



Vaasan yliopisto
UNIVERSITY OF VAASA

Paavo Lahti

NVIDIA DLSS ja tekoälyavusteinen renderöinti

Syväoppimisen vaikutus videopeligrafiikan suorituskykyyn ja kuvanlaatuun

Tekniikan ja innovaatiojohtamisen
akateeminen yksikkö
Kandidaatin tutkielma
Automaatio ja tietotekniikka

Vaasa 2025

VAASAN YLIOPISTO**Tekniikan ja innovaatiojohtamisen akateeminen yksikkö**

Tekijä:	Paavo Lahti		
Tutkielman nimi:	NVIDIA DLSS ja tekoälyavusteinen renderöinti - Syväoppimisen vaikutus videopeligrafiikan suorituskykyyn ja kuvanlaatuun		
Tutkinto:	Tekniikan kandidaatti		
Oppiaine:	Automaatio- ja tietotekniikka		
Työn ohjaaja:	Timo Mantere		
Valmistumisvuosi:	2025	Sivumäärä:	44

TIIVISTELMÄ:

Videopeliteollisuuden visuaaliset vaatimukset ovat kasvaneet merkittävästi viime vuosikymmeninä. Kuluttajat odottavat peleiltä samanaikaisesti korkeaa resoluutiota, realistista valaistusta sekä sulavaa ruudunpäivitysnopeutta. Renderöinnin laskentatehon kasvattaminen pelkällä raa'alla voimalla ei enää riitä vastaamaan näihin vaatimuksiin. Tämän seurauksena ala on siirtynyt hyödyntämään tekoälyä ja koneoppimista osana kuvanmuodostusprosessia.

Tämän kandidaatintutkielman tavoitteena on tarkastella tekoälyavusteisen renderöinnin roolia nykyaikaisessa tietokonegrafiikassa. Tutkimus keskittyy erityisesti NVIDIA:n kehittämään Deep Learning Super Sampling (DLSS) -teknologiaan, sen toimintaperiaatteisiin sekä kehityskaareen. Tutkielmassa selvitetään, miten syväoppimiseen perustuvat menetelmät eroavat perinteisistä renderöintitekniikoista, kuten natiiviresoluutiosta ja klassisista reunanpehmennysmenetelmistä. Lisäksi työssä arvioidaan teknologian vaikutuksia pelien suorituskykyyn ja kuvanlaatuun sekä vertaillaan DLSS:ää kilpaileviin ratkaisuihin.

Tutkielma on toteutettu kirjallisuuskatsauksena, jossa hyödynnetään teknistä dokumentaatiota, alan julkaisuja sekä riippumattomia suorituskykytestejä. Teoreettisessa osuudessa käydään läpi tietokonegrafiikan renderöintiputken perusteet sekä neuroverkkojen soveltaminen kuvanrekonstruktiossa. Työssä analysoidaan DLSS-teknologian evoluutiota yksinkertaisesta kuvan skaalauksesta kohti useita peräkkäisiä ruutuja generoivaa tekoälymallia.

Tekoälypohjainen renderöinti on muuttanut grafiikan tuottamisen peruseriaatteita. Tulosten perusteella DLSS on onnistunut ratkaisemaan perinteisen laadun ja suorituskyvyn välisen kompromissin. Se mahdollistaa merkittävästi korkeamman ruudunpäivitysnopeuden ilman, että kuvanlaatu visuaalisesti heikkenee.

Natiiviresoluutiolla pelaaminen on väistymässä. Tulevaisuuden renderöinti perustuu hybridimalliin, jossa perinteinen grafiikkaputki luo geometrisen rungon ja tekoäly vastaa lopullisen pikselimassan tuottamisesta ja viimeistelystä. Vaikka tekoälygenerointi tuo mukanaan haasteita esimerkiksi syöteviiveen muodossa, sen tarjoamat suorituskykyedut ovat tärkeitä nykyaikaisen peligrafiikan toteuttamisessa.

AVAINSANAT: tietokonegrafiikka; tekoäly; syväoppiminen; renderöinti; kuvanlaatu; suorituskyky

Sisällys

1	Johdanto	7
1.1	Tutkielman tausta ja motivaatio	7
1.2	Tutkimuskysymykset, tavoitteet ja rajaukset	8
1.3	Tutkielman rakenne	9
2	Tietokonegrafiikan perusteet	11
2.1	Mitä on tietokonegrafiikka?	11
2.2	Näytönohjaimen rooli tietokonegrafiikassa	12
3	Videopeligrafiikan ja renderöinnin keskeiset osa-alueet	14
3.1	Vertex Shading	15
3.2	Rasterointi	15
3.3	Fragment Shading	15
3.4	Z-buffer ja syvyysvertailu	17
3.5	Anti-aliasing ja supersampling	17
4	Tekoälyn rooli tietokonegrafiikassa	20
4.1	Syväoppimismenetelmät ja neuroverkkoarkkitehtuurit kuvanlaadun optimoinnissa	20
4.2	Neuroverkkojen kouluttaminen peligrafiikassa	21
5	NVIDIA DLSS vs. muut menetelmät	24
5.1	Mikä on NVIDIA DLSS?	24
5.1.1	DLSS 1.0	25
5.1.2	DLSS 2.0	26
5.1.3	DLSS 3.0	27
5.1.4	DLSS 4.0	28
5.2	Miten perinteiset menetelmät vertautuvat DLSS?	30
5.3	Muiden näytönohjainvalmistajien kilpailevat menetelmät	32
5.3.1	AMD FSR	33
5.3.2	Intel XeSS	34
6	DLSS:n tulevaisuuden näkymät	36

6.1	DLSS:n nykytila ja haasteet	36
6.2	Voiko tekoäly korvata perinteiset renderöintimenetelmät?	38
7	Johtopäätökset	40
	Lähteet	42

Kuvat

Kuva 1. Renderöintiputken vaiheet	14
Kuva 2. Konvoluutioautoenkooderin kerrokset	25
Kuva 3. Pelikohtainen vertailu DLSS Off, DLSS 3 ja DLSS 4 välillä	29
Kuva 4. Transformer-malli	30
Kuva 5. Kuvavertailu Quality-tilassa	34

Lyhenteet

2D	Two-dimensional, kaksiulotteinen
2K	2K resolution, 2K-resoluutio (2560 x 1440)
3D	Three-dimensional, kolmiulotteinen
4K	4K resolution, 4K-resoluutio (3840 x 2160)
AI	Artificial Intelligence, tekoäly
CNN	Convolutional Neural Network, konvoluutioneuroverkko
CPU	Central Processing Unit, keskussuoritin
DLAA	Deep Learning Anti-Aliasing, syväoppimiseen perustuva reunanpehmenys
DLSS	Deep Learning Super Sampling, syväoppimiseen perustuva ylinäytteistys
FP8	Floating Point 8-bit, 8-bittinen liukuluku
FPS	Frames Per Second, kuvataajuus
FSR	FidelityFX Super Resolution
GAN	Generative Adversarial Network, generatiivinen vastakkainen verkko
GPU	Graphics Processing Unit, grafiikkaprosessori
HR	High Resolution, korkea resoluutio
LR	Low Resolution, matala resoluutio

MSAA	Multisample Anti-Aliasing, moninäytteistykseen perustuva reunanpehmennys
RDNA	Radeon DNA, AMD:n grafiikka-arkkitehtuuri
SR	Super Resolution, superresoluutio
SSAA	Super-Sampling Anti-Aliasing, ylinäytteistykseen perustuva reunanpehmennys
TAA	Temporal Anti-Aliasing, ajallinen reunanpehmennys
VAE	Variational Autoencoder, variaationaalinen autoenkooderi
VRAM	Video Random Access Memory, videomuisti
XeLL	Xe Low Latency, Intelin matalan viiveen teknologia
XeSS	Xe Super Sampling
XMN	Xe Matrix eXtensions, Intelin matriisilaskentalaajennukset

1 Johdanto

Tekoälyn hyödyntäminen tietokonegrafiikassa on vielä kehitysvaiheessa, mutta sen merkitys kasvaa jatkuvasti. AI-pohjaiset renderöintitekniikat tarjoavat mahdollisuuksia, joita perinteiset algoritmit eivät pysty saavuttamaan, kuten entistä tarkempaa liikkeen ennustamista ja kuvan rekonstruktioita vähäisemmällä laskentateholla.

Tutkielma tarkastelee tekoälypohjaisten renderöintimenetelmien, etenkin NVIDIA DLSS:n toimintaperiaatteita, vertailee eri teknologioita ja arvioi niiden vaikutuksia suorituskykyyn, kuvanlaatuun ja laitteistovaatimukseen. Lisäksi pohditaan DLSS:n tekoälyrenderöinnin tulevaisuutta ja sen mahdollisia kehityssuuntia sekä sitä, voisiko se mahdollisesti korvata perinteiset renderöintimenetelmät kokonaan.

1.1 Tutkielman tausta ja motivaatio

Työn pohjana tarkastellaan tietokonegrafiikan huimaa kehitystä viime vuosikymmeninä, erityisesti peliteollisuuden saralla. Kuvan renderöinnin laskennalliset vaatimukset ovat kasvaneet merkittävästi, koska kuluttajat käyttävät yhä suurempia resoluutioita, kehittyneempiä valaistuksen mallinnuksia sekä säteenseurantaa. Käyttäjät eli esimerkiksi pelaajat odottavat saavansa yhä parempaa visuaalista tarkkuutta sekä korkeampaa kuvataajuutta (FPS). Tämä pakottaa laitteistovalmistajat kehittämään uusia tapoja tasapainottaa kuvanlaatu ja suorituskyky.

Perinteisesti renderöintimenetelmissä on käytetty erilaisia reunanpehmennys- ja ylinäytteistys-tekniikoita, joiden tavoitteena on poistaa renderöinnin aiheuttamia artefakteja ja parantaa siten kuvanlaatua. Perinteiset menetelmät ovat kuitenkin laskennallisesti raskaita ja voivat heikentää suorituskykyä huomattavasti erityisesti korkeilla resoluutioilla. Tämä on johtanut tarpeeseen kehittää kevyempiä ja älykkäämpiä tapoja parantaa kuvanlaatua ilman merkittävää suorituskykyheikennystä.

Tekoälypohjaiset menetelmät, kuten neuroverkkoihin perustuvat ylinäytteistys- ja kuvankorjaustekniikat, ovat nousseet merkittäväksi ratkaisuksi tähän ongelmaan. Esimerkiksi NVIDIA:n DLSS (Deep Learning Super Sampling) hyödyntää koneoppimista ja syväoppimisen malleja skaalaamaan kuvia tehokkaasti ja parantamaan niiden laatua säilyttäen samalla korkean suorituskyvyn. Tutkielmassa perehdytään tekoälyavusteiseen renderöintiin erityisesti videopelimaailman näkökulmasta.

1.2 Tutkimuskysymykset, tavoitteet ja rajaukset

Tutkielman tavoitteena on tarkastella tekoälyn roolia nykyaikaisessa tietokonegrafiikassa, erityisesti resoluution skaalaamiseen ja kuvanlaadun parantamiseen liittyvien menetelmien näkökulmasta. Tutkielma keskittyy NVIDIA:n kehittämään Deep Learning Super Sampling -teknologiaan (DLSS) ja sen käyttöön osana renderöintiprosessia. DLSS toimii esimerkkinä siitä, kuinka syväoppimiseen perustuva laskenta voi parantaa visuaalista laatua ja suorituskykyä yhtä aikaa.

Tutkielma pyrkii vastaamaan seuraaviin kysymyksiin: Miten tekoälypohjaiset renderöintimenetelmät, erityisesti DLSS, toimivat ja miten ne eroavat muista käytössä olevista skaalaustekniikoista tietokonegrafiikassa? Miten DLSS vaikuttaa renderöinnin kuvanlaatuun ja suorituskykyyn? Sekä millainen on tekoälyavusteisen renderöinnin tulevaisuus ja voiko tekoäly korvata perinteiset menetelmät?

Tutkielma on suunnattu ensisijaisesti akateemiselle yleisölle, koska se on kandidaatin tutkielma osana opintoja. Tutkielman sisältö on hyödyllinen teknisesti suuntautuneille lukijoille, opiskelijoille tai alan harrastajille, jotka ovat kiinnostuneet pelaamisesta, näyttönohjaimista, grafiikasta sekä tekoälyn soveltamisesta. Tavoitteena on tarjota ymmärrettävä ja syvällinen kokonaiskuva siitä, millä tavoin tekoälyä voidaan hyödyntää renderöintitehtävissä ja miten nämä ratkaisut vaikuttavat graafiseen lopputulokseen.

Tutkielma rajataan käsittelemään tekoälyn ja syväoppimisen soveltamista nimenomaan videopeligrafiikan kontekstissa. Työssä ei syvennytä laajasti tekoälyn tai koneoppimisen

teoreettisiin perusteisiin, vaan näitä käsitellään vain siltä osin kuin ne tukevat teknologian ymmärtämistä grafiikkaprosessin ja DLSS:n näkökulmasta. Tutkielmassa ei myöskään tarkastella yksityiskohtaisesti grafiikkaprosessorin eli GPU:n sisäistä rakennetta tai toimintaperiaatteita, sillä se vaatisi laajemman teknisen käsittelyn. Lisäksi muut tietokonegrafiikan laajat osa-alueet jäävät työn ulkopuolelle. Näihin voidaan viitata taustatiedon yhteydessä, mutta varsinainen tarkastelu keskittyy nimenomaan videopelien graafiseen renderöintiin ja siihen liittyviin tekoälyratkaisuihin.

1.3 Tutkielman rakenne

Tutkielma rakentuu seitsemästä pääluvusta, jotka etenevät johdonmukaisesti tietokonegrafiikan perusteista kohti tekoälyavusteisten skaalausmenetelmien, erityisesti DLSS:n syvällistä tarkastelua. Kokonaisuuden tavoitteena on hahmottaa, miten tekoälyä hyödynnetään graafisen kuvanlaadun parantamisessa ja mitä etuja sekä haasteita siihen liittyy verrattuna perinteisiin ratkaisuihin.

Aluksi johdantoluvussa esitellään työn tausta, tutkimuskysymykset ja tavoitteet. Samalla rajataan käsiteltävä aihepiiri siten, että painopiste säilyy nimenomaan tekoälyn hyödyntämisessä visuaalisen laadun ja suorituskyvyn parantamisessa peleissä ja tietokonegrafiikassa.

Toisessa luvussa käydään läpi tietokonegrafiikan peruskäsitteistöä ja tarkastellaan yleisellä tasolla näytönohjaimen ja grafiikkaprosessorin roolia kuvien tuottamisessa. Tämä muodostaa teknisen pohjan, johon myöhemmät luvut nojaavat.

Kolmannessa luvussa tarkastellaan videopeligrafiikan renderöintiputken keskeisiä osa-alueita. Siinä käsitellään muun muassa kärkipistevarjostusta (vertex shading), rasterointia, fragmenttivarjostusta (fragment shading), syvyystiedon hallintaa syvyyspuskurin (Z-buffer) avulla sekä reunanpehmennyksen ja ylinäytteistyksen merkitystä kuvanlaadun kannalta. Tämä osuus on keskeinen ymmärtääkseen, miksi skaalaustekniikoita ylipäätään tarvitaan.

Tekoälyn roolia tarkastellaan neljännessä luvussa. Siinä perehdytään tekoälypohjaisiin renderöintimenetelmiin, generatiivisiin malleihin sekä syväoppimisen hyödyntämiseen kuvanparannuksessa. Luvun tavoitteena on antaa lukijalle käsitys siitä, millaista teknologiaa DLSS ja muut vastaavat menetelmät hyödyntävät.

Viidennessä luvussa siirrytään tutkielman keskeiseen tutkimuskohteeseen, DLSS-teknologiaan ja sen haastajiin. Luvussa esitellään ensin DLSS:n toimintaperiaate, minkä jälkeen sitä verrataan kilpaileviin menetelmiin, kuten AMD:n FSR:ään ja Intelin XeSS:ään. Vertailussa arvioidaan DLSS:n vahvuuksia ja rajoituksia suhteessa muihin ratkaisuihin.

Kuudennessa luvussa luodaan katsaus tekoälyrenderöinnin tulevaisuudennäkymiin ja sen vaikutuksiin peliteollisuudessa. Luvun keskeisenä tavoitteena on arvioida DLSS:n potentiaalia ja vastata tutkimuskysymykseen: voiko se korvata perinteiset renderöintimenetelmät?

Tutkielman lopuksi esitetään johtopäätökset, joissa kootaan yhteen keskeisimmät havainnot ja pohditaan mahdollista jatkotutkimuksen aihetta. Työ muodostaa kokonaiskuvan siitä, miten tekoälyteknologiat, kuten DLSS, vaikuttavat renderöintimenetelmien nykytilaan ja tulevaisuuteen.

2 Tietokonegrafiikan perusteet

Tietokonegrafiikka on tieteenala ja käytännön menetelmä, jonka tarkoituksena on tuottaa ja käsitellä visuaalista informaatiota tietokoneen avulla Hughes ja muut (2014). He määrittelevät tietokonegrafiikan monitieteiseksi alaksi, jossa yhdistyvät muun muassa fysiikka, matematiikka, ihmisen havaintokyky, käyttöliittymien suunnittelu, tekninen toteutus, graafinen suunnittelu ja taide. Visuaalisuus on tietokonegrafiikassa keskeistä, sillä sen tavoitteena on viestiä informaatiota tehokkaasti käyttäjälle (Hughes ja muut, 2014). Ihmisen visuaalinen havaintojärjestelmä vaikuttaa ratkaisevasti siihen, kuinka tietokonegrafiikan sovelluksia suunnitellaan ja toteutetaan. Sen perusteella tarpeeton informaatio voidaan jättää pois ja keskittyä vain havaittavaan ja merkitykselliseen sisältöön (Hughes ja muut, 2014).

2.1 Mitä on tietokonegrafiikka?

Hughes ja muut (2014) kuvaavat, että tietokonegrafiikka käsittelee yleensä kolmiulotteisen kohtauksen mallia, johon kuuluvat geometriset muodot ja niiden ominaisuudet sekä valon ominaisuudet ja sen vuorovaikutukset kohtauksessa olevien objektien kanssa. Heidän mukaansa kohtauksen mallintaminen sisältää geometrinen objektien lisäksi myös valon lähteiden ominaisuuksien määrittämisen. Mallinnuksen tavoitteena on siis tuottaa tietokoneavusteisesti realistinen tai muuten informatiivinen näkymä kyseisestä kohtauksesta. Tämä näkymä syntyy laskennallisesti mallintamalla valon kulkua, heijastuksia ja muita fysikaalisia ilmiöitä realistisesti tai tiettyjen tarpeiden mukaan yksinkertaistettuna (Hughes ja muut, 2014). Tietokonegrafiikan avulla voidaan luoda sekä fotorealistic kuvia että abstrakteja visualisointeja tavoitteen ja sovellusalueen mukaan (Hughes ja muut, 2014).

Tietokonegrafiikkaa voidaan pitää myös eräänlaisena ”yleistettynä kertolaskuna”, jossa valon ja objektien vuorovaikutusten simulointi perustuu valon määrän kertolaskutoimituksiin pintojen heijastavien ominaisuuksien kanssa (Hughes ja muut, 2014). Tämä kuvaus tarjoaa lähtökohdan ymmärtää perusprosessia tietokonegrafiikan ytimessä.

Tietokonegrafiikka ei kuitenkaan rajoitu pelkkään realistiseen kuvantamiseen. Hughes ja muut (2014) korostavat, että monet nykyaikaiset käyttökohteet tietokonegrafiikalle, kuten pelit, käyttöliittymät, virtuaalitodellisuussovellukset ja tieteelliset visualisoinnit, hyödyntävät erilaisia lähestymistapoja, joissa realismi ei ole aina se keskeisin tavoite. Sen sijaan voidaan tavoitella esimerkiksi selkeyttä, tyyliä esitystapaa tai vuorovaikutteisuutta. Tämä korostaa tietokonegrafiikan monipuolisuutta ja sitä, kuinka tärkeää on valita oikeat menetelmät halutun lopputuloksen saavuttamiseksi (Hughes ja muut, 2014). Tässä tutkielmassa aihe rajautuu tietokonegrafiikan osalta videopeligrafiikkaan, jossa realismi on usein hyvinkin tavoiteltava asia.

2.2 Näytönohjaimen rooli tietokonegrafiikassa

Tässä osiossa tarkastellaan lyhyesti näytönohjaimen eli grafiikkaprosessorin (GPU) roolia osana tietokonegrafiikkaa. Näkökulma pidetään yleistasoisena, ja käsittely keskittyy vain sen keskeisiin toimintoihin, jotka liittyvät renderöintiin ja grafiikkaputken päävaiheisiin. Tavoitteena on tarjota riittävä pohja siihen, miten nykyaikaiset näytönohjaimet mahdollistavat vaativien visuaalisten efektien, kuten tekoälyavusteisen skaalaamisen, tehokkaan suorittamisen.

Näytönohjain eli grafiikkakortti vastaa siitä, että näytöllä näkyvät pikselit piirretään oikeaan värisinä, oikeaan aikaan ja oikeaan paikkaan. Tämä tapahtuu millisekunnissa ja vaatii valtavan määrän rinnakkaisia laskutoimituksia, jotka hoitaa grafiikkaprosessori (GPU) (Basics Explained, H3Vtux, 2020). Näytönohjain toimii ikään kuin omana tietokoneenaan, joka on suunniteltu nimenomaan visuaalisen informaation tuottamiseen ja esittämiseen (Basics Explained, H3Vtux, 2020).

GPU on näytönohjaimen sisällä oleva erikoistunut suoritin, joka eroaa tietokoneen keskussuorittimesta (CPU) erityisesti siinä, että se sisältää tuhansia pieniä ytimiä. Siinä missä CPU suorittaa monimutkaisia loogisia operaatioita tehokkaasti vain muutamalla ytimellä,

GPU suorittaa valtavan määrän yksinkertaisia laskutoimituksia rinnakkain. Juuri tätä tarvitaan kolmiulotteisen maailman esittämiseen ruudulla (Basics Explained, H3Vtux, 2020).

Renderöintiprosessin aikana grafiikkakortti hyödyntää vektorigrafiikkaa. Esineet ja muodot esitetään kolmiulotteisessa koordinaatistossa pisteinä ja näiden välisinä viivoina. Näiden laskeminen ja piirtäminen perustuu geometriseen matematiikkaan ja suureen määrään yksinkertaisia laskuja, jotka GPU:n rinnakkaisytimet voivat suorittaa tehokkaasti (Basics Explained, H3Vtux, 2020). Tähän perehdytään tarkemmin osiossa kolme, jossa käydään läpi grafiikkaputken keskeisiä osa-alueita.

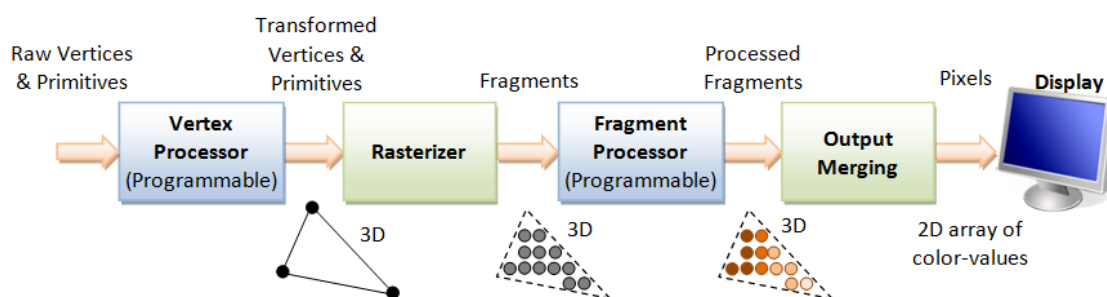
Näytönohjaimessa on lisäksi oma muisti, joka tunnetaan nimellä VRAM (Video Random Access Memory). Se toimii samalla tavalla kuin tietokoneen päämuisti, mutta on optimoitu graafisten tietojen, kuten tekstuurien ja väliaikaisten kuvien tallentamiseen ja siirtämiseen nopeasti GPU:lle. Tämän avulla vältetään viiveitä ja varmistetaan visuaalisesti sulava lopputulos (Basics Explained, H3Vtux, 2020).

Yhteenvetona voidaan todeta, että GPU:n tuhannet rinnakkaiset ytimet, erillinen muisti ja graafiseen laskentaan optimoitu rakenne tekevät siitä keskeisen osan nykyaikaista tietokonegrafiikkaa ja renderöintiä (Basics Explained, H3Vtux, 2020). Nämä ominaisuudet ovat perusta tekoälypohjaisten ratkaisujen, kuten DLSS:n tehokkaalle toiminnalle.

3 Videopeligrfiikan ja renderöinnin keskeiset osa-alueet

Renderöinnillä tarkoitetaan prosessia, jossa syötetystä datasta, kuten geometrisista objekteista tai laskennallisista tuloksista, muodostetaan konkreettinen kuva (Chen, 2010). Se on keskeinen osa tietokonegrafiikkaa, jossa kolmiulotteinen (3D) malli muunnetaan kaksiulotteiseksi (2D) kuvaksi näytölle. Chenin (2010) mukaan renderöinnin tehtävänä on kuvata tietokoneen kykyä piirtää lopullinen kuva näkyvistä asioista, kuten muodoista, väreistä, valaistuksesta, varjoista ja tekstuureista käyttäjän antaman mallin ja siihen sisältyvän tiedon pohjalta. Hän kuvailee renderöintiä ”taikakynäksi”, jota liikutetaan ohjelmallisesti siten, että jokainen pikseli saa oikean värinsä.

Renderöinti on erityisen tärkeässä roolissa nykyaikaisissa videopeleissä, joiden visuaalinen laatu on kehittynyt merkittävästi viime vuosikymmeninä. Branch Educationin (2023) mukaan tällaiset pelimaailmat koostuvat miljoonista kolmiulotteisista pisteistä, väreistä ja tekstuureista, jotka ovat pohjimmiltaan pelkkiä ykkösiä ja nollia. Tämän bittidatan muuttaminen näytöllä näkyväksi grafiikaksi tapahtuu niin kutsutun renderöintiputken avulla (Kuva 1). Branch Educationin (2023) mukaan videopeligrfiikan renderöintiprosessi koostuu kolmesta keskeisestä päävaiheesta: vertex shading (kärkipisteiden varjostus), rasterointi ja fragment shading (fragmenttien varjostus). Nämä kolme vaihetta ovat olleet hänen mukaansa käytössä jo vuosikymmenten ajan tuhansissa eri videopeleissä sekä tietokoneilla että konsoleilla.



Kuva 1. Renderöintiputken vaiheet (Mengistu, 2023)

3.1 Vertex Shading

Branch Educationin (2023) mukaan grafiikkaputken ensimmäinen vaihe on kärkipisteiden varjostus (vertex shading), jossa pelimaailman objektien kärkipisteet muunnetaan kolmiulotteisesta tilasta kohti kaksiulotteista näkymää. Tämä muunnos tapahtuu kolmessa matriisilaskentaan perustuvassa vaiheessa: mallin siirto mallitilasta maailmatilaan, sieltä kameratilaan ja lopuksi näyttötilaan. Branch Educationin (2023) on nostanut esimerkiksi Red Dead Redemption 2 -pelin junakohtauksen, jossa pelimoottori renderöi 600 näkyvissä olevaa objektia, jotka koostuvat yhteensä 3,5 miljoonasta kolmiosta. Pelkäs-tään esimerkiksi otettu veturimalli rakentuu 762 000 kolmiosta ja 382 000 kärkipisteestä, joille on määritelty yhdeksän erilaista materiaalia (Branch Education, 2023).

Kunkin kärkipisteen sijainti määritetään matemaattisesti, käyttäen muun muassa objek-tin skaalausta, sijaintia ja rotaatiota. Nämä arvot yhdistetään matriisilaskennan avulla, jonka lopputuloksena saadaan kolmiulotteisen kärkipisteen paikka näytöllä, mukaan lu-kien sen syvyysarvo eli Z-arvo (Branch Education, 2023).

3.2 Rasterointi

Kun kärkipisteet on muunnettu ruudulle, seuraa rasterointi. Tässä vaiheessa selvitetään, mitkä pikselit kuuluvat mihinkin kolmioon. 4K-resoluutiolla tämä tarkoittaa 8,3 miljoon-pikselin käsittelyä jokaisessa ruudussa. Näytönohjain laskee kolmioiden X- ja Y-koor-dinaattien perusteella, mitkä pikselit kuuluvat kolmiolle. Tämän jälkeen kullakin pikselillä käytetään kolmiolle määriteltyä väriä tai tekstuuria (Branch Education, 2023). Rasteroin-nin seurauksena syntyy niin kutsuttuja fragmentteja, eli pikseliryhmiä, jotka jakavat yh-dessä samat visuaaliset ominaisuudet (Branch Education, 2023).

3.3 Fragment Shading

Fragmenttien varjostus (fragment shading) on renderöintiputken kolmas vaihe, jossa määritetään lopullinen väri jokaiselle pikselille. Pikselien värittämisessä ei ainoastaan

riitä, että ne sijoitetaan rasteroinnin määrittämään kolmioon. Realistisen lopputuloksen saavuttamiseksi tarvitaan laskentaa, joka ottaa huomioon myös valon suunnan ja voimakkuuden, kameran sijainnin sekä varjojen ja heijastusten vaikutukset (Branch Education, 2023).

Fragmentit muodostuvat rasteroiduista kolmioista ja ne voivat jakaa saman tekstuurin tai värin. Pelkkä väri ei kuitenkaan riitä, sillä esimerkiksi kiiltävän musta metallipinta näyttää hyvin erilaiselta varjossa kuin suorassa auringonvalossa. Fragment shading -vaiheessa pikseleille lasketaan valaistusolosuhteiden perusteella tarkka sävy ja kirkkaus, mikä tekee kuvasta kolmiulotteisen ja luonnollisen näköisen (Branch Education, 2023).

Valon vaikutusta pinnan väriin arvioidaan vertaamalla valon suuntaa kolmion pinta-normaalini suuntaan. Mitä suurempaan valo osuu pintaan, sitä kirkkaampi siitä tulee. Laskennassa käytetään kulman kosinifunktiota, ja tulos kerrotaan valon voimakkuudella sekä pinnan värillä. Näin saadaan jokaiselle kolmion osalle realistinen sävy (Branch Education, 2023).

Jos kolmion pinta ei osoita kohti valoa, sen ei haluta näyttävän täysin mustalta. Tämän estämiseksi lisätään ympäristövalaistus, joka simuloi hajavaloa ja pehmentää varjoja. Kun kohtauksessa on useita valonlähteitä, jokaisen vaikutus lasketaan erikseen ja summataan. Tämä parantaa huomattavasti visuaalista laatua, mutta lisää siitä aiheutuvaa laskentaa (Branch Education, 2023).

Flat shading -menetelmä antaa kolmiolle tasaisen valaistuksen, mikä saa pinnat näyttämään kulmikkailta. Realistisempi lopputulos saavutetaan smooth shading -menetelmällä, jossa pinnan valaistus vaihtelee sujuvasti pikselikohtaisesti kolmen kärkipisteen normaalin perusteella. Tämä tekee esimerkiksi kaarevista muodoista luonnollisemman näköisiä (Branch Education, 2023).

3.4 Z-buffer ja syvyysvertailu

Branch Education (2023) kertoo Z-bufferin olevan ratkaisu näkyvyysongelmaan, jossa useat kolmiot voivat sijaita päällekkäin. Jotta saadaan selville, mikä pinta näkyy ja mikä jää taakse, jokaiselle pikselille lasketaan etäisyys. Tätä etäisyyttä kutsutaan Z-arvoksi, ja se tallennetaan erilliseen Z-bufferiin. Kun uusi kolmio rasteroidaan, sen Z-arvo verrataan Z-bufferin arvoon kyseisessä pikselissä (Branch Education, 2023).

Jos uuden kolmion Z-arvo on pienempi eli lähempänä kameraa, sen väri piirretään ruutuun ja tämä johtaa siihen, että Z-buffer päivitetään. Jos kolmio on kauempana kuin jo näkyvä pinta, se hylätään, eikä sitä täten piirretä ollenkaan. Tällä tavalla ruudulle jää näkyviin vain ne pinnat, jotka ovat katsojaa lähimpänä (Branch Education, 2023).

Koska kolmiot ovat kolmiulotteisia, niillä on usein kolme erilaista Z-arvoa eli yksi jokaiselle kärkipisteelle. Tämän vuoksi jokaisen pikselin Z-arvo interpoloidaan näiden kolmen pisteen perusteella. Interpolointi tarkoittaa sitä, että kolmion kärkipisteiden välille laskeetaan arvoja. Tämän ansiosta kolmiot voivat leikkautua keskenään realistisesti ja niiden leikkauspisteet renderöidään oikein (Branch Education, 2023). Kiteytetysti Z-bufferin avulla pelimoottorit voivat siis hallita tehokkaasti, mitä näkyy missäkin kohtaa kuvaa. Tämä visuaalinen syvyystieto on tärkeää myös esimerkiksi valon käyttäytymisen ja varjojen laskennan kannalta (Branch Education, 2023).

3.5 Anti-aliasing ja supersampling

Viimeisessä kappaleessa liittyen videopeligrafiikan ja renderöinnin keskeisiin osa-alueisiin on tärkeää avata, mitä tarkoittavat reunanpehmennys (anti-aliasing) ja sen alalaji ylinäytteistys (supersampling). Nämä ovat tutkielmani kannalta erittäin tärkeässä asemassa, koska NVIDIA:n DLSS on tekoälyavusteinen supersampling kuvanparannustekniikka.

Roach (2024) ja Rohner (n.d.) kertovat aliasingin olevan ilmiö, jossa digitaalisessa kuvassa näkyy sahalaitaisia, epäluonnollisen teräviä reunoja silloin, kun viivat tai muodot kulkevat vinosti pikseliruudukossa. Tämä johtuu siitä, että yksittäinen pikseli voi näyttää vain yhden värin kerrallaan, eikä kykene ilmaisemaan sujuvaa siirtymää vinon tai kaarevan muodon yli. Tähän ratkaisuna on siis reunanpehmennys (anti-aliasing), joka pyrkii tasamaan näitä sahalaitaisia reunaviivoja (Roach, 2024).

Reunanpehmennyksen toteuttamiseen on useita eri tekniikoita, jotka jakautuvat kahteen päätyyppiin. Ensimmäinen lähestymistapa Roachin (2024) mukaan on supersampling, jossa kuva renderöidään aluksi korkeammalla resoluutiolla ja skaalataan sitten pienemmäksi. Toinen puolestaan perustuu algoritmiseen päättelyyn, jossa lähellä olevia pikseleitä vertaillaan ja arvioidaan, miten reunoja tulisi pehmentää (Roach, 2024).

Tarkemmin tarkasteltuna SSAA on näistä menetelmistä yksinkertaisin, mutta laskennallisesti raskain. SSAA:ssa näytönohjain renderöi kuvan sisäisesti huomattavasti suuremmalla resoluutiolla kuin mitä näyttö pystyy toistamaan, ja skaalaa sen sitten alaspäin näytön natiiviresoluutioon. Tässä prosessissa väriarvot ”keskiarvoistetaan” ja se tuottaa erittäin tarkan ja pehmeäreunaisen kuvan, mutta vaatii moninkertaisen laskentatehon (Roach, 2024; Rohner, n.d.). Tätä ongelmaa varten on kehitetty kevyempiä menetelmiä, kuten MSAA, joka soveltaa pehennystä vain objektien reunoihin eikä koko kuvaan. Tällä pyritään säästämään resursseja, jotta prosessi ei olisi niin raskas (Roach, 2024).

Nykyisessä peligrafiikassa valaistus ja varjostus ovat erittäin monimutkaisia. Tämän vuoksi pelkkä reunojen pehennys ei usein riitä. Alan standardiksi on noussut TAA eli ajallinen reunanpehmennys. Toisin kuin MSAA tai SSAA, jotka tarkastelevat vain yhtä pysäytettyä kuvaa kerrallaan, niin TAA hyödyntää useiden peräkkäisten kuvien informaatiota (Roach, 2024).

TAA vertaa nykyistä kuvaa edellisiin ruutuihin ja käyttää liikevektoreita päätelläkseen, mihin pikselit ovat siirtyneet. TAA poistaa tehokkaasti sahalaitaisuutta ja väreilyä kuvasta,

mutta menetelmällä on omat haasteensa. Koska TAA sekoittaa vanhaa kuvan dataa uuteen, se aiheuttaa usein kuvan pehmenemistä eli liikesumennusta (motion blur) sekä nopeasti liikkuvien objektien perään jääviä haamukuvia (ghosting) (Roach, 2024).

Tämä ero on tutkielman kannalta kriittinen: perinteinen TAA käyttää ajallista tietoa pelkkään pehmennykseen (Roach, 2024), kun taas myöhemmin käsiteltävä DLSS mahdollistaa saman ajallisen datan ja liikevektorit tekoälyn käytettäväksi, pyrkimyksenä rekonstruoida kuva tarkaksi ilman TAA:lle tyypillistä sumennusta (Mengistu, 2023).

4 Tekoälyn rooli tietokonegrafiikassa

Tässä osiossa tarkastellaan, miten tekoälyä hyödynnetään tietokonegrafiikassa. Tekoäly ja erityisesti syväoppiminen ovat tärkeässä asemassa nykyaikaisessa peligrafiikassa. Videopelien visuaaliset vaatimukset kasvavat entisestään, joka tarkoittaa sitä, että ne vaativat jatkuvasti entistä enemmän itse käyttäjän tietokoneelta. Laskentateho ei yksinkertaisesti kykene tuottamaan korkearesoluutioisia ja sulavia pelikuvia samanaikaisesti. Tästä syystä videopeligrafiikassa hyödynnetään yhä enemmän tekoälyä, jonka avulla voidaan esimerkiksi renderöidä pelikuva alhaisemmalla resoluutiolla ja parantaa se jälkikäteen älykkäiden algoritmien avulla (Eloy, 2024; Mengistu, 2023).

4.1 Syväoppimismenetelmät ja neuroverkkoarkkitehtuurit kuvanlaadun optimoinnissa

Aulanko-Jokirinteen (2019) mukaan tekoälyn käyttö tietokonegrafiikassa on yleistynyt erityisesti realististen pintarakenteiden ja materiaalien mallinnuksessa. Neuroverkkojen ja koneoppimisen avulla on mahdollista analysoida ja tuottaa tarkkoja tekstuureja, jotka jäljittelevät tosielämän materiaaleja. Hänen mukaansa yksi keskeinen haaste graafisen sisällön realismissa liittyy pintarakenteiden monimutkaisuuteen ja mikrotason virheisiin, jotka vaikuttavat valon käyttäytymiseen materiaalien pinnalla. Perinteisesti nämä ominaisuudet on jouduttu säätämään manuaalisesti, mutta tekoäly voi nopeuttaa ja automatisoida tätä prosessia (Aulanko-Jokirinne, 2019).

Aulanko-Jokirinne (2019) kertoo myös, että tutkimusten mukaan koneoppimista voidaan käyttää kouluttamaan algoritmeja tunnistamaan ja toistamaan materiaalien luonnollisia piirteitä. Esimerkiksi tietokone voi vertailla aidon ja digitaalisen pintarakenteen eroja, ennustaa tarvittavat muuttujat ja säätää tekstuuria vastaamaan todellista esinettä. Tämä vähentää graafikoiden tarvetta manuaaliseen hienosäätöön ja mahdollistaa todenmukaisemman lopputuloksen. Samalla tämä auttaa tehostamaan elokuva- tai pelikehityksen tuotantoprosesseja, joissa realistinen grafiikka on erityisen keskeisessä roolissa (Aulanko-Jokirinne, 2019).

Tutkielmani kannalta tärkeimpiä tekoälymenetelmiä kuvanlaadun parantamisessa ovat konvoluutioneuroverkot (CNN), generatiiviset vastakkaiset verkostot (GAN), autoenkooderit ja kohinanpoistoon liittyvät denoising-menetelmät. CNN-mallit ovat tehokkaita kuvan rakenteellisten yksityiskohtien tunnistamisessa ja parantamisessa, minkä ansiosta niitä käytetään kohinanpoistossa ja resoluution parantamisessa. GAN-verkkojen etuna on niiden kyky rekonstruoida puuttuvia tai epätarkkoja yksityiskohtia siten, että lopputulos muistuttaa uskottavasti alkuperäistä kuvaa. Autoenkooderit puolestaan tiivistävät ja palauttavat kuvatiedon mallin sisällä, mikä mahdollistaa laadukkaan ylöskaalauksen alhaisesta resoluutiosta. Nämä mainitut syväoppimiseen liittyvät mallit palvelevat erityisesti kohinan vähentämistä, resoluution kasvattamista ja kontrastin säätöä (Zangana ja muut, 2024; Mengistu, 2023).

4.2 Neuroverkkojen kouluttaminen peligrafiikassa

Neuroverkkoihin perustuvissa kuvanlaadun parantamismenetelmissä koulutus tapahtuu yleisimmin valvotun oppimisen menetelmällä, jossa mallille syötetään pareittain matalaresoluutioisia (LR) ja niiden vastaavia korkearesoluutioisia (HR) kuvia (Yang ja muut, 2019). Super-resoluutiota käsittelevässä katsauksessaan Yang ja muut (2019) korostavat, että HR-kuvat toimivat koulutuksen ground truth -referenssinä, jonka perusteella malli oppii rekonstruoimaan yksityiskohtaisempia ja laadukkaampia kuvia LR-syötteistä (Yang ja muut, 2019). Malli optimoi parametrejään vertaamalla tuottamaansa SR-ulostuloa HR-viitekuvaan ja minimoimalla näiden välistä virhettä (Yang ja muut, 2019). Optimointiprosessin seurauksena neuroverkko oppii tunnistamaan ja palauttamaan kuvasta yksityiskohtia ja rakenteita, jotka eivät ole suoraan nähtävissä matalaresoluutioisessa syötteessä (Yang ja muut, 2019).

Mengistun (2023) mukaan konvoluutioneuroverkot (CNN) ovat olennainen osa syväoppimiseen perustuvia kuvanlaadun parantamismenetelmiä. CNN-verkkojen koulutus perustuu juuri tähän aiemmin mainittuun periaatteeseen: verkolle syötetään korkearesoluutioisia referenssikuvia, ja sen tuottamia tuloksia verrataan näihin referensseihin. CNN-verkot on erityisesti suunniteltu käsittelemään visuaalista dataa, ja

ne soveltuvat hyvin esimerkiksi reunojen ja tekstuurien tunnistamiseen (Mengistu, 2023). CNN-rakenteet sisältävät syötteenä matriisimuotoista pikselidataa, jota käsitellään kerroksittain erilaisilla suodattimilla. Nämä oppivat tunnistamaan tärkeät kuvalliset yksityiskohdat (Mengistu, 2023). CNN tehtävänä tiivistetyksi on siis analysoida kuvia. Mengistun (2023) mukaan esimerkiksi DLSS 1.0 -teknologiassa hyödynnetään konvoluutiopohjaisia autoenkoodausverkkoja. Kaksivaiheisissa verkkoarkkitehtuureissa kuva ensin tiivistetään, jota kutsutaan enkoodausvaiheeksi. Tämän jälkeen se palautetaan korkearesoluutioiseksi, jota kutsutaan puolestaan dekodausvaiheeksi. Tämä on tärkeä osa visuaalisen laadun parantamista ja aliasing-artefaktien vähentämistä (Mengistu, 2023).

Mengistun (2023) mukaan erityisen tärkeää CNN-pohjaisissa järjestelmissä on, että ne kykenevät rekonstruoimaan yksityiskohtia, joita alkuperäisessä matalaresoluutioisessa kuvassa ei välttämättä ollut saatavilla. Tämä mahdollistaa pelikuvaan realistisen ja yksityiskohtaisen ilmeen ilman raskasta natiiviresoluution renderöintiä (Mengistu, 2023).

Generatiiviset vastakkaiset verkot (GAN) ovat muodostuneet yhdeksi keskeisimmistä syväoppimisen malleista tietokonegrafiikassa. Ne ovat tärkeitä erityisesti tehtävissä, joissa tarvitaan uskottavaa kuvan generointia, super-resoluutiota, kuvan täydennystä tai tyyliin perustuvaa muunnosta (Wang ja muut, 2021). Periaatteena on siis tuottaa uutta dataa. Heidän mukaansa GAN koostuu kahdesta neuroverkosta: generaattorista ja diskriminaattorista. Generaattori tuottaa keinotekoisia kuvia, kun taas diskriminaattori pyrkii erottamaan ne aidoista. Mallin koulutus on prosessi, jossa generaattori pyrkii huijaamaan diskriminaattoria, ja täten diskriminaattori oppii paremmaksi (Wang ja muut, 2021).

GAN-mallien erityinen vahvuus verrattuna muihin generatiivisiin malleihin, kuten variational autoencodereihin (VAE), on kyky luoda visuaalisesti tarkkoja, teräviä ja uskottavia kuvia ilman ennalta määrättyjä rajoitteita (Wang ja muut, 2021). Tämän vuoksi GAN-malleja hyödynnetään esimerkiksi image-to-image-tilanteissa, joissa syötetään

esimerkiksi matalaresoluutioinen tai osittain puuttuva kuva ja saadaan generoitua siitä täydentynyt versio (Wang ja muut, 2021).

Koulutusdatan laatu ja monipuolisuus ovat ratkaisevia neuroverkkojen onnistuneelle soveltamiselle peligrafiikassa. Yang ja muut (2019) korostavat, että monipuoliset HR-esimerkit parantavat mallien kykyä yleistää ja vähentävät artefaktien syntymistä super-resoluutiossa. Yhteenvetona voidaan todeta, että neuroverkkojen kouluttaminen peligrafiikassa perustuu korkealaatuisten referenssikuvien hyödyntämiseen ja iteratiiviseen optimointiin, jossa verkko oppii tuottamaan tarkempia ja realistisempia kuvia. Tämän koulutusmenetelmän periaatteet muodostavat pohjan DLSS:n kaltaisille teknologioille, johon tutustutaan seuraavassa osiossa.

5 NVIDIA DLSS vs. muut menetelmät

Tässä luvussa perehdytään NVIDIA DLSS -teknologian (Deep Learning Super Sampling) toimintaperiaatteisiin ja sen kehityskaaren merkittävimpiin vaiheisiin varhaisesta 1.0-versiosta uusimpaan 4.0-versioon. Tarkastelun keskiössä on, kuinka tekoälypohjainen kuvan rekonstruktio ja generointi ovat muuttaneet renderöintiä suhteessa perinteisiin menetelmiin, kuten natiiviresoluutioon ja erilaisiin reunojenpehmennystekniikoihin. Lisäksi luvun lopussa vertaillaan DLSS:n teknisiä ratkaisuja ja markkina-asemaa sen pääkilpailijoiden, AMD:n FSR:n ja Intelin XeSS:n, vastaaviin menetelmiin.

5.1 Mikä on NVIDIA DLSS?

NVIDIA DLSS on GeForce RTX -näytönohjaimien Tensor-ytimillä toimiva renderöintitekniologioiden kokonaisuus, jonka tehtävänä on parantaa suorituskykyä ja tuottaa korkean laadun kuvia (NVIDIA, n.d.). Uusin versio NVIDIA DLSS 4 tuo mukanaan uuden Multi Frame Generation -ominaisuuden, jonka avulla tekoäly pystyy luomaan jopa kolme lisäruutua jokaista renderöityä ruutua kohti. Tämä mahdollistaa suorituskyvyn kahdeksankertaistamisen perinteiseen renderöintiin verrattuna samalla, kun NVIDIA Reflex varmistaa järjestelmän reagoivuuden (NVIDIA, n.d.).


NVIDIA:n (n.d.) mukaan DLSS-ominaisuudet voidaan jakaa viiteen tekoälyä hyödyntävään teknologiaan. Uusin näistä on DLSS Multi Frame Generation, joka nopeuttaa ruudunpäivitystä generoimalla tekoälyn avulla jopa kolme uutta väliruutua kutakin renderöityä ruutua kohden. Tätä edeltävä DLSS Frame Generation parantaa suorituskykyä luomalla yksittäisiä väliruutuja ja ylläpitämällä samalla hyvää vasteaikaa NVIDIA Reflex -teknologian avulla. Kolmantena teknologiana on DLSS Ray Reconstruction, joka tehostaa säteenseurannan kuvanlaatua. Se korvaa perinteiset, käsin säädetyt kohinanpoistajat (denoisers) tekoälyverkolla, joka generoi laadukkaita pikseleitä säteiden väliin. DLSS Super Resolution puolestaan nostaa suorituskykyä skaalaamalla matalaresoluutioisen syötekuvan korkeampaan tarkkuuteen hyödyntäen liikedataa ja aiempien ruutujen informaatiota. Viimeisenä mainittu Deep Learning Anti-Aliasing (DLAA) pohjautuu samaan

teknologiaan kuin Super Resolution, mutta sitä käytetään natiiviresoluutiolla kuvanlaadun ja reunanpehmennyksen parantamiseen ilman skaalausta (Eloy, 2024; NVIDIA, n.d.).

5.1.1 DLSS 1.0

DLSS 1.0 on DLSS:n yksinkertaisin ja varhaisin versio. Se on ensisijaisesti kuvan skaalaaja, joka hyödyntää skaalaamisessa aiemmin mainittua konvoluutioon perustuvaa autoenkooderineuroverkkoa (Mengistu, 2023). Hänen mukaansa tämän version päätehtävänä oli siis kasvattaa matalamman resoluution kuvien laatua korkeammalle tasolle säilyttäen mahdollisimman paljon yksityiskohtia.

Mengistun (2023) mukaan konvoluutioautoenkooderi koostuu kerroksista, jossa yksittäiset solmut suorittavat matemaattisia operaatioita syötteelle (Kuva 2). Hänen mukaansa verkko sisältää syötekerroksen, useita konvoluutiokerroksia sekä ulostulokerroksen. Näiden kerrosten avulla se pystyy käsittelemään kuvadataa siten, että kuvien sisältämä rakenteellinen ja paikallinen informaatio säilyy (Mengistu, 2023).



Kuva 2. Konvoluutioautoenkooderin kerrokset (Mengistu, 2023)

Mengistu (2023) mainitsee DLSS 1.0:n koulutuksen tapahtuneen kahdessa vaiheessa: ensin supertietokoneilla verkkoa koulutettiin syöttämällä sille korkearesoluutioisia kuvia ja toiseksi optimoitiin sen suodattimet, jotta se oppisi rekonstruoimaan alkuperäisen

tarkkuuden mahdollisimman hyvin. Mengistun (2023) mukaan varsinaisen käytön aikana tietokone käytti jo koulutettua mallia skaalaamaan matalaresoluutiosta kuvadataa reaaliaikaisesti.

Mengistu (2023) kertoo DLSS 1.0:n merkittävimpiä heikkouksia olleen, että verkkomallia koulutettiin aina pelikohtaisesti. Uudet pelit vaativat aina erillistä koulutusta, joka johti esimerkiksi siihen, että pelaajat joutuivat päivittää jatkuvasti ajureitaan saadakseen DLSS-tuen uuteen peliin. Lisäksi DLSS 1.0 perustui vain yhteen matalan resoluution kuvaan ja liikevektoreihin ilman ajallista tietoa edellisistä ruuduista. Tämä johti siihen, että sen tuli "arvata" kadonnutta tietoa. Mengistun (2023) mukaan tämä aiheutti visuaalisia ongelmia, kuten epätarkkuutta ja keinotekoisia näköisiä yksityiskohtia. Vaikka DLSS 1.0 paransi suorituskykyä ja teki peleistä helpommin pelattavia, sen kuvanlaadulliset ongelmat olivat todella haasteellisia. Erityisesti nopeiden pelitilanteiden häiritsevät visuaaliset artefaktit olivat todella ongelmallisia (Mengistu, 2023).

5.1.2 DLSS 2.0

Siirryttäessä DLSS 2.0 versioon pyrittiin parantamaan sitä muokkaamalla aiempia lähestymistapoja sekä lisäämällä myös uusia. Mengistun (2023) mukaan ensimmäisenä keskeisenä erona on se, että DLSS 2.0 hyödyntää useampia tietolähteitä verrattuna aiempaan. Tässä tieto ei perustu pelkästään nykyiseen ruutuun ja liikevektoreihin, jota käsiteltiin DLSS 1.0 kohdalla. Mengistu (2023) ja Xiao ja muut (2020) kertovat DLSS 2.0:n ja vastaavien menetelmien sisältävän ajallista tietoa, kuten useita ruutuja ja syvyyskarttoja. Tämän lisäksi DLSS 2.0 ottaa huomioon myös valotustiedot ja kirkkaustason pelikohtauksesta (Mengistu, 2023).

Mengistun (2023) mukaan toinen merkittävä uudistus oli se, että DLSS 2.0 on täysin yleistetty malli. Tämä tarkoittaa sitä, että neuroverkko voi tuottaa korkealaatuisia kuvia peleissä ilman, että mallia täytyy kouluttaa eri peleihin erikseen. Tämä muutos sai aikaan sen, että DLSS teknologiaa oli helpompi soveltaa eri peleihin, eikä pelinkehittäjien tarvinnut aina odottaa NVIDIA:n suorittamaa koulutusprosessia (Mengistu 2023).

Kolmas ja merkittävin uudistus DLSS 2.0 kohdalla oli sen super-resoluutio. Siinä neuroverkkoa koulutetaan käyttämään edellisten ruutujen ajallista tietoa nykyisen kuvan lisäksi. Kun verkko saa syötteekseen edellisten matalan resoluution ruutujen tietoa, se pystyy palauttamaan paremmin puuttuvia yksityiskohtia. Tällä pyritään välttämään virheellisiä ja keinotekoisia ilmestymiä ruudulla, joita aiemmassa DLSS 1.0 versiossa oli (Mengistu, 2023).

DLSS 2.0 hyödyntää myös lisäksi syväoppimista reunojen pehmennykseen. Tämä tunnetaan nimellä Deep Learning Anti-Aliasing (DLAA). Mengistun (2023) mukaan reunojen pehmenys eli anti-aliasing pyrkii vähentämään kaarevien muotojen aiheuttamia sahalaitaisia reunoja. Hän kertoo myös, että DLAA:n tehtävänä on hyödyntää neuroverkon kykyä oppia kuvien rakenteita, joiden perusteella se arvioi miltä reunat näyttäisivät matalamman resoluution kuvissa. Mengistu (2023) mainitsee tämän olevan mahdollista, koska verkkoa on koulutettu huomattavasti korkeamman resoluution kuvilla. Anti-aliasing-prosessi tapahtuu osana DLSS 2.0 skaalausprosessia, jossa se tasoittaa reunoja samanaikaisesti.

5.1.3 DLSS 3.0

DLSS 3.0 paransi edeltävään versiota ottamalla käyttöön uuden tekniikan nimeltä Optical flow frame generation. Mengistun (2023) mukaan tämä menetelmä perustuu siihen, että tekoäly luo kahden ”oikean ruudun” väliin yhden väliruudun, jolla se pyrkii yhdistämään nämä kaksi alkuperäistä ruutua yhteen sulavasti. Mengistu (2023) kertoo, että tämän ansiosta on pystytty saamaan huomattavasti parempia ruudunpäivitysnopeuksia peleissä, mutta latenssi eli viive pelaajan toiminnan ja näytöllä tapahtuvien asioiden välillä on silti kasvanut.


Optical flow -menetelmä hyödyntää kahta peräkkäistä ruutua ja liikevektoreita, kuten myös DLSS 2.0, mutta tämän lisäksi se hyödyntää optical flow field -dataa. Kyseinen data tarkoittaa pikselien tallennettua liike- ja suuntatietoa niiden siirtyessä ruudusta toiseen. Liikevektorit tulevat pelimoottorista, kun taas optical flow -data tulee suoraan

renderöidyistä pikseleistä. DLSS 3 yhdistää nämä molemmat menetelmät parantaakseen liikkeen esitystä sekä kolmannen ruudun ennustamista (Mengistu, 2023). Tämä uudistus on DLSS:n kannalta todella tärkeä, koska ilman optical flow -dataa liikevektorit voivat johtaa visuaalisiin virheisiin, kuten esimerkiksi niin sanottuihin haamukuviin.

Mengistu (2023) mainitsee NVIDIA Reflex-tekniikan tulleen kompensoimaan ruutugeneroinnin aiheuttamaa viivettä. Reflexin tehtävänä on tarjota pelinkehittäjille ohjelmistokehityspaketin, jonka avulla prosessorin (CPU) ja näytönohjaimen (GPU) välinen synkronointi voidaan optimoida paremmaksi (Mengistu, 2023). Reflexin tavoitteena on vähentää ennakkoon tuotettujen ruutujen määrää, jotka odottavat pääsyä CPU:lta GPU:n renderöintiin. Tällöin GPU ei muodostu pullonkaulaksi ja käyttäjä voi hyötyä DLSS 3.0 tuomasta suorituskykyparannuksesta entistä enemmän (Mengistu, 2023).

5.1.4 DLSS 4.0

DLSS 4.0 on uusin saatavilla oleva versio DLSS:stä. DLSS 4 tarjoaa merkittäviä parannuksia suorituskykyyn ja kuvanlaatuun erityisesti uusilla GeForce RTX 50 -sarjan näytönohjaimilla (Lin & Burnes, 2025). DLSS 4:n keskeisin uudistus on Multi Frame Generation, josta kappaleessa 5.1 jo mainittiin. Linin ja Burnesin (2025) mukaan Multi-Frame Generation -tekniikka voi tuottaa jopa kolme lisäruutua jokaista perinteisesti renderöityä ruutua kohden. Heidän mukaansa RTX 5090 -näytönohjaimella tämä voi moninkertaistaa ruudunpäivitysnopeuden jopa kahdeksankertaiseksi verrattuna perinteiseen renderöintiin (Kuva 3).



Kuva 3. Pelikohtainen vertailu DLSS Off, DLSS 3 ja DLSS 4 välillä (Lin & Burnes, 2025)

Linin ja Burnesin (2025) mukaan Multi Frame Generation hyödyntää uudenlaista entistä tehokkaampaa neuroverkkomallia, joka on 40% nopeampi ja käyttää 30% prosenttia vähemmän VRAM-muistia kuin aiemmat mallit. Heidän mukaansa myös optisen virtausdatan tuottaminen (generation of the optical flow field) on siirretty AI-pohjaiseksi, mikä mahdollistaa useiden ruutujen tuottamisen yhdellä mallisuorituksella ja vähentää täten samalla laskennallista kuormitusta.

DLSS 4:n suuri suosio ja keskustelu aiheen ympärillä johtuu pitkälti siitä, että se on DLSS:n suurin tekoälymallipäivitys sitten DLSS 2.0:n. Linin ja Burnesin (2025) mukaan DLSS Ray Reconstruction, Super Resolution ja DLAA siirtyivät käyttämään transformer-pohjaista neuroverkkoarkkitehtuuria (Kuva 4). Heidän mukaansa tämä on ensimmäinen kerta grafiikkateollisuudessa, kun vastaavanlainen malli otetaan käyttöön. Samanlaista arkkitehtuuria käyttävät myös AI-mallit, kuten Gemini ja ChatGPT. Tämä Transformer-malli käyttää apunaan itsehuomiota (self-attention), jolla se arvioi eri pikseleiden merkitystä koko kuvassa sekä eri ruutujen välillä. Linin ja Burnesin (2025) mukaan tämän tuloksena on esimerkiksi vakaampi kuva, vähemmän ghosting-efektejä, tarkemmat yksityiskohdat liikkeessä sekä pehmeämmät reunat.



Kuva 4. Transformer-malli (Lin & Burnes, 2025)

DLSS 4 sisältää myös teknisiä uudistuksia kuvan esittämisen rytmitykseen. Aiemmin DLSS käytti CPU-pohjaista ruutujen ajoitusta, mikä saattoi aiheuttaa epätasaisuutta. DLSS 4:n Blackwell-arkkitehtuuri siirtää ajoituksen hallinnan näytönohjaimen näyttöyksikölle, minkä ansiosta ruutujen välinen ajoitus on tarkempaa ja kuvan esitys sulavampaa myös korkeilla virkistystaajuuksilla ja resoluutioilla (Lin & Burnes, 2025).

5.2 Miten perinteiset menetelmät vertautuvat DLSS?

NVIDIA DLSS pyrkii korvaamaan tai tehostamaan useita perinteisiä renderöinti- ja jälkikäsittelymenetelmiä. Vaikka se hyödyntää samoja tietolähteitä, esimerkiksi liikevektoreita, kuin Temporal Anti-Aliasing (TAA), sen tavoitteena on haastaa perinteinen natiiviresoluutiolla renderöinti ja syrjäyttää siihen liittyvät menetelmät. Näihin kuuluvat TAA, laskennallisesti raskaat menetelmät kuten SSAA ja MSAA sekä yksinkertaiset skaalausalgoritmit kuten bilineaarinen ja bikubinen skaalaus. Lisäksi uusimmat DLSS-versiot haastavat säteenseurannassa käytetyt perinteiset kohinanpoistajat (denoisers) sekä näytöissä käytetyt kuvan interpolaatiomenetelmät (frame interpolation). Tässä osiossa vertaillaan tarkemmin näiden eroja DLSS:ään.

Kuten luvussa 3.5 todettiin, TAA on nykyinen alan standardi, mutta se kärsii liikesumenuksesta ja haamukuvista (ghosting) (Roach, 2024). DLSS on suunniteltu korvaamaan peilin oman TAA:n kokonaan. Merkittävin ero on datan käsittelyssä: siinä missä TAA sekoittaa vanhaa ja uutta kuvaa keskenään pehmentäen lopputulosta, DLSS käyttää neuroverkkoa ja liikevektoreita rekonstruoidakseen kuvan uudelleen (Xiao ja muut, 2020). Tavoitteena on säilyttää TAA:n vakaus mutta palauttaa sen kadottamat yksityiskohdat ja terävyys liikkeessä (Mengistu, 2023).

SSAA ja MSAA edustavat perinteistä, raakaan laskentatehoon perustuvaa kuvanlaadun parantamista. Vaikka SSAA tuottaa Roachin (2024) ja Rohnerin (n.d.) mukaan parhaan reunojen laadun, se on laskennallisesti liian raskas moderneille peleille. MSAA puolestaan on kevyempi, mutta se ei pysty parantamaan tekstuurien laatua. DLSS pyrkii tarjoamaan SSAA:n kaltaisen "täyden kuvan" laadun mutta päinvastaisella logiikalla: sen sijaan, että kuva renderöitäisiin ylisuurella resoluutiolla (SSAA), DLSS renderöi sen matalammalla ja käyttää tekoälyä puuttuvan tiedon luomiseen. Tämä vapauttaa merkittävästi näytönohjaimen resursseja verrattuna perinteisiin menetelmiin (Mengistu, 2023).

Perinteiset skaalausmenetelmät perustuvat yksinkertaiseen matemaattiseen interpolointiin, jossa kuvaa venytetään laskemalla pikseleille keskiarvoja. Tämä johtaa suttuiseen lopputulokseen, koska menetelmä ei luo kuvaan uutta informaatiota. DLSS eroaa näistä perustavanlaatuisesti, sillä se on rekonstruktio menetelmä (Xiao ja muut, 2020). Mengistun (2023) mukaan DLSS:n neuroverkko on koulutettu tunnistamaan muotoja ja yksityiskohtia, jolloin se pystyy lisäämään kuvaan informaatiota, jota alkuperäisessä matalan resoluution syötteessä ei ollut.

Reaaliaikainen säteenseuranta eli Ray Tracing vaatii perinteisesti manuaalisesti säädettyjä kohinanpoistajia (denoisers) kuvan tasoittamiseksi, mikä voi hävittää yksityiskohtia. NVIDIA:n (n.d.) mukaan DLSS 3.5:n Ray Reconstruction korvaa nämä manuaaliset "denoiserit" tekoälyverkolla. Koska neuroverkko on koulutettu ymmärtämään valon käyttäytymistä, se pystyy erottamaan oikeat heijastukset kohinasta paremmin kuin

perinteiset algoritmit. Näin se pystyy tuottamaan tarkemman valaistuksen ilman kuvan suttuisuutta.

Perinteinen televisioissa käytetty kuvan interpolaatio luo väliruutuja liikkeen sulavoittamiseksi, mutta aiheuttaa pelikäytössä häiritsevää viivettä ja virheitä. DLSS Frame Generation (DLSS 3) ja Multi Frame Generation (DLSS 4) parantavat tätä hyödyntämällä pelimoottorin syvällistä dataa, kuten optista virtausta (optical flow) ja liikevektoreita. Lin ja Burnesin (2025) mukaan tämä mahdollistaa lisäruutujen generoinnin ilman perinteisen interpolaation visuaalisia virheitä, ja yhdessä NVIDIA Reflex -teknologian kanssa viive pysyy pelaamisen kannalta hyväksyttävällä tasolla.

Natiiviresoluutiota pidetään usein vertailun "nollapisteenä". Se on kuitenkin laskennallisesti raskain tapa tuottaa kuva. Lisäksi natiivikuva vaatii toimiakseen TAA-pehmennyksen, jolloin se kärsii samoista sumennusongelmista kuin muutkin TAA-kuvat. DLSS haastaa natiiviresoluution tarjoamalla parempaa suorituskykyä (FPS) renderöimällä pelin alemmalla tarkkuudella. Kuvanlaadullisesti NVIDIA:n Deep Learning Anti-Aliasing (DLAA) hyödyntää DLSS-teknologiaa natiiviresoluutiolla, pyrkimyksenä tuottaa vakaampi ja tarkempi kuva kuin mihin perinteinen natiivirenderöinti TAA:lla pystyy (Roach, 2024; Lin & Burnes, 2025).

5.3 Muiden näytönohjainvalmistajien kilpailevat menetelmät

Tässä osiossa perehdytään NVIDIA DLSS:n merkittävimpiin kilpailijoihin eli AMD:n FSR ja Intelin XeSS -teknologioihin. Tavoitteena on esitellä lyhyesti, mihin valmistajien teknologiat perustuvat, ja vertailla niiden uusimpia versioita NVIDIA:n DLSS 4:ään. AMD:n FidelityFX Super Resolution 4 (FSR 4) siirtää yhtiön kuvaskaalauksen tekoälyaikaan hyödyntäen RDNA 4 -arkkitehtuurin FP8-tarkkuutta ja useita tekoälymalleja, jotka on kehitetty Zen- ja XDNA-arkkitehtuureilla (Laine, 2025). Puolestaan Intelin XeSS 2 yhdistää tekoälypohjaisen skaalauksen, ruudungeneroinnin ja matalan latenssin, hyödyntäen XMN-ytimiä Battlemage-näytönohjaimissa (Laird, 2024; Laine, 2024).

5.3.1 AMD FSR

AMD:n FidelityFX Super Resolution 4 (FSR 4) -teknologia edustaa yhtiön siirtymää tekoälypohjaiseen kuvaskaalaukseen. Tämä asettaa sen kilpailukykyiseksi muita tekoälypohjaisia skaalaustekniikoita vastaan, kuten NVIDIA:n DLSS:ää ja Intelin XeSS:ää (Laine, 2025). Hänen mukaansa FSR 4 hyödyntää RDNA 4 -arkkitehtuurin tarjoamaa FP8-tarkkuutta, mikä mahdollistaa siinä tehokkaan tekoälykiihdytyksen. Hän painottaa kuitenkin rajoituksena olevan, että teknologia on käytössä vain Radeon RX 9070- sarjan näytönohjaimilla. Laine (2025) mainitsee, että teknologiaa on kehitetty Zen- ja XDNA-arkkitehtuureilla, opetettu Epyc-prosessoreilla ja Instinct-kiihdyttimillä, ja se käyttää useita erikoistuneita tekoälymalleja. Lisäksi AMD:n Fluid Motion Frames -teknologia on päivitetty versioon 2.1, mikä parantaa ruutujen generointia vähentämällä haamukuvia ja tehostamalla yksityiskohtien toistoa (Laine, 2025). Yhdessä HYPH-RX-ominaisuuksien kanssa teknologia voi parantaa suorituskykyä 4K-resoluutiolla jopa 2,2–3-kertaiseksi natiiviin verrattuna (Laine, 2025).

Tässä DLSS- ja FSR-vertailussa keskitytään 2K-resoluutioon sen yleisyyden ja pelaajien keskuudessa nauttiman suosion vuoksi. Schiesserin (2025) mukaan FSR 4 osoittaa 2K-testeissä merkittävää parannusta FSR 3.1:een nähden, erityisesti tekstuuri-terävyydessä, disokklusiossa ja ruohon laadussa, ja se päihittää usein jopa NVIDIA:n DLSS 3-version. Kuitenkin DLSS 4:n Transformer-pohjainen tekoälymalli säilyttää etulyöntiaseman erityisesti reunojen vakaudessa ja yleisessä kuvanlaadussa, vaikka FSR 4 onkin lähellä tietyissä skenaarioissa, kuten esimerkiksi hiusten ja läpinäkyvien efektien käsittelyssä (Schiesser, 2025). Schiesser (2025) huomauttaa, että FSR 4:n heikkous ilmenee ajoittaisena epävakauteina, esimerkiksi reunojen käsittelyssä.

Vaikka FSR 4 tukee julkaisussa yli 30 peliä, sen pelituki on rajallisempi kuin DLSS 4:n, mikä voi rajoittaa sen houkuttelevuutta (Laine, 2025; Schiesser, 2025). Suorituskyvyn osalta Schiesser (2025) raportoi, että FSR 4 tarjoaa 2K-resoluutiolla Quality-tilassa noin 14–31 % suorituskykyisän peleistä riippuen (Kuva 5). Tämä on todella lähellä DLSS 4:n 16–34 %

parannusta, mutta kuitenkin DLSS 4 on hieman nopeampi erityisesti sen Balanced- ja Performance-tiloissa.



Kuva 5. DLSS 3, FSR 4 ja DLSS 4 Quality-tilassa (Schiesser, 2025)

5.3.2 Intel XeSS

Intelin uusi tulokas XeSS 2 -skaalausteknologia on kehittynyt tekoälypohjainen ratkaisu, joka yhdistää Super Resolution (XeSS-SR) -skaalauksen, ruudungeneroinnin (XeSS-FG) ja matalan latenssin (XeLL) ominaisuudet kilpaillakseen NVIDIA:n DLSS:n kanssa (Laird, 2024). Hänen mukaansa XeSS 2 hyödyntää Intelin Battlemage-näytönohjainten XMX-ytimiä tekoälypohjaiseen skaalaukseen, ja sen ruudungenerointiin, joka perustuu liikevektoreihin ja syvyystietoihin. Esimerkkinä tästä hän mainitsee suorituskyvyn nousseen jopa 3,9-kertaiseksi F1 24 -pelissä 2K-resoluutiolla. Laine (2024) täydentää, että XeSS 2:n ruudungenerointi on interpolointipohjainen ja tuo 57–65 % suorituskykyisän skaalauksen päälle, kun taas kokonaisuudessaan XeSS 2 voi olla jopa 180–290 % nopeampi kuin natiivirenderöinti. Laine (2024) korostaa myös XeSS-SR:n kahta tekoälymallia: XMX-yksiköille optimoitua mallia erillisnäytönohjaimille ja kevyempää Lite-mallia integroiduille tai jopa muiden valmistajien näytönohjaimille. Matalan latenssin XeLL-ominaisuus vähentää

Lairdin (2024) mukaan latenssia jopa 45 %, ja Laine (2024) lisää, että se voi käytännössä eliminoida ruudungeneroinnin aiheuttaman viiveen lähes kokonaan.

Vertailussa NVIDIA:n DLSS 4:ään Lairdin (2024) mukaan XeSS 2 on ominaisuuksiltaan hyvin samankaltainen, sillä molemmat hyödyntävät tekoälypohjaista skaalausta ja ruudungenerointia, mutta Laine (2024) ei mainitse DLSS 4:ää artikkelissaan, joten suoraa vertailua niiden suorituskykyyn tai kuvanlaatuun ei tehdä. Lairdin (2024) mukaan XeSS 2:n todellinen kilpailukyky DLSS 4:ää vastaan vaatii vielä kehitystä. Intelin ja NVIDIA:n kilpailussa on myös huomioitava se, että Intelin näytönohjaimet, kuten Arc B580 ja B570, eivät nykypäivänä yllä suorituskyvyssä NVIDIA:n huippunäytönohjainten tasolle, vaan ne kilpailevat lähinnä NVIDIA:n matalamman pään, kuten RTX 4060 -mallin kanssa (Laird, 2024). Tämä esimerkiksi laskee Intelin suosiota high-end-pelaajien keskuudessa, koska on selvää, että suorituskyky on monelle tärkein asia tässä kontekstissa. Tämän lisäksi XeSS 2 -pelituki jää selvästi DLSS 4:n tasosta.

6 DLSS:n tulevaisuuden näkymät

Tässä luvussa tarkastellaan NVIDIA:n Deep Learning Super Sampling (DLSS) -teknologian ja laajemmin tekoälyavusteisen renderöinnin vaikutuksia peliteollisuuteen, kuluttajakäyttäytymiseen sekä tietokonegrafiikan tulevaisuudennäkymiin. Tarkastelu etenee arvioimalla ensin DLSS:n positiivisia kehityssuuntia tavallisen pelaajan ja pelikehittäjän näkökulmasta. Tämän lisäksi analysoidaan teknologian nykyisiä ja potentiaalisia rajoitteita, jotka voivat hidastaa sen omaksumista. Lopuksi pohditaan kysymystä siitä, voiko tekoäly mahdollisesti korvata perinteiset renderöintimenetelmät kokonaan.

6.1 DLSS:n nykytila ja haasteet

NVIDIA DLSS on muuttanut pysyvästi peliteollisuuden tapaa tuottaa grafiikkaa. Siirtymä perinteisestä "raakaan laskentatehoon" perustuvasta renderöinnistä kohti tekoälyavusteista kuvanrakennusta on tunnetusti yksi merkittävimmistä kehityssuunnista tietokonegrafiikassa. Voidaan sanoa, että DLSS mahdollistaa nykypelien visuaalisen kunnianhimon toteuttamisen kuluttajalaitteilla. DLSS:n ja aiemmin tutkielmassa mainittujen kilpailijoiden kehitys on luonut positiivisen kierteen, joka hyödyttää ekosysteemiä pidentämällä laitteistojen elinkaarta ja mahdollistamalla pelinkehittäjille entistä laajempaa taiteellisen vapauden (Lin & Burnes, 2025; Mengistu, 2023).

Coken (2025) mukaan uusin DLSS 4 -versio edustaa suurta laadullista harppausta tekoälymallien hyödyntämisessä. Siirtyminen uuteen Transformer-pohjaiseen malliin on parantanut järjestelmän kykyä analysoida pelikuvaa. Uusi malli käsittelee kaksinkertaisen määrän parametreja ja ymmärtää paremmin pitkän aikavälin visuaalisia rakenteita. Käytännössä tämä näkyy kuvanlaadun terävöitymisinä ja aiempia versioita vaivanneiden artefaktien vähentymisenä. Suorituskyvyn osalta uusi Multi-Frame Generation -ominaisuus kykenee generoimaan jopa kolme tekoälypohjaista ruutua yhtä perinteisesti renderöityä ruutua kohden. Menetelmä tarjoaa huomattavan suorituskykyisän kasvattamatta laitteiston laskentataakkaa (Coke, 2025).

Taloudellisesta näkökulmasta DLSS pidentää laitteistojen käyttöikää komponenttien hintojen noustessa. Coke (2025) kuvaa teknologiaa "porttominaisuudeksi", joka avaa pääsyn korkeampiin resoluutioihin ja grafiikka-asetuksiin myös keskihintaisilla näyttönohjaimilla. Tämän myötä kuluttajan kynnyksen korkealaatuisen pelikokemuksen saavuttamiseen madaltuu. Näiden uudistusten myötä DLSS on vakiinnuttanut asemansa keskeisenä vertailukohtana, johon muiden valmistajien ratkaisuja peilataan (Coke, 2025).

Vaikka DLSS on mullistanut renderöinnin ja tarjoaa kiistattomia etuja, niin siitä huolimatta on tärkeää tarkastella kriittisesti sen rajoitteita ja haasteita, jotta kokonaiskuva pysyy tasapainossa. Kaikki kehitys DLSS:n ympärillä ei ole ollut ongelmaton, ja tekoälypohjainen lähestymistapa tuo mukanaan uudenlaisia ongelmia, joita perinteisessä renderöinnissä ei välttämättä ole.

Schiesserin (2022) mukaan tekoälyn generoimat väliruudut voivat aiheuttaa nopeassa liikkeessä havaittavia artefakteja, kuten "haamukuvia" ja reunojen värinää, sekä vääristää käyttöliittymän elementtejä, joita algoritmi ei aina tunnista oikein. Uudemmat versiot, kuten DLSS 4, pyrkivät korjaamaan juuri näitä virheitä. Ongelmat eivät ole silti poistuneet kokonaan. Rozario (2025) huomauttaa, että aggressiivinen skaalaus ja useiden peräkkäisten ruutujen generointi (Multi-Frame Generation) voivat edelleen johtaa yksityiskohtien suttaisuuteen.

Latenssin osalta DLSS Frame Generation tuo merkittäviä ongelmia. Testejä julkaisseet tahot kuten TechSpot raportoivat, että vaikka FPS nousee Frame Generationin myötä, syöttölatenssi voi kasvaa merkittävästi (Schiesser, 2022). Latenssilla tarkoitetaan sitä, että esimerkiksi klikkauksen viive näytöllä voi olla suurempi kuin pelin ollessa renderöitynä tiivistettynä (Schiesser, 2022). Tämä tarkoittaa, että korkeampi FPS ei välttämättä tarkoita sulavampaa tai responsiivisempaa pelikokemusta, mikä on tärkeä huomio etenkin kilpailullisessa pelaamisessa (Schiesser, 2022). Tiivistettynä teknologia pystyy siis nostamaan ruudunpäivitysnopeutta (FPS) huomattavasti, mutta samalla se kasvattaa viivettä. Tämä luo ristiriitaisen tilanteen, jossa peli näyttää visuaalisesti sulavalta, mutta tuntuu

ohjattavuudeltaan tahmealta. Ristiriidan myötä DLSS:n käyttö ei ole suosiossa kilpailullisessa pelaamisessa, missä nopeat reaktiot ja pelin responsiivisuus ovat yksi sen tärkeimpiä asioita (Schiesser, 2022; Rozario, 2025). Coke (2025) kuitenkin mainitsee, että kritiikkiin syöttöviiveestä on pyritty vastaamaan integroimalla järjestelmään NVIDIA Reflex 2.0 -teknologia, jonka tavoitteena on minimoida mahdolliset viiveet ja pitää pelikokemus responsiivisena korkeasta ruudunluontimäärästä huolimatta.

Rozarion (2025) mukaan teknisten rajoitteiden lisäksi DLSS:n yleistymisen nähdään vaikuttaneen negatiivisesti pelialan optimointikäytäntöihin ja laitteistomarkkinointiin. Rozario (2025) argumentoi, että pelinkehittäjät tukeutuvat yhä useammin tekoälyskaalauksen suorituskyvyn takaajana, jolloin pelimoottorien varsinainen optimointi jää vähemmälle huomiolle. Rozario (2025) toteaa myös, että samalla kuluttajia saatetaan johtaa harhaan markkinoimalla uusia näytönohjaimia tekoälyn generoimilla suorituskykyluvuilla, jotka eivät välttämättä vastaa laitteiston todellista laskentatehoa. Schiesser (2022) täydentää, että saadakseen DLSS-teknologiasta todellisen hyödyn, käyttäjällä on jo valmiiksi oltava erittäin suorituskykyinen laitteisto, mikä rajaa sen hyödyllisyyttä edullisemmissä hintaluokissa.

6.2 Voiko tekoäly korvata perinteiset renderöintimenetelmät?

Tutkielman alussa nostettiin esille mielenkiintoinen hypoteettinen kysymys siitä, että kykeneekö tekoäly korvaamaan perinteiset renderöintimenetelmät. Sims (2023) mainitsee artikkelissaan, että NVIDIA:n soveltavan syväoppimisen tutkimusjohtaja Bryan Catanzaro on todennut, että natiiviresoluutio pelien renderöinnissä on väistymässä eikä se ole enää paras tapa tuottaa korkeinta mahdollista kuvanlaatua. Simsin (2023) artikkelin ja tutkielmassa aiemmin mainitun mukaan natiiviresoluutiolla renderöinti on verrattavissa ”raakaan voimaan” ja ala tarvitsee älykkäämpiä tapoja säästää laskentaresursseja. Simsin (2023) mukaan NVIDIA näkee resoluution skaalauksen tulevaisuuden standardina.

Sims (2023) korostaa erityisesti, että tekoälypohjainen skaalaus on lähes välttämätöntä raskasta säteenseurantaa käyttävissä peleissä. Hän mainitsee esimerkkinä tästä

Cyberpunk 2077 -pelin, jossa natiiviresoluutio ei enää pysty takaamaan pelattavaa suorituskykyä. Tämä havainto tukee tutkielman luvussa 5.1.4 esitettyä suorituskykyvertailua (Kuva 3), jossa kyseinen peli on mukana. Todellinen ero suorituskyvyssä DLSS Off ja DLSS 4 välillä on merkittävä.

Tekoäly ei korvaa perinteistä renderöintiprosessia kokonaisuudessaan, vaan teknologiat ovat siirtymässä kohti hybridimallia (Eloy, 2024). Vaikka tekoäly ottaa vastuun lopullisen kuvan muodostamisesta ja pikselien täydentämisestä, se on edelleen riippuvainen perinteisen grafiikkaputken tuottamasta datasta. Sirdesai ja muut (2025) toteavat, että vaikka tekoäly vähentää merkittävästi perinteisen rasteroinnin kuormaa, järjestelmä vaatii edelleen perinteisesti renderöityjä ruutuja toimiakseen pohjana tekoälyn ennustuksille. Tulevaisuudessa renderöinti perustuukin todennäköisesti malliin, jossa perinteinen grafiikkaputki luo vain välttämättömän rungon ja tekoäly vastaa puolestaan lopullisen ulkoasun hiomisesta.

7 Johtopäätökset

Tämän kandidaatintutkielman tavoitteena oli tarkastella tekoölyavusteisen renderöinnin roolia nykyaikaisessa tietokonegrafiikassa, keskittyen erityisesti NVIDIA:n DLSS-teknoologiaan. Tutkielmassa selvitettiin, kuinka syväoppimiseen perustuvat menetelmät eroavat perinteisistä renderöintitekniikoista ja millaisia vaikutuksia niillä on pelien suorituskykyyn ja kuvanlaatuun. Kirjallisuuskatsauksen ja teknisen vertailun perusteella voidaan todeta, että tekoöly ei ole enää pelkkä lisäominaisuus. Tekoölystä on tullut vakiintunut osa renderöintiä, ja samalla alan painopiste on siirtynyt älykkäämpään kuvan tuottamiseen.

Ensimmäiseen tutkimuskysymykseen tekoölypohjaisten menetelmien toimintaperiaatteista ja eroista perinteisiin tekniikoihin saatiin selkeä vastaus. Perinteiset menetelmät perustuvat matemaattiseen keskiarvoistamiseen tai näytemäärien kasvattamiseen. DLSS ja vastaavat tekniikat ovat luonteeltaan puolestaan rekonstruktivisia. Hyödyntämällä neuroverkkoja, kuten konvoluutioautoenkoodereita ja uusimmissa versioissa Transformer-malleja, järjestelmä kykenee luomaan kuvaan informaatiota, jota alkuperäisessä syötteessä ei ole. Tekoöly siis "hallusinoi" puuttuvat yksityiskohdat opitun datan perusteella sen sijaan, että se vain venyttäisi olemassa olevia pikseleitä.

Toinen tutkimuskysymys käsitteli vaikutuksia kuvanlaatuun ja suorituskykyyn. Tulosten valossa DLSS on onnistunut ratkaisemaan perinteisen "laatu vastaan suorituskyky" -kompromissin. Erityisesti DLSS 2.0:n tuoma ajallinen vakaus ja DLSS 4.0:n Transformer-pohjainen tarkkuus osoittavat, että skaalattu kuva voi olla laadultaan jopa parempi kuin natiiviresoluution kuva, joka kärsii usein TAA-pehmennyksen aiheuttamasta suttuisuudesta. DLSS 3:n ja 4:n tuomat Frame Generation -teknologiat mahdollistavat jopa kahdeksankertaisen FPS:n verrattuna natiivirenderöintiin. On kuitenkin huomioitava, että generoidut lisäruudut kasvattavat syöteviivettä, mikä luo ristiriidan visuaalisen sulavuuden ja pelattavuuden välille. Vaikka NVIDIA Reflex pyrkii tätä kompensoimaan, tekoöly-renderöinti vaatii edelleen tasapainottelua responsiivisuuden ja visuaalisuuden välillä.

Kolmantena tavoitteena oli arvioida tekoölyn tulevaisuutta ja potentiaalia korvata perinteiset menetelmät. Tutkielman havaintojen ja pelikohtaisen suorituskykyvertailun perusteella, natiiviresoluutiolla pelaaminen on väistymässä. Nykyaikaiset pelimoottorit ja säteenseuranta ovat niin raskaita, että ne on suunniteltu lähtökohtaisesti toimimaan skaa-lausteknologioiden varassa. Tulevaisuuden suunta näyttää olevan hybridimalli, jossa perinteinen grafiikkaputki luo vain välttämättömän geometrisen rungon ja tekoäly vastaa lopullisen pikselimassan tuottamisesta ja viimeistelystä. DLSS 4:n Multi Frame Generation, joka tuottaa valtaosan näytöllä näkyvistä pikseleistä tekoälyllä, on vahva osoitus tästä kehityksestä.

Tutkielman luotettavuutta arvioitaessa on huomioitava, että osa lähdeaineistosta perustuu laitevalmistajien omiin teknisiin dokumentteihin ja markkinointimateriaaleihin, joissa korostetaan omien teknologioiden vahvuuksia. Riippumattomat testit, artikkelit ja asiantuntijoiden kommentit kuitenkin tukevat pääosin valmistajien väitteitä suorituskyvystä.

Eriyisen merkittävä ja ajankohtainen jatkotutkimuskohde on tekoälygeneroinnin vaikutus kilpapelaamiseen. Tutkielmassa havaittiin, että tekniikat kuten DLSS 3 ja 4 moninkertaistavat kuvataajuuden, mutta vastapainona se aiheuttaa syöttöviivettä. Tulevissa tutkimuksissa olisikin mielenkiintoista selvittää, miten tekoölyn generoimat väliruudut vaikuttavat pelaajien reaktioihin ja tarkkuuteen nopeutta vaativissa tilanteissa. Aihetta tulisi tutkia, miten tekoälyavusteisuus vaikuttaa kilpapelaamisen tasapuolisuuteen. Tarjoaako tekoäly epäreilua etua visuaalisen selkeyden kautta, vai estävätkö mahdolliset viiveet teknologian käytön huipputasolla?

Lähteet

- Aulanko-Jokirinne, T. (2019). *Todenmukaista grafiikkaa tekoälyllä*. Aalto-yliopisto. Noudettu 13.3.2025 osoitteesta <https://www.aalto.fi/fi/uutiset/todenmukaista-grafiikkaa-tekoalylla>
- Basics Explained, H3Vtux. (2020). *How does a graphics card work? GPUs and graphics cards explained*. YouTube. Noudettu 14.4.2025 osoitteesta https://www.youtube.com/watch?v=Kgcfj_KV-mo
- Branch Education. (2023). *How do video game graphics work?* YouTube. Noudettu 14.4.2025 osoitteesta <https://www.youtube.com/watch?v=C8YtdC8mxTU>
- Chen, J. X. (2010). Rendering in computer graphics. *Wiley interdisciplinary reviews. Computational statistics*, 2(1), 120-126. <https://doi.org/10.1002/wics.60>
- Coke, C. (2025). *What Is DLSS and Why Does It Matter for Gaming?* IGN. Noudettu 24.11.2025 osoitteesta <https://nordic.ign.com/guide/90792/what-is-dlss-and-why-does-it-matter-for-gaming>
- Eloy, R. (2024). *How AI rendering is revolutionizing architecture design*. Chaos. Noudettu 13.3.2025 osoitteesta <https://www.chaos.com/blog/how-ai-rendering-is-revolutionizing-architecture-design>
- Hughes, J. F., van Dam, A., McGuire, M., Sklar, D. F., Foley, J. D., Feiner, S. K., & Akeley, K. (2014). *Computer graphics: Principles and practice* (3. painos). Addison-Wesley Professional. Noudettu 12.4.2025 osoitteesta https://cgisutic.wordpress.com/wp-content/uploads/2016/07/computer_graphics_principles_and_practice.pdf
- Laine, P. (2025). *AMD esitteli tekoälyaikaan päivittyneen FSR 4 -teknologian*. io-tech.fi. Noudettu 2.6.2025 osoitteesta <https://www.io-tech.fi/uutinen/amd-esitteli-tekoalyaikaan-paivittyneen-fsr-4-teknologian/>
- Laine, P. (2024). *Intel julkaisi XeSS 2 -teknologian ruutujen generoinnilla ja muita ohjelmistopäivityksiä*. io-tech.fi. Noudettu 2.6.2025 osoitteesta <https://www.io-tech.fi/uutinen/intel-julkaisi-xess-2-teknologian-ruutujen-generoinnilla-ja-muita-ohjelmistopaivityksia/>

- Laird, J. (2024). *Intel's new second-gen XeSS 2 upscaling tech with frame generation matches Nvidia's DLSS for features and might have the edge on AMD's FSR*. PC Gamer. Noudettu 2.6.2025 osoitteesta <https://www.pcgamer.com/hardware/graphics-cards/intels-new-second-gen-xess-2-upscaling-tech-with-frame-generation-matches-nvidias-dlss-for-features-and-might-have-the-edge-on-amds-fsr/>
- Lin, H. & Burnes, A. (2025). *NVIDIA DLSS 4 Introduces Multi Frame Generation & Enhancements For All DLSS Technologies*. NVIDIA. Noudettu 28.4.2025 osoitteesta <https://www.nvidia.com/en-us/geforce/news/dlss4-multi-frame-generation-ai-innovations/>
- Mengistu, B. (2023). *Deep-learning Realtime Upsampling Techniques in Video Games*. Scholarly Horizons: University of Minnesota, Morris Undergraduate Journal. <https://doi.org/10.61366/2576-2176.1127>
- NVIDIA. (n.d.). *NVIDIA DLSS*. NVIDIA Developer. Noudettu 28.4.2025 osoitteesta <https://developer.nvidia.com/rtx/dlss>
- Roach, J. (2024). *What is anti-aliasing? TAA, FXAA, DLAA, and more explained*. Digital Trends. Noudettu 10.3.2025 osoitteesta <https://www.digitaltrends.com/computing/what-is-anti-aliasing/#dt-heading-what-is-anti-aliasing>
- Rohner, M. A. (n.d.). *Aliasing & anti-aliasing in CGI*. Anti-aliasing.com. Noudettu 10.3.2025 osoitteesta <https://www.anti-aliasing.com>
- Rozario, H. (2025). *4 reasons why Nvidia's DLSS is ruining PC gaming*. XDA Developers. Noudettu 24.11.2025 osoitteesta <https://www.xda-developers.com/why-nvidias-dlss-ruins-pc-gaming/>
- Schiesser, T. (2025). *AMD FSR 4 vs. Nvidia DLSS 4 at 4K*. TechSpot. Noudettu 2.6.2025 osoitteesta <https://www.techspot.com/article/2976-amd-fsr4-4k-upscaling/>
- Schiesser, T. (2022). *Nvidia DLSS 3: Fake Frames or Big Gains?* TechSpot. Noudettu 24.11.2025 osoitteesta <https://www.techspot.com/article/2546-dlss-3/>
- Sirdesai, A., Limbikai, V., Kalyani, P., Joshi, S., & Kugali, S. N. (2025). *A Concise Overview of DLSS-Based Frame Generation*. International Scientific Journal of Engineering and Management (ISJEM), 4(6). <https://doi.org/10.55041/ISJEM04657>

- Sims, D. (2023). *Nvidia says resolution upscaling like DLSS (and not native resolution) is the future*. TechSpot. Noudettu 25.11.2025 osoitteesta <https://www.techspot.com/news/100226-nvidia-resolution-upscaling-future-recent-dlss-discussion.html>
- Wang, Z., She, Q., & Ward, T. E. (2021). Generative adversarial networks in computer vision: A survey and taxonomy. *ACM Computing Surveys*, 54(2), Article 37, 1–38. <https://doi.org/10.1145/3439723>
- Xiao, L., Nouri, S., Chapman, M., Fix, A., Lanman, D., & Kaplanyan, A. (2020). Neural supersampling for real-time rendering. *ACM Transactions on Graphics*, 39(4), Article 142, 1–12. <https://doi.org/10.1145/3386569.3392376>
- Yang, W., Zhang, X., Tian, Y., Wang, W., Xue, J., & Liao, Q. (2019). Deep Learning for Single Image Super-Resolution: A Brief Review. *IEEE transactions on multimedia*, 21(12), 3106-3121. <https://doi.org/10.1109/TMM.2019.2919431>
- Zangana, H. M., Mustafa, F. M., Mohammed, A. K., & Omar, N. (2024). Enhancing image quality with deep learning: Techniques and applications. *Jurnal ELTIKOM: Jurnal Teknik Elektro, Teknologi Informasi dan Komputer*, 8(2), 119–131. <https://doi.org/10.31961/eltikom.v8i2.1242>