyezett generatív MI-előfizetéseket, és mérlegelniük kell, hogy a kapcsolódó kibocsátásokat – lényegességük függvényében – a Scope 3-as ESG-jelentési keretben is jelezzék.

A C-CPM-et a hagyományos pénzügyi mutatók mellé integrálva a kampánymenedzserek a tartalmak megtérülését a költséghatékonyság és a környezeti hatás kettős szempontja szerint értékelhetik. Végül a karbantudatos munkafolyamatok (lásd a 3. táblázat stratégiáit) jelentősen csökkenthetik a csapat karbonlábnyomát a kimeneti minőség érdemi romlása nélkül.

Korlátok és jövőbeli kutatások

Limitations and future research

A kereskedelmi MI-modellek zárt forráskódú jellege korlátozza az eredmények abszolút pontosságát; e bizonytalanság kezelésére explicit technikai becslési sávokat (érzékenységi stressztesztet) alkalmaztunk (Fischer, 2025); a jövőbeli kutatásokhoz azon-

ban elengedhetetlen lesz a platformszolgáltatókkal való közvetlen együttműködés, hogy a becslési modelleket valódi, elsődleges energiafogyasztási adatok váltsák fel. A szélső értékek közötti nagyságrendi szórás is jelzi, hogy a modell feltáró, nem prediktív jellegű.

A C-CPM rendszerhatára a tartalomelőállítás inferencia- és adatközponti terhére terjed ki, a tárolást, az adatátvitelt, a platformon történő lejátszást és a modellbetanítás arányosított részét nem tartalmazza, így a mutató a tartalomelőállítás részleges működési lábnyomát méri, nem a teljes kampányét.

A technikai adatok pontosításán túl a C-CPM-mutató alkalmazhatóságát nagyvállalati kampánykörnyezetekben is célszerű lesz tesztelni, hogy skálázhatósága összetett megtérülési elemzésekben is igazolt legyen. Egy további, eddig kevésbé feltárt kutatási irány az MI-alapú munkafolyamatok és a hagyományos, emberi stábbal végzett produkciók karbonintenzitás-arányának vizsgálata. Ahogy a globális energiahálózatok a megújuló energiaforrások irányába tolódnak, a két módszer emissziós egyensúlya várhatóan olyan módon fog változni, amelyet a jelenlegi statikus modellek még nem képesek teljeskörűen megragadni.

További korlátot jelent, hogy az árnyék MI-használat elterjedtségére vonatkozó adatok (Silic et al., 2025; Reco, 2025) általános vállalati felmérésekből származnak, és nem specifikusan a rövid videó generálásra vonatkoznak; a jelen tanulmány nem végzett saját empirikus felmérést a marketingcsapatok tényleges árnyék MI-használatáról. Ennek megfelelően a K1 kutatási kérdésre adott válasz a jelenség nagyságrendjét szemlélteti, nem annak közvetlen mérését adja; a jövőbeli kutatásoknak célszerű lenne közvetlen szervezeti felmérésekkel (pl. IT-naplóadatok, alkalmazotti kérdőívek) validálnia az itt felvázolt arányokat.

A generatív MI és MI-támogatott technológiák használatára vonatkozó nyilatkozat az írási folyamat során Statement on the use of generative AI and AI-assisted technologies during the writing process

A munka előkészítése során a szerzők nyelvi szerkesztésre, szerkezeti finomításra és lektorálásra a Claude AI-t, a Gemit és a Perplexity AI-t vették igénybe. Az említett eszközök alkalmazását követően a szerzők szükség szerint felülvizsgálták és szerkesztették a tartalmat, és teljes felelősséget vállalnak a publikáció végső tartalmáért.

HIVATKOZÁSOK REFERENCES

A * jel a strukturált mintába tartozó 37 forrást jelöli; a többi célzott hivatkozáskereséssel bevont kontextuális mű.

Adobe Express (2025). *How often should you really post on social?* <https://www.adobe.com/express/learn/blog/how-often-should-you-post-content>

* Alzoubi, Y., & Mishra, A. (2024). Green artificial intelligence initiatives: Potentials and challenges. *Journal of Cleaner Production*, 468, 143090. <https://doi.org/10.1016/j.jclepro.2024.143090>

Animoto (2026). *State of video 2026: Balancing AI innovation and human authenticity*. <https://animoto.com/state-of-video>

* Anthony, L. F. W., Kanding, B., & Selvan, R. (2020). Carbontracker: Tracking and predicting the carbon footprint of training deep learning models. *arXiv*. <https://doi.org/10.48550/arXiv.2007.03051>

Benbya, H., Pachidi, S., & Jarvenpaa, S. (2021). Artificial intelligence in organizations: Implications for information systems research. *Journal of the Association for Information Systems*, 22(2). <https://doi.org/10.17705/1ja-is.00662>

* Bouza, L., Bugeau, A. and Lannelongue, L. (2023). How to estimate carbon footprint when training deep learning models? A guide and review. *Environmental Research Communications*, 5(11), 115014. <https://doi.org/10.1088/2515-7620/acf81b>

Bozsik, N., Fűrész, Á., & Szeberényi, A. (2025). Smart Energy, Conscious Future: The Role of Artificial Intelligence in Energy Efficiency. In: Belak, J., Nedelko, Z. (eds.), *9th FEB International Scientific Conference: Sustainable Management in the Age of ESG and AI: Navigating Challenges and Opportunities, Maribor* (pp. 511–520). <https://doi.org/10.18690/um.epf.5.2025.47>

* Budenny, S., Lazarev, V., Zakharenko, N., Korovin, A., Plosskaya, O., Dimitrov, D., Arkhipkin, V., Oseledets, I., Barsola, I., Egorov, I., Kosterina, A., & Zhukov, L. (2022). eco2AI: Carbon emissions tracking of machine learning models as the first step towards sustainable AI. *Doklady Mathematics*, 106, 118–128. <https://doi.org/10.1134/s1064562422060230>

* Chien, A. A., Lin, L., Nguyen, H. B., Rao, V., Sharma, T., & Wijayawardana, R. (2023). Reducing the carbon impact of generative AI inference (today and in 2035). In: *HotCarbon '23: Proceedings of the 2nd Workshop on Sustainable*

Computer Systems (Article 11, pp. 1–7.) <https://doi.org/10.1145/3604930.3605705>

* Chung, J.-W., Wu, R., Ma, J. J., & Chowdhury, M. (2026). Where do the Joules go? Diagnosing inference energy consumption. *arXiv*. <https://doi.org/10.48550/arXiv.2601.22076>

* Cows, J., Tsamados, A., Taddeo, M., & Floridi, L. (2021). The AI gambit: Leveraging artificial intelligence to combat climate change – opportunities, challenges, and recommendations. *AI & Society*, 38(1), 283–307. <https://doi.org/10.1007/s00146-021-01294-x>

Delavande, J. (2025a). *How much power does a SOTA open video model use?* Hugging Face. <https://huggingface.co/blog/jdelavande/text-to-video-energy-cost>

* Delavande, J., Pierrard, R., & Luccioni, S. (2025b). Video Killed the Energy Budget: Characterizing the latency and power regimes of open Text-to-Video models. *arXiv*. <https://doi.org/10.48550/arXiv.2509.19222>

* Desislavov, R., Martínez-Plumed, F., & Hernández-Orallo, J. (2023). Trends in AI inference energy consumption: Beyond the performance-vs-parameter laws of deep learning. *Sustainable Computing: Informatics and Systems*, 38, 100857. <https://doi.org/10.1016/j.suscom.2023.100857>

* Dodge, J., Prewitt, T., Combes, R. T. D., Odmark, E., Schwartz, R., Strubell, E., Luccioni, A. S., Smith, N. A., DeCario, N., & Buchanan, W. (2022). Measuring the carbon intensity of AI in cloud instances. *arXiv*. <https://doi.org/10.48550/arXiv.2206.05229>

Dudás, K. (2013). Fenntarthatatlan növekedés, fenntarthatatlan fogyasztás. *Fenntarthatatlan marketing? Marketing & Menedzsment*, 47(4), 24–35.

Eccles, R. G., Ioannou, I., & Serafeim, G. (2014). The impact of corporate sustainability on organizational processes and performance. *Management Science*, 60(11), 2835–2857. <https://doi.org/10.1287/mnsc.2014.1984>

European Commission (2023). *Commission Delegated Regulation (EU) 2023/2772 of 31 July 2023 supplementing Directive 2013/34/EU of the European Parliament and of the Council as regards sustainability reporting standards. (Official Journal of the European Union.)* https://eur-lex.europa.eu/eli/reg_del/2023/2772/oj (utolsó letöltés: 2026.03.12.)

* Famularo, J. (2023). Corporate social responsibility communication in the ICT sector: Digital issues, greenwashing, and materiality. *International Journal of Corporate Social*

- Responsibility*, 8, 1–25. <https://doi.org/10.1186/s40991-023-00082-8>
- * Fischer, R. (2025). Ground-truthing AI energy consumption: Validating CodeCarbon against external measurements. *arXiv*. <https://doi.org/10.48550/arXiv.2509.22092>
- Gao, B., Wang, Y., Xie, H., Hu, Y., & Hu, Y. (2023). Artificial intelligence in advertising: Advancements, challenges, and ethical considerations in targeting, personalization, content creation, and ad optimization. *SAGE Open*, 13(4). <https://doi.org/10.1177/21582440231210759>
- * Garg, S., Haralayya, B., Qudah, A. A. M., Maguluri, P. L., Szeberényi, A., & Sameen, Z. A. (2024). The impact of artificial intelligence on management productivity and efficiency. *Business Management and Economics Engineering*, 22(1), 424–434. <https://doi.org/10.2139/ssrn.5000221>
- Horváth, K. G. (2020). Az Európai Zöld Megállapodás és a 2021–2027-es többéves pénzügyi keret kapcsolata. *Európai Tükör*, 23(1), 91–110. <https://doi.org/10.32559/et.2020.1.5>
- Horváth, K. G. (2023). Vállalati fenntarthatóság és fenntartható vállalkozások. *Acta Humana: Emberi Jogi Közlemények*, 11(3), 165–184. <https://doi.org/10.32566/ah.2023.3.8>
- HubSpot (2025). *Not another state of marketing report: 2025 marketing trends*. <https://www.hubspot.com/state-of-marketing> (utolsó letöltés: 2026.02.13.)
- Huang, M.-H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49(1), 30–50. <https://doi.org/10.1007/s11747-020-00749-9>
- * Karaarslan, E., & Aydın, Ö. (2024). Generate impressive videos with text instructions: A review of OpenAI Sora, Stable Diffusion, Lumiere and comparable models. *TechRxiv*. <https://doi.org/10.36227/techrxiv.170862194.43871446/v1>
- * Khan, S., Naz, N. S., Mazhar, T., Tariq, M. U., Shahzad, T., Guizani, S., & Hamam, H. (2025). Green AI techniques for reducing energy consumption in AI systems. *Array*, 29, 100652. <https://doi.org/10.1016/j.array.2025.100652>
- * Kirkpatrick, K. (2023). The carbon footprint of artificial intelligence. *Communications of the ACM*, 66, 17–19. <https://doi.org/10.1145/3603746>
- Kovács, Sz., Végh, M., & Szabó, I. (2025). Nyílt innováció és mesterséges intelligencia: az új innovációmenedzsment dimenziói. *Marketing & Menedzsment*, 59(különszám), 52–61. <https://doi.org/10.15170/MM.2025.59.KSZ.01.05>
- * Lacoste, A., Luccioni, A., Schmidt, V., & Dandres, T. (2019). Quantifying the carbon emissions of machine learning. *arXiv*. <https://doi.org/10.48550/arXiv.1910.09700>
- * Li, B., Jiang, Y., & Tiwari, D. (2025). Carbon in motion: Characterizing Open-Sora on the sustainability of generative AI for video generation. *ACM SIGEnergy Energy Informatics Review*, 4, 160–165. <https://doi.org/10.1145/3727200.3727224>
- Lin, B. (2025). Research on the impact, risks and ethical boundaries of AI-generated content in advertising creativity and delivery. *Frontiers in Humanities and Social Sciences*, 5(8), 285–289. <https://doi.org/10.54691/c5z3a890>
- * Liu, Y., Zhang, K., Li, Y., Yan, Z., Gao, C., Chen, R., Yuan, Z., Huang, Y., Sun, H., Gao, J., He, L., & Sun, L. (2024). Sora: A review on background, technology, limitations, and opportunities of large vision models. *arXiv*. <https://doi.org/10.48550/arXiv.2402.17177>
- * Luccioni, A. S., Jernite, Y., & Strubell, E. (2024). Power hungry processing: Watts driving the cost of AI deployment? In: *Proceedings of the 2024 ACM Conference on Fairness, Accountability, and Transparency (FAccT '24)* (pp. 85–99). Association for Computing Machinery. <https://doi.org/10.1145/3630106.3658542>
- Luo, C., Hasan, N. A. M., Zamri bin Ahmad, A. M., & Lei, G. (2025). Influence of short video content on consumers' purchase intentions on social media platforms with trust as a mediator. *Scientific Reports*, 15(1), 16605. <https://doi.org/10.1038/s41598-025-94994-z>
- * Montgomery, A. W., Lyon, T. P., & Barg, J. (2023). No end in sight? A greenwash review and research agenda. *Organization & Environment*, 37(2), 221–256. <https://doi.org/10.1177/10860266231168905>
- Mustak, M., Salminen, J., Plé, L., & Wirtz, J. (2021). Artificial intelligence in marketing: Topic modeling, scientometric analysis, and research agenda. *Journal of Business Research*, 124, 389–404. <https://doi.org/10.1016/j.jbusres.2020.11.001>
- Najafloo, A., Soltani, A., & Szeberényi, A. (2025). Enhanced Marketing Strategies in the Metaverse: Opportunities and Challenges. *Acta Carolus Robertus*, 15(1), 246–263. <https://doi.org/10.33032/acr.6235>
- * Patterson, D., Gonzalez, J., Hölzle, U., Le, Q. V., Liang, C., Munguia, L.-M., Rothchild, D., So, D. R., Texier, M., & Dean, J. (2022). The carbon footprint of machine learning training will plateau, then shrink. *arXiv*. <https://doi.org/10.48550/arXiv.2204.05149>
- * Pimenow, S., Pimenowa, O., & Prus, P. (2024). Challenges of artificial intelligence development

- in the context of energy consumption and impact on climate change. *Energies*, 17(23), 5965. <https://doi.org/10.3390/en17235965>
- * Reco (2025). *2025 state of shadow AI report*. <https://www.reco.ai/state-of-shadow-ai-report>
- * Sætra, H. (2021). A framework for evaluating and disclosing the ESG related impacts of AI with the SDGs. *Sustainability*, 13(15), 8503. <https://doi.org/10.3390/su13158503>
- Schellewald, A. (2021). Communicative forms on TikTok: Perspectives from digital ethnography. *International Journal of Communication*, 15, 1437–1457.
- * Schmidt, V., Luccioni, A., Lacoste, A., & Dandres, T. (n.d.). *Machine learning CO2 impact calculator*. <https://mlco2.github.io/impact/> (utolsó letöltés: 2026.03.01.)
- * Schwartz, R., Dodge, J., Smith, N. A., & Etzioni, O. (2019). Green AI. *arXiv*. <https://doi.org/10.48550/arXiv.1907.10597>
- * Sharma, V., Kour, M., Vass, V., & Szeberényi, A. (2026). How Does Sustainability Governance Shape the Green Finance and Climate Nexus?. *Sustainability*, 18(2), 1022. <https://doi.org/10.3390/su18021022>
- * Silic, M., Silic, D., & Kind-Trüller, K. (2025). From shadow IT to shadow AI – threats, risks and opportunities for organizations. *Strategic Change*, 35(1). <https://doi.org/10.1002/jsc.2682>
- * Singer, U., Polyak, A., Hayes, T., Yin, X., An, J., Zhang, S., Hu, Q., Yang, H., Ashual, O., Gafni, O., Parikh, D., Gupta, S., & Taigman, Y. (2022). Make-A-Video: Text-to-video generation without text-video data. *arXiv*. <https://doi.org/10.48550/arXiv.2209.14792>
- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104(1), 333–339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- Somov, A. G., Ergunova, O. T., & Szeberényi, A. (2025). The influence of artificial intelligence on decision-making in the field of personnel management of large corporations. In: Krastev, V., Rani, C., Ergunova, O., Kansra, P. and Kajla, T. (eds.), *Empowering human resources through human-computer interaction* (pp. 181–206.). IGI Global Scientific Publishing. <https://doi.org/10.4018/979-8-3373-1676-5.ch007>
- * Strubell, E., Ganesh, A., & McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, 3645–3650. <https://doi.org/10.18653/v1/p19-1355>
- Szeberényi, A., Akbar, S., Araz, N., & Balku, R. (2025). Interactive and Immersive Advertising in the Metaverse: User Perceptions and Engagement Compared to Traditional Online Environments. *Acta Carolus Robertus*, 15(Special Issue), 3–19. <https://doi.org/10.33032/acr.7019>
- Szeberényi, A., Fűrész, Á., & Rokicki, T. (2024). Renewable energy in Hungary: Awareness, challenges, and opportunities. In: Belak, J., Nedelko, Z. (eds.), *8th FEB International Scientific Conference: Challenges in the Turbulent Economic Environment and Organizations' Sustainable Development* (pp. 509–518.). Maribor. <https://doi.org/10.18690/um.epf.5.2024>
- Synthetic Labs. (2025). *Wan2.1 vs Sora, Runway, Kling, Pika*. Synthetic Labs. <https://syntheticlabs.xyz/2025/03/10/wan2-1-ai-video-comparison/>
- * van Wynsberghe, A. (2021). Sustainable AI: AI for sustainability and the sustainability of AI. *AI and Ethics*, 1(1), 213–218. <https://doi.org/10.1007/s43681-021-00043-6>
- * Verdecchia, R., Sallou, J., & Cruz, L. (2023). A systematic review of Green AI. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 13, 1–26. <https://doi.org/10.1002/widm.1507>
- * Vergallo, R., Aprile, M., Cruz, L., Vadacca, R., & Mainetti, L. (2025). Large-scale evaluation of quantization for reducing the energy footprint of deep learning models. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.5719661>
- World Resources Institute (WRI), & World Business Council for Sustainable Development (WBCSD) (2011). *Corporate value chain (Scope 3) accounting and reporting standard. GHG Protocol*. <https://ghgprotocol.org/scope-3-standard>
- * Xiao, L., Li, X., & Zhang, Y. (2023). Exploring the factors influencing consumer engagement behavior regarding short-form video advertising: A big data perspective. *Journal of Retailing and Consumer Services*, 70, 103170. <https://doi.org/10.1016/j.jretconser.2022.103170>
- * Xing, Z., Dai, Q., Hu, H., Wu, Z., & Jiang, Y.-G. (2023). SimDA: Simple diffusion adapter for efficient video generation. *arXiv*. <https://doi.org/10.48550/arXiv.2308.09710>
- * Yu, Y., Wang, J., Liu, Y., Yu, P., Wang, D., Zheng, P., & Zhang, M. (2024). Revisit the environmental impact of artificial intelligence: The overlooked carbon emission source? *Frontiers of Environmental Science & Engineering*, 18, 158. <https://doi.org/10.1007/s11783-024-1918-y>

Finta Krisztina, egyetemi tanársegéd
kfinta@metropolitan.hu

Budapesti Metropolitan Egyetem Marketing és Kommunikáció Intézet

Kozma Dorottya Edina, egyetemi docens
kozma.dorottya.edina@gtk.uni-pannon.hu

Pannon Egyetem Számvitel és Pénzügy Intézeti Tanszék

The hidden carbon footprint of short videos created by generative artificial intelligence: examining the sustainability paradox in social media marketing

THE AIM OF THE PAPER

The rapid uptake of generative artificial intelligence (AI) for producing short-form marketing videos is reshaping digital content creation, while creating growing tension between corporate Net Zero objectives and the European Union's sustainability reporting demands. This paper addresses that sustainability paradox, focusing on the largely hidden carbon footprint of AI video-creation tools such as Runway, Pika and Sora in marketing use.

METHODOLOGY

The study adopts a two-pillar approach. First, it conducts a structured review of the 2019-2026 literature across AI ethics, environmental science and marketing. Second, it uses scenario-based carbon modelling to estimate the environmental burden of generative video production under different model-architecture and grid carbon-intensity scenarios.

MOST IMPORTANT RESULTS

The results show that generating a video with AI consumes, on average, thirty times more energy than image generation and orders of magnitude more than text creation. The annual carbon footprint of a two-person team producing 2,500 AI-generated videos varies by orders of magnitude depending on model choice and grid mix: about 22.6 kg CO₂ for a medium model on an average grid, rising to as much as 900 kg CO₂ in the worst case (large model, fossil-based grid, including the estimation band). These emissions remain largely invisible in corporate ESG and Scope 3 reporting due to shadow AI practices and the absence of AI-specific sustainability indicators, thereby contributing to algorithmic greenwashing.

RECOMMENDATIONS

To address these reporting gaps, the paper proposes a new Carbon Per Mille (C-CPM) index that adds a carbon-intensity dimension to existing marketing-performance metrics. It also shows that lightweight and quantized AI models and carbon-aware render scheduling can substantially reduce CO₂ emissions without materially affecting output quality. Together, these findings offer a conceptual and practical framework for measuring and managing the sustainable use of generative AI in marketing.

Keywords: Green AI, algorithmic greenwashing, short-form video marketing, digital carbon footprint, generative AI, ESG reporting, sustainable marketing