



DUURZAAMHEID & AI

Handreiking voor klinisch fysici

Abstract

Deze handreiking geeft concrete handvatten voor hoe de klinisch fysicus duurzaamheid mee kan wegen bij de selectie, implementatie en het gebruik van AI-systemen in de medisch specialistische zorgpraktijk

NVKF kennisplatforms duurzaamheid & AI
Lovisa Westlund-Gotby, Janita van Timmeren,
Hanneke Bluemink, Femke Vaassen, Margo van Gent

duurzaamheid@nvkf.nl
kpai@nvkf.nl

Inhoud

1. Inleiding.....	2
2. Energieverbruik en milieu-impact van AI	3
2.1 Energieverbruik gedurende de AI-levenscyclus	3
2.2 IT-infrastructuur, opslag en dataverkeer	4
2.3 Van energieverbruik naar milieu-impact	5
3. Praktische aanbevelingen voor klinisch fysici	7
3.1 Wanneer is een beoordeling van energieverbruik zinvol?	7
3.2 Beschikbaarheid en vergelijkbaarheid van energiedata	7
3.3 Vijf kernvragen aan leveranciers van AI-oplossingen	8
3.4 Tijdens implementatie en gebruik	10
4. Toekomstige ontwikkelingen	12
Conclusie	12
Referenties	13

1. Inleiding

Kunstmatige intelligentie (artificial intelligence; AI) ontwikkelt zich in hoog tempo tot een integraal onderdeel van de gezondheidszorg. AI wordt steeds vaker toegepast voor onder andere beeldreconstructie, segmentatie, beslissingsondersteuning, workflow optimalisatie en behandelplanning. Deze ontwikkelingen bieden belangrijke kansen voor verbetering van zorgkwaliteit, toegankelijkheid en efficiëntie. Tegelijkertijd groeit de aandacht voor de milieu-impact van AI, met name door het toenemende energieverbruik van rekenintensieve algoritmen, datacenters, gegevensopslag en cloudinfrastructuur.

Bijdrage van de zorgsector aan uitstoot broeikasgassen

De zorgsector zorgde in 2019 wereldwijd voor 5.2% van de uitstoot van broeikasgassen⁽¹⁾. In datzelfde jaar droeg de Nederlandse gezondheidszorg 7% bij aan de totale CO₂ uitstoot van Nederland^(2,3).

De afgelopen jaren is duidelijk geworden dat de gezondheidszorg onder druk staat door een groeiende zorgvraag en personeelstekorten. Tegelijkertijd wordt van de sector verwacht dat zij haar milieu-impact vermindert⁽⁴⁾. AI kan zowel bijdragen aan als afdoen aan de verduurzaming van de zorg. Enerzijds kunnen AI-toepassingen leiden tot efficiëntere zorgprocessen, kortere scantijden, minder herhaalonderzoeken, betere benutting van apparatuur en reductie van onnodige zorg. Anderzijds verbruiken AI-systemen energie gedurende verschillende fases van hun levenscyclus, waaronder modelontwikkeling, implementatie, klinisch gebruik en is energie nodig voor de benodigde IT-infrastructuur bij zowel leveranciers als zorginstellingen^(5,6). De netto milieu-impact van AI binnen de zorg is daardoor niet vanzelfsprekend.

Naarmate AI een grotere rol krijgt binnen medische technologie ontstaat de vraag hoe energieverbruik kan worden meegenomen in besluitvorming rondom aanschaf, implementatie en gebruik. Dit sluit aan bij de visie *Klinisch Fysicus 2035* van de NVKF, waarin wordt benadrukt dat medische technologie niet alleen moet worden beoordeeld op kwaliteit, veiligheid en doelmatigheid, maar ook op duurzaamheid en maatschappelijke impact gedurende de volledige levenscyclus van de technologie⁽⁷⁾.

Duurzaamheid omvat meer dan alleen energieverbruik. Ook aspecten zoals broeikasgasemissies, materiaalgebruik, circulariteit en waterverbruik zijn relevant⁽⁸⁾. Om deze handreiking praktisch toepasbaar te houden, is ervoor gekozen om de nadruk te leggen op energieverbruik. Dit vormt de meest direct meetbare duurzaamheidsparameter voor AI-toepassingen en is bovendien een belangrijke onderliggende factor voor veel andere milieueffecten van digitale technologie. Voor het beoordelen van de klimaatimpact is echter ook de CO₂-uitstoot van belang. Deze hangt niet alleen af van de hoeveelheid verbruikte energie, maar ook van de energiebron en de locatie van de gebruikte infrastructuur⁽⁸⁾. Waar mogelijk verdienen daarom zowel energieverbruik (kWh) als CO₂-equivalenten (kg CO₂e) aandacht⁽⁹⁾.

Het doel van deze handreiking is om klinisch fysici praktische handvatten te bieden voor het meenemen van energieverbruik bij de selectie, implementatie en het gebruik van AI-toepassingen, zodat AI-toepassingen niet alleen klinisch betekenisvol zijn, maar ook bijdragen aan een toekomstbestendige inzet van medische technologie.

2. Energieverbruik en milieu-impact van AI

Om het energieverbruik van AI-toepassingen te kunnen beoordelen, is inzicht nodig in de verschillende fasen van de AI-levenscyclus waarin energie wordt verbruikt. AI verbruikt niet alleen energie tijdens het klinisch gebruik van een algoritme, ook de ontwikkeling van modellen, de onderliggende IT-infrastructuur en de opslag van gegevens dragen bij aan de totale energievraag.

Voor klinisch fysici is het belangrijk te begrijpen welke componenten naar verwachting het grootste aandeel hebben in het totale energieverbruik, en welke daarvan binnen de eigen organisatie beïnvloedbaar zijn.

2.1 Energieverbruik gedurende de AI-levenscyclus

De levenscyclus van een AI-toepassing bestaat grofweg uit vier fasen: (1) ontwikkeling van het model, (2) lokale validatie, (3) klinisch gebruik en (4) eventuele modelupdates of hertraining. Het energieverbruik verschilt sterk tussen deze fasen.

(1) Ontwikkeling van AI-modellen

Voordat een AI-model klinisch kan worden ingezet, moet het worden ontwikkeld, getraind en gevalideerd. Met name het trainen van complexe modellen, zoals deep-learning modellen of foundation modellen, kan aanzienlijk veel energie verbruiken^(8,10-12). Hiervoor worden vaak gespecialiseerde GPU's ingezet die gedurende uren, dagen of zelfs weken intensief rekenen. Het energieverbruik neemt verder toe doordat modelontwikkeling meestal bestaat uit vele iteraties, waarbij verschillende modelarchitecturen, instellingen en trainingsstrategieën worden geoptimaliseerd.

Voor ziekenhuizen die commerciële AI-software aanschaffen, vindt de fase van ontwikkeling, training en eerste validatie doorgaans plaats bij de leverancier. Het bijbehorende energieverbruik is daardoor niet zichtbaar voor de gebruiker, maar maakt wel onderdeel uit van de totale energie-impact van de technologie.

(2) Implementatie en lokale validatie

Wanneer een ziekenhuis AI-software aanschafft, dient er een lokale validatie van het model te worden uitgevoerd om te verifiëren dat het model betrouwbaar, veilig en effectief werkt binnen de eigen klinische context en op lokale (patiënten)data⁽¹³⁾. Het energieverbruik van deze validatiefase is relatief beperkt, omdat hiervoor meestal een relatief kleine dataset wordt gebruikt⁽¹⁴⁾.

(3) Klinisch gebruik (inference)

Tijdens het klinische gebruik voert een AI-model berekeningen uit op nieuwe patiëntgegevens. Dit proces wordt doorgaans aangeduid als *inference*. Het energieverbruik per analyse is meestal aanzienlijk lager dan tijdens de trainingsfase, maar door langdurig en grootschalig gebruik kan het totale energieverbruik alsnog substantieel worden⁽¹⁵⁾. Het aantal en soort analyses, de complexiteit van het model en de gebruikte hardware bepalen in belangrijke mate het energieverbruik tijdens deze fase⁽¹⁰⁾. Het type gebruikte energiebron is bepalend voor de CO₂-uitstoot⁽⁹⁾.

(4) Hertraining en continual learning

Het hertrainen van een model, bijvoorbeeld op lokale data, kan leiden tot een hoger energieverbruik. Daarnaast, met de mogelijke opkomst van “continual learning” van medische AI, kan het energieverbruik tijdens de gebruiksfase toenemen doordat het model periodiek wordt bijgewerkt op basis van nieuwe data. Anderzijds wordt de noodzaak voor hertrainen of een nieuw model ontwikkelen mogelijk kleiner.

Energieverbruik in perspectief

Het ontwikkelen en trainen van een groot AI-model kan in de orde van tientallen MWh aan energieverbruik vereisen, afhankelijk van o.a. modelgrootte, grootte van de trainingsdataset en hardware⁽⁸⁾. Dit is een eenmalige investering per model (versie). Een eenmaal getraind model kan vervolgens in meerdere ziekenhuizen en gedurende meerdere jaren worden ingezet, waardoor het energieverbruik van de trainingsfase over een groot aantal analyses wordt verdeeld. Het gebruik van een getraind model (inference) vergt minder energie, vaak in de orde van fracties van een Wh tot enkele Wh per voorspelling of query.

Stel dat een ziekenhuis jaarlijks 4000 MRI-scans uitvoert en een AI beeldanalyse-toepassing eveneens 4000 keer per jaar wordt gebruikt. Wanneer deze toepassing gemiddeld 0,5 gram CO₂ per analyse uitstoot, resulteert dit in een jaarlijkse uitstoot van circa 2 kg CO₂⁽¹⁵⁾. Uitgaande van de gemiddelde Nederlandse emissiefactor van 0,24 kg CO₂e per kWh komt dit overeen met een energieverbruik van ongeveer 8,3 kWh⁽⁹⁾.

Om dit energieverbruik in perspectief te plaatsen: een MRI-scanner verbruikt, afhankelijk van het type scanner en het gebruikspatroon, grofweg tussen de 15-100 kWh per scan⁽¹⁶⁻¹⁸⁾. Dit zou voor 4000 MRI-scans resulteren in een energieverbruik van 60.000-400.000 kWh.

Let op: wanneer een AI-model veel vaker wordt gebruikt, neemt ook het energieverbruik van het gebruik toe. Omgekeerd kan de trainingsfase relatief zwaar meewegen wanneer een model regelmatig wordt hertraind, maar slechts beperkt wordt toegepast.

Deze voorbeelden illustreren dat zowel de ontwikkelfase als de grootschalige toepassing relevant kunnen zijn voor de totale milieu-impact van AI.

2.2 IT-infrastructuur, opslag en dataverkeer

Datacenter infrastructuur en energie-efficiëntie

AI-toepassingen draaien op een onderliggende infrastructuur van servers, opslag, netwerken en datacenters. Deze infrastructuur verbruikt niet alleen energie voor de rekenprocessen zelf, maar ook voor koeling, noodstroomvoorzieningen en ondersteunende systemen.

De energie-efficiëntie van een datacenter wordt vaak uitgedrukt met de *Power Usage Effectiveness* (PUE)^(6,11,19), waarbij lagere waarden duiden op een efficiënter gebruik van energie. Een PUE van 1,5 betekent dat voor elke 1 kWh die de servers verbruiken, nog eens 0,5 kWh nodig is voor ondersteunende voorzieningen (koeling, verlichting, stroom). Een PUE van 1,0 is theoretisch perfect efficiënt.

Power Usage Effectiveness

Moderne hyperscale cloud-datacenters behalen vaak lage PUE-waarden. In 2025 rapporteerden Google Cloud, AWS en Microsoft gemiddelde PUE-waarden van 1,09, 1,14 en 1,17, respectievelijk⁽²⁰⁻²²⁾.

Voor gebruikers is vaak niet direct zichtbaar waar een AI-toepassing draait. Sommige toepassingen draaien op lokale systemen binnen het ziekenhuis, terwijl andere gebruikmaken van cloud omgevingen of externe datacenters. Grootschalige cloud-datacenters kunnen energie-efficiënter opereren dan conventionele datacenters, onder meer door hogere bezettingsgraden, efficiëntere koeling en geoptimaliseerd energiebeheer⁽¹⁰⁾. Er bestaat echter geen algemene voorkeur voor cloud-

of lokale infrastructuur vanuit duurzaamheidsoogpunt. Welke oplossing het meest duurzaam is, hangt af van de specifieke toepassing, het gebruikspatroon en de infrastructuur⁽¹¹⁾.

Locatie en cloudgebruik

Naast de technische inrichting van een datacenter speelt ook de locatie een rol^(8,10). Datacenters in koelere klimaten hebben doorgaans minder energie nodig voor koeling en ventilatie. Daarnaast beïnvloedt de gebruikte energiemix de klimaatimpact. Wanneer een datacenter wordt gevoed met elektriciteit uit fossiele bronnen leidt hetzelfde energieverbruik tot een hogere CO₂-uitstoot dan wanneer gebruik wordt gemaakt van hernieuwbare energie.

Datacenter locatie

Voor grote AI-modellen kan het verschil in milieu-impact door datacenter locatie aanzienlijk zijn. Zo is voor GPT-3 geschat dat de uitstoot van een trainingsrun, afhankelijk van de locatie van het datacenter, kan variëren van 223.920 tot 858.360 kg CO₂e. Dit illustreert dat niet alleen het energieverbruik zelf, maar ook de herkomst van de gebruikte energie van belang is voor de uiteindelijke milieu-impact^(5,11).

Gegevensopslag en dataverkeer

Daarnaast dragen gegevensopslag en datatransport bij aan het totale energieverbruik van AI-toepassingen⁽¹¹⁾. Naast de opslag van medische beelden in PACS-systemen worden vaak extra datasets, tussenresultaten, logbestanden en modelversies opgeslagen. Ook de overdracht van gegevens tussen scanners, servers, cloudomgevingen en gebruikerswerkplekken vraagt energie.

Voor individuele onderzoeken is dit energieverbruik meestal beperkt, maar op ziekenhuisniveau kunnen opslag en dataverkeer een relevante bijdrage leveren. Dit geldt vooral wanneer grote beeldbestanden langdurig worden opgeslagen of regelmatig tussen systemen worden uitgewisseld.

2.3 Van energieverbruik naar milieu-impact

Het energieverbruik van een AI-toepassing vertelt slechts een deel van het verhaal. AI wordt vaak ingezet om zorgprocessen efficiënter te maken, bijvoorbeeld door kortere scantijden, minder herhaalonderzoeken of een betere benutting van apparatuur. Voor de beoordeling van de milieu-impact is het daarom relevant om niet alleen te kijken naar het energieverbruik van het AI-systeem zelf, maar ook naar de effecten op het zorgproces als geheel.

Netto energie-impact

Indien leveranciers informatie beschikbaar stellen over energieverbruik, kun je de informatie gebruiken om de netto energie impact van een AI-systeem te schatten.

Netto energie impact

=

extra energieverbruik van het AI-systeem - de verwachte energiebesparingen in het zorgproces

Jevons-paradox

Efficiëntere systemen leiden niet automatisch tot een lagere milieu-impact. Wanneer AI de drempel voor beeldanalyse, screening of aanvullende diagnostiek verlaagt, kan het gebruik toenemen waardoor de gerealiseerde energiebesparing deels of volledig teniet wordt gedaan. Dit verschijnsel staat bekend als de Jevons-paradox⁽⁷⁾. Een vergelijkbaar effect is gezien bij CT: mede door kortere scantijden, lagere stralingsdosis en een betere beschikbaarheid is de inzet van CT in de afgelopen decennia sterk gegroeid.



3. Praktische aanbevelingen voor klinisch fysici

De keuze voor een AI-toepassing kan langdurige gevolgen hebben voor het energieverbruik van infrastructuur en zorgprocessen. Tegelijkertijd zijn betrouwbare gegevens hierover nog beperkt beschikbaar. Voor klinisch fysici betekent dit niet dat zij energiedeskundigen of datacenterexperts moeten worden. Hun rol ligt vooral in het kritisch beoordelen van beschikbare informatie, het stimuleren van transparantie bij leveranciers en het meenemen van energieverbruik in bestaande besluitvormingsprocessen.

De aanbevelingen in dit hoofdstuk zijn bedoeld als aanvulling op bestaande afwegingen rondom veiligheid, klinische prestaties, gebruikerservaring, interoperabiliteit, cybersecurity en kosten.

3.1 Wanneer is een beoordeling van energieverbruik zinvol?

Niet voor iedere AI-toepassing is een uitgebreide energiebeoordeling noodzakelijk. De grootste meerwaarde wordt verwacht bij toepassingen die:

- Op grote schaal worden gebruikt;
- Gebruikmaken van complexe AI-modellen;
- Grote hoeveelheden beelddata verwerken;
- Aanvullende hardware vereisen;
- Leiden tot veranderingen in zorgprocessen.

Bij kleinschalige toepassingen kan het uitvragen van basisinformatie over energieverbruik en infrastructuur vaak volstaan.

3.2 Beschikbaarheid en vergelijkbaarheid van energiedata

Energieverbruik wordt steeds vaker beschouwd als een relevante factor bij de beoordeling van AI-systemen, naast kwaliteit, veiligheid en doelmatigheid. Tegelijkertijd is informatie over het energieverbruik van AI-oplossingen vaak beperkt beschikbaar, waardoor het lastig kan zijn om verschillende systemen op dit punt met elkaar te vergelijken.

Het ontbreken van deze informatie betekent niet automatisch dat een toepassing niet duurzaam is, maar beperkt wel de mogelijkheid om een onderbouwde afweging te maken. Het is daarom belangrijk om energieverbruik actief uit te vragen tijdens selectie-, inkoop- en implementatietrajecten. Door deze informatie structureel op te nemen in de programma's van eisen (PVE's), aanbestedingen en leveranciersgesprekken, kunnen zorginstellingen bijdragen aan verdere transparantie en standaardisatie binnen de markt.

Een bijkomende uitdaging is dat energiedata van AI-systemen vaak zijn gebaseerd op aannames, schattingen of specifieke gebruiksscenario's. Daarnaast ontbreken momenteel breed geaccepteerde standaarden voor het rapporteren van energieverbruik van medische AI-toepassingen. Hierdoor zijn cijfers van verschillende leveranciers niet altijd direct vergelijkbaar. De beschikbare cijfers dienen daarom vooral als hulpmiddel voor vergelijking en bewustwording en minder als absolute maat voor duurzaamheid.

Er zijn wel initiatieven die werken aan standaardisering van de rapportage van energieverbruik van AI-systemen, zoals de ontwikkeling van de Software Carbon Intensity (SCI) for AI-standaard van de Green Software Foundation, een verdere uitwerking van de ISO/IEC 21031:2024 standaard^(23,24).

Specifiek voor AI in de zorg is er een initiatief vanuit Practice Greenhealth waarbij ook de ambitie van de leverancier om te verduurzamen uitgevraagd wordt. Er is een aanschaf gids en een scoringstabel beschikbaar op hun website: <https://practicegreenhealth.org/resources/us-artificial-intelligence-procurement-guide>⁽²⁵⁾. Dit is een praktische handreiking om de motivatie van leveranciers uit te vragen en duurzaamheid te stimuleren. Tevens kan hiermee de transparantie rondom energieverbruik vergroot worden.

De kernvragen in de volgende paragraaf kunnen helpen om de beschikbaarheid, kwaliteit en relevantie van energiedata systematisch te beoordelen.

3.3 Vijf kernvragen aan leveranciers van AI-oplossingen

Neem duurzaamheid expliciet mee in businesscases, aanbestedingen en PvE's.

Bij de beoordeling van AI-oplossingen verdienen ten minste de volgende aspecten aandacht:

1. Transparantie van de leverancier;
2. Energieverbruik;
3. Benodigde infrastructuur;
4. Opslag en dataverkeer;
5. Invloed op het zorgproces.

Deze aandachtspunten zijn samengevat in vijf kernvragen die kunnen worden gebruikt tijdens leveranciersgesprekken, aanbestedingen en implementatietrajecten. Per kernvraag zijn voorbeelden van verdiepende vragen opgenomen. Niet iedere vraag zal voor iedere toepassing relevant zijn. De vragen zijn bedoeld als hulpmiddel om duurzaamheid expliciet mee te nemen in bestaande besluitvormingsprocessen.

Kernvraag 1: Kunt u inzicht geven in het energieverbruik en de duurzaamheid van uw AI-oplossing?

Waarom relevant?

Transparantie is momenteel vaak belangrijker dan de absolute getallen. Zonder inzicht in de gebruikte aannames, infrastructuur en meetmethoden zijn energiegegevens moeilijk te interpreteren.

Verdiepende vragen

- Is een duurzaamheidsrapport beschikbaar?
- Wordt gebruikgemaakt van tooling zoals CarbonTracker, CodeCarbon, Green Algorithms^(19,26,27) of vergelijkbare methodieken?
- Zijn energiegegevens onafhankelijk gevalideerd?
- Welke standaard of methodiek is gebruikt voor de berekeningen?

Kernvraag 2: Wat is het energieverbruik van de AI-oplossing gedurende de levenscyclus?

Waarom relevant?

Om energieverbruik mee te nemen in besluitvorming is ten minste een globale inschatting van de orde van grootte nodig.

Verdiepende vragen

- Wat is het gemiddelde energieverbruik per analyse?
- Wat is het energieverbruik per 1.000 analyses?
- Zijn in de getallen het energieverbruik voor het trainen van het model meegenomen?
- Hoeveel analyses zijn gemiddeld nodig binnen één patiënttraject?
- Zijn de opgegeven waarden gemeten of berekend?
- Hoe vaak wordt het model geüpdatet of opnieuw getraind, en is het energieverbruik hiervan meegenomen in de gerapporteerde cijfers?

Kernvraag 3: Welke infrastructuur is gebruikt tijdens de ontwikkeling van de AI-oplossing en welke is nodig voor het gebruik?

Waarom relevant?

Het energieverbruik wordt niet alleen bepaald door het algoritme, maar ook door de benodigde hardware en infrastructuur. Dit omvat zowel de trainings- en ontwikkelingsfase als de inference fase.

Verdiepende vragen

- Kan de oplossing worden geïmplementeerd op bestaande infrastructuur?
- Is aanschaf van nieuwe hardware noodzakelijk?
- Vereist de oplossing vervroegde vervanging van bestaande infrastructuur?

Indien cloudgebaseerd getraind/gehost:

- In welk datacenter is het model getraind?
- In welk datacenter wordt het model gehost?
- Wat is de Power Usage Effectiveness (PUE) van de gebruikte datacenters?
- Welke duurzaamheidscriteria stelt de leverancier aan cloudproviders en datacenters?
- Zijn energiegegevens van de gebruikte datacenters beschikbaar?

Indien lokaal getraind/gehost:

- Welke hardware wordt gebruikt?
- Wat is het energieverbruik van deze hardware?

Kernvraag 4: Welke gevolgen heeft de oplossing voor gegevensopslag en dataverkeer?

Waarom relevant?

Naast rekenkracht kunnen ook opslag en gegevensuitwisseling bijdragen aan het totale energieverbruik.

Verdiepende vragen

- Hoeveel extra dataopslag wordt gegenereerd?
- Worden gegevens uitgewisseld tussen ziekenhuis en cloudomgeving?
- Hoeveel netwerkverkeer ontstaat per analyse?
- Hoe vaak worden gegevens verzonden en opgeslagen?

Kernvraag 5: Welke invloed heeft de AI-toepassing op het zorgproces en de netto energie-impact?

Waarom relevant?

De uiteindelijke milieu-impact wordt niet alleen bepaald door het energieverbruik van het AI-systeem zelf, maar ook door de manier waarop het zorgproces verandert.

Verdiepende vragen

- Welke klinische of operationele meerwaarde wordt verwacht?
- Welke procesverbeteringen worden gerealiseerd?
- Zijn deze voordelen onderbouwd met praktijkgegevens?
- Kunnen de procesverbeteringen juist leiden tot verhoogd energieverbruik (Jevons-paradox)? Zijn er werkafspraken te maken om dit te voorkomen?

Voorbeelden van mogelijke voordelen:

- Kortere beoordelingstijden
- Kortere intekentijden
- Snellere diagnosestelling
- Minder herhaalonderzoeken
- Kortere scantijden
- Efficiëntere dataopslag
- Vermindering van handmatige werkzaamheden

3.4 Tijdens implementatie en gebruik

De verwachte milieu-impact van een AI-toepassing wordt in de praktijk bepaald door de manier waarop deze wordt geïmplementeerd en gebruikt. De werkelijke effecten kunnen afwijken van de verwachtingen tijdens de aanschafffase. Het is daarom belangrijk om niet alleen de technische prestaties, maar ook de gevolgen voor energieverbruik en zorgprocessen te evalueren.

Bij implementatie

Bij de implementatie van een AI-oplossing kan het zinvol zijn om:

- In kaart te brengen welke onderdelen van het zorgproces veranderen;
- Vooraf vast te leggen welke voordelen worden verwacht;
- Waar mogelijk verwachte effecten op energieverbruik of efficiëntie te kwantificeren;
- Samen te werken met ICT-, data- en informatiemanagementafdelingen wanneer aanvullende informatie nodig is over infrastructuur, cloudgebruik, opslag of energieverbruik.

Tijdens gebruik

Tijdens het gebruik van AI kan periodiek worden geëvalueerd of de verwachte voordelen daadwerkelijk worden gerealiseerd en of deze opwegen tegen het extra energieverbruik van de toepassing. Hierbij kan onder meer aandacht worden besteed aan veranderingen in:

- Het aantal onderzoeken of analyses;
- Scantijden;
- Opslagbehoefte;

- Dataverkeer;
- Het gebruik van cloudcapaciteit;
- De tijdsinvestering van zorgprofessionals;
- Het aantal herhaal- of vervolgonderzoeken.

Neem duurzaamheid waar mogelijk mee in reguliere evaluaties van medische technologie. Daarbij hoeft niet uitsluitend gekeken te worden naar het energieverbruik van de AI-toepassing zelf, maar juist naar de bredere gevolgen voor het zorgproces. Uiteindelijk is niet alleen het energieverbruik van AI van belang, maar de nettobijdrage aan een duurzamere en doelmatiger zorgverlening.

4. Toekomstige ontwikkelingen

De aandacht voor het energieverbruik van AI staat nog relatief aan het begin van haar ontwikkeling. Hoewel de afgelopen jaren belangrijke stappen zijn gezet in het inzichtelijk maken van de energie- en milieu-impact van AI ^(5,6,11,12,14,28-31), bestaat er nog geen breed geaccepteerde standaard voor het rapporteren, vergelijken en beoordelen van energieverbruik van medische AI-toepassingen.

Voor klinisch fysici betekent dit dat veel van de informatie die nodig is om een goede afweging te maken momenteel nog niet of slechts beperkt beschikbaar is. Het is echter aannemelijk dat hierin de komende jaren verandering zal optreden. Net zoals eisen rondom patiëntveiligheid, cybersecurity en interoperabiliteit steeds beter zijn verankerd in wet- en regelgeving en inkoopprocessen, zullen ook transparantie over energieverbruik naar verwachting een groter onderdeel worden van de beoordeling van medische technologie.

Standaardisatie van energie-indicatoren

Een belangrijke ontwikkeling is de behoefte aan gestandaardiseerde indicatoren voor energieverbruik ^(6,24,32). Momenteel gebruiken studies uiteenlopende maatstaven, zoals energieverbruik per trainingsrun, energieverbruik per analyse, CO₂-equivalenten, aantal modelparameters of rekencapaciteit. Hierdoor zijn verschillende AI-oplossingen vaak moeilijk met elkaar te vergelijken. Verschillende auteurs pleiten daarom voor uniforme rapportage van energie gerelateerde prestatie-indicatoren naast traditionele kwaliteits- en prestatie-maten ^(5,6,11,12,14,32).

Meer transparantie van leveranciers

Een tweede ontwikkeling betreft de beschikbaarheid van gegevens over energieverbruik. Momenteel verstrekken de meeste leveranciers van medische AI-oplossingen slechts beperkt informatie over de gebruikte infrastructuur, de benodigde rekenkracht of het energieverbruik van hun producten. Naar verwachting zullen zorginstellingen, inkopers en toezichthouders steeds vaker vragen om dergelijke informatie. Dit kan leiden tot meer transparantie en betere mogelijkheden om energieaspecten mee te nemen in de besluitvorming.

Ecolabels en duurzaamheidsprofielen

In de radiologische literatuur zijn voorstellen gedaan voor de ontwikkeling van zogenoemde ecolabels of duurzaamheidsprofielen voor AI-systemen. Dergelijke instrumenten zouden gebruikers inzicht kunnen geven in aspecten zoals energieverbruik, benodigde infrastructuur, opslagbehoefte en de verwachte impact op zorgprocessen. Hoewel dergelijke systemen zich nog in een vroeg stadium bevinden, kunnen zij in de toekomst de vergelijking van technologieën vereenvoudigen.

Conclusie

Hoewel betrouwbare energiegegevens momenteel nog beperkt beschikbaar zijn, kunnen klinisch fysici nu al bijdragen aan een meer duurzame inzet van AI. Door transparantie te stimuleren, kritische vragen te stellen aan leveranciers en energieverbruik mee te wegen naast kwaliteit, veiligheid en doelmatigheid, kan duurzaamheid expliciet onderdeel worden van bestaande besluitvormingsprocessen. Daarbij is uiteindelijk niet het energieverbruik van AI zelf doorslaggevend, maar de nettobijdrage aan een duurzamere, doelmatiger en toekomstbestendige zorg.

Referenties

- (1) Romanello M, Di Napoli C, Drummond P, Green C, Kennard H, Lampard P, et al. The 2022 report of the Lancet Countdown on health and climate change: health at the mercy of fossil fuels. *The Lancet* 2022 -11-05;400(10363):1639.
- (2) Health care's climate footprint: the health sector contribution and opportunities for action 16th World Congress on Public Health 2020; 2020; ; 2020.
- (3) Bruin Jd, Houwert T, Merkus K. Een stuur voor de transitie naar duurzame gezondheidszorg - Kwantificering van de CO₂-uitstoot en maatregelen voor verduurzaming. Gupta Strategists 2019 Mei.
- (4) GREEN DEAL: Samen werken aan duurzame zorg C-238 2022 8 December.
- (5) Doo FX, Vosschenrich J, Cook TS, Moy L, Almeida EPRP, Woolen SA, et al. Environmental Sustainability and AI in Radiology: A Double-Edged Sword. *Radiology* 2024 -02-01;310(2).
- (6) Champendal M, Lokaj B, De Gevigney VD, Brulé G, Zaghir J, Boiko P, et al. Exploring environmental sustainability of artificial intelligence in radiology: A scoping review. *European Journal of Radiology* 2025 -11-19;194.
- (7) Bakker N, Canters R, Lanting C, Minkels T, Nederveen A, Winter Md, et al. Klinisch Fysicus 2035 - Visiedocument van de Nederlandse Vereniging voor Klinische Fysica.
- (8) Aczel M, Chamanara S, Matin M, Farsi A, Marwala T, Madani K. Environmental Cost of Artificial Intelligence: Carbon, Water, and Land Footprints. United Nations University - Institute for Water, Environment and Health 2026 -10-08:41.
- (9) Milieu Centraal, Stichting Stimular, SKAO, Connekt, Rijksoverheid. CO₂ Emissiefactoren. Available at: <https://co2emissiefactoren.nl/factoren/2026/11/elektriciteit/?unit=kwh..> Accessed 3 September, 2026.
- (10) Patterson D, Gonzalez J, Le Q, Liang C, Munguia L, Rothchild D, et al. Carbon Emissions and Large Neural Network Training. 2021 April 23.
- (11) Ranschaert ER, Klontzas ME, Safdar NM. Sustainability of AI in Radiology. : Springer; 2026.
- (12) De Vries A. The growing energy footprint of artificial intelligence. *Joule* 2023 -10;7(10):2191.
- (13) van Smeden M, Moons K, Hooft L, Chavannes N, van Os H, Kant I. Guideline for high-quality diagnostic and prognostic applications of AI in healthcare. 2023 16-08.
- (14) Kocak B, Ponsiglione A, Romeo V, Ugga L, Huisman M, Cuocolo R. Radiology AI and sustainability paradox: environmental, economic, and social dimensions. *Insights Imaging* 2025 -04-17;16(1).
- (15) Truhn D, Müller-Franzes G, Kather JN. The ecological footprint of medical AI. *Eur Radiol* 2024;34(2):1176–1178.
- (16) Ghatpande O, Van Sant A, Clarke A, Consul N, Tompkins J, Ruschke C, et al. Multi-facility analysis using metered power data to quantify MRI energy use and utility bill costs across scanner operating modes. *Applied Energy* 2026 -11-01;422:128290.

(17) Heye T, Knoerl R, Wehrle T, Mangold D, Cerminara A, Loser M, et al. The Energy Consumption of Radiology: Energy- and Cost-saving Opportunities for CT and MRI Operation. *Radiology* 2020 - 06;295(3):593–605.

(18) Woolen S, Becker AE, Martin AJ, Knoerl R, Lam V, Folsom J, et al. Ecodesign and Operational Strategies to Reduce the Carbon Footprint of MRI for Energy Cost Savings. *Radiology* 2023 6 July;304(4).

(19) Anthony LFW, Kanding B, Selvan R. Carbontracker: Tracking and Predicting the Carbon Footprint of Training Deep Learning Models. 2020; Available at: <http://arxiv.org/abs/2007.03051>. Accessed Jun 17, 2026.

(20) Google. Google Datacenters - Duurzaam ondernemen - Energie-efficiëntie. 2026; Available at: <https://datacenters.google/efficiency/>. Accessed 28 July, 2026.

(21) Amazon. 2025 Amazon Sustainability Report - AWS Summary. 2026.

(22) Microsoft. Measuring energy and water efficiency for Microsoft Datacenters. Available at: <https://datacenters.microsoft.com/sustainability/efficiency/>. Accessed 8 August, 2026.

(23) Standards Working Group Green Software Foundation. Software Carbon Intensity (SCI) Specification. ISO/IEC 21031:2024 2024.

(24) Joint Development Foundation Projects, LLC, GSF Series, and its contributors. SCI for AI — Software Carbon Intensity for Artificial Intelligence. Available at: <https://greensoftware.foundation/standards/sci-ai/>. Accessed Oct 2, 2026.

(25) Healthcare Without Harm, Practice Greenhealth. U.S. Artificial Intelligence Procurement Guide. 2026; Available at: https://practicegreenhealth.org/resources/us-artificial-intelligence-procurement-guide?sso_checked=1. Accessed Oct 2, 2026.

(26) Benoît C, Schmidt V, Goyal-Kamal, inimaz, Coutarel M, Blanche L, et al. Codecarbon.

(27) Lannelongue L, Grealey J, Inouye M. Green Algorithms: Quantifying the Carbon Footprint of Computation. *Advanced Science* 2021 24 June;8(12).

(28) Tomlinson B, Black RW, Patterson DJ, Torrance AW. The carbon emissions of writing and illustrating are lower for AI than for humans. *Sci Rep* 2024 -02-14;14(1).

(29) Prajwal R, Pawan SJ, Nazarian S, Heller N, Weight CJ, Duddalwar V, et al. A Study on Energy Consumption in AI-Driven Medical Image Segmentation. *J Imaging* 2025 -05-26;11(6).

(30) Selvan R, Bhagwat N, Wolff LF, Kanding B, Dam EB. Carbon Footprint of Selecting and Training Deep Learning Models for Medical Image Analysis. 2022 -09-15.

(31) Latif I, Newkirk AC, Carbone MR, Munir A, Lin Y, Koomey J, et al. Empirical Measurements of AI Training Power Demand on a GPU-Accelerated Node. 2024 -12-23.

(32) Doo FX, Parekh VS, Kanhere A, Savani D, Tejani AS, Sapkota A, et al. Evaluation of Climate-Aware Metrics Tools for Radiology Informatics and Artificial Intelligence: Toward a Potential Radiology Ecolabel. *Journal of the American College of Radiology* 2024 -02-01;21(2):239–247.