

Opinnäytetyö (AMK)

Tieto- ja viestintätekniikka

2024

Kirsi Koivuaho

Konenäön soveltamismahdollisuudet kroonisten haavojen hoidossa

Opinnäytetyö (AMK) | Tiivistelmä

Turun ammattikorkeakoulu

Tieto- ja viestintätekniikka

2024 | 31 sivua, 5 liitesivua

Kirsi Koivuaho

Konenäön soveltamismahdollisuudet kroonisten haavojen hoidossa

Tässä opinnäytetyössä kartoitetaan konenäön soveltamismahdollisuuksia kroonisten haavojen hoidossa. Työ on toteutettu kirjallisuuskatsauksena, johon on koottu kansainvälisiä vertaisarvioituja artikkeleita.

Kroonisiin haavoihin liittyvät keskeisesti sekä inhimillinen kärsimys että pitkäkestoisten hoitojen aiheuttamat merkittävät kustannukset. Haavojen paranemisedellytyksiin vaikuttavat säännöllisen ja menetelmien osalta vakioidun seurannan toteutuminen sekä laadukkaaseen dokumentaatioon pohjautuva päätöksenteko.

Eri tutkimuksissa on verrattu tekoälyn ja konenäön suoriutumista klinikoiden saamiin tuloksiin haavan koon ja haavapohjan eri kudostyyppien määrittämisessä. Näissä tehtävissä tekoälyn kanssa on saatu lupaavia tuloksia. Tutkimuksissa on kuitenkin todettu tekoälyn perustuvien menetelmien olevan alttiita valaistusolosuhteiden ja kuvausetaisyyden vaihteluille.

Tekoälyn ja konenäön hyödyntäminen kroonisten haavojen hoidossa edellyttää määrällisesti suurta, sisällöltään kattavaa ja laadukasta opetusaineistoa. Kehitettävien ratkaisujen tulee myös olla helposti käyttöön otettavia ja vaihtelevissa ympäristöissä toimivia, jotta niiden käyttö voi vakiintua hoitotyön asiantuntijoiden työvälineenä.

Asiasanat:

tekoäly, konenäkö, konvoluutioneuroverkot, krooninen haava, arviointi

Bachelor's Thesis | Abstract

Turku University of Applied Sciences

Information and Communications Technology

2024 | 31 pages, 5 in appendices

Kirsi Koivuaho

Application possibilities of computer vision in the treatment of chronic wounds

This thesis explores the possibilities of applying computer vision in the treatment of chronic wounds. The work has been carried out as a literature review with international peer-reviewed articles.

Chronic wounds are associated with both human suffering and the significant costs of long-term treatments. The prerequisites for wound healing are affected by the implementation of regular and methodically standardised monitoring and decision-making based on high-quality documentation.

Various studies have compared the performance of artificial intelligence and computer vision with the results obtained by clinicians in determining wound size and different tissue types of the wound bed. These tasks with artificial intelligence have yielded promising results. However, studies have shown that AI-based methods are susceptible to variations in lighting conditions and shooting distance.

The use of artificial intelligence and computer vision in the treatment of chronic wounds requires large, comprehensive and high-quality datasets for training. The solutions developed must also be easy to deploy and work in varying environments so that their use can become established as a tool for nursing experts.

Keywords:

artificial intelligence, computer vision, convolutional neural networks, chronic wound, assessment

Sisältö

1 Johdanto	6
2 Kroonisten haavojen hoito	7
2.1 Kroonisen haavan tunnusmerkit	7
2.2 Arviointi ja päätöksenteko kroonisen haavan hoidossa	7
2.2.1 TIMERS-malli	11
2.2.2 Esimerkkejä muista mittareista ja arviointimalleista	11
3 Konenäön teoreettisia lähtökohtia	13
4 Konenäön hyödyntäminen haavahoidossa	15
4.1 Aiemmat tutkimukset	15
4.2 Käytännön sovellukset	24
4.3 Konenäön mahdollisuudet	24
4.4 Konenäön rajoitteet	24
5 Lopuksi	25
Lähteet	26

Liitteet

Liite 1. Tekoälyyn ja konenäköön perustuvia ratkaisuja

Kuvat

Kuva 1. Epitelisoituva haava, jonka ympärillä rasvakarstaa.	8
Kuva 2. Puhdaspohjainen granuloiva haava.	9
Kuva 3. Fibriinikatteinen haava.	9
Kuva 4. Nekroottista katetta haavapohjassa.	10

Taulukot

Taulukko 1. VPKM-väriluokitus.	8
Taulukko 2. TIMERS-malli.	11
Taulukko 3. Haavojen arviointiin kehitettyjä ratkaisuja.	32

1 Johdanto

Tämän opinnäytetyön aiheena on konenäön hyödyntämismahdollisuudet kroonisten haavojen hoidossa. Krooniset haavat aiheuttavat potilaille huomattavaa inhimillistä kuormitusta ja heikentävät elämänlaatua. Krooniset haavat ovat merkittävä kuormitustekijä sosiaali- ja terveysalalla, jonka resurssien rajallisuus on laajalti tunnustettu.

Haavojen hoidosta aiheutuu merkittäviä kustannuksia niin potilaalle kuin terveydenhuollollekin. Toiminnan laatuun voi vaikuttaa arviointiin ja päätöksentekoon osallistuvien terveydenhuollon ammattihenkilöiden kokemuksessa ja osaamisessa esiintyvä yksilöllinen vaihtelu. Laadukkaan hoidon edellytyksenä ovat vakioidut seurantamenetelmät sekä tasalaatuinen ja johdonmukainen dokumentaatio.

Selvitystyön tarkoituksena oli kartoittaa konenäön mahdollisuuksia ja rajoituksia kroonisten haavojen arvioinnissa ja hoitoon liittyvässä päätöksenteossa. Selvitystyön tavoitteena oli luoda pohjaa jatkokehitystyölle ja mahdollisille käytännön sovelluksille. Selvitystyössä käytettävän aineiston keruu tapahtui kirjallisuuskatsauksena aiemmista tutkimuksista, julkaisuista sekä mahdollisista jo kehitetyistä ratkaisuksista.

2 Kroonisten haavojen hoito

2.1 Kroonisen haavan tunnusmerkit

Haava on ehjään ihoon ja/tai ihonalaisiin kudoksiin kohdistuva vaurio, joka syntyy ulkoisen tekijän, kuten vamman tai sairauden seurauksena. Haavat voidaan jaotella akuutteihin ja kroonisiin haavoihin. Haava luokitellaan krooniseksi, jos sen ilmaantumiseen tai huonoon paranemiseen liittyy jokin haavaa ylläpitävä sisäinen ja/tai ulkoinen tekijä. Kroonistumiselle on asetettu syntymekanismikohtaisia aikarajoja, jotka kuitenkin tunnistetaan jossain määrin keinotekoisiksi. (Terveyskylä 2021a; Krooninen alaraajahaava 2021.)

Kroonisista alaraajahaavoista suurin osa on verenkiertoperäisiä (laskimohaavoja 32–51 %, valtimohaavoja 11–27 %, sekahaavoja 13–26 %) ja epätyypillisten haavojen osuus on 10–20 %. Haavaa sairastavilla liitännäissairauksista verenpainetauti, lihavuus sekä sydämen vajaatoiminta ovat yleisiä ja diabetesta sairastaa 18–27 %. Krooniseen alaraajahaavaan sairastuu 1,3–6,0 % väestöstä jossain vaiheessa elämäänsä, ja kroonisten haavojen esiintyvyys moninkertaistuu ikääntymisen myötä. Kroonisten alaraajahaavojen on todettu heikentävän merkittävästi potilaiden elämänlaatua ja aiheuttavan huomattavia kustannuksia terveydenhuollolle. Suomessa näitä kustannuksia on tutkittu vain vähän. Arvioiden perusteella kroonisten alaraajahaavojen hoito maksaa yhtä haavaa kohden tuhansia euroja vuodessa. Kansainvälisten tutkimusten perusteella haavojen hoidon kustannusten on arvioitu muodostavan 2–6 % terveydenhuollon kokonaiskustannuksista. (Krooninen alaraajahaava 2021.)

2.2 Arviointi ja päätöksenteko kroonisen haavan hoidossa

Haavan arvioinnissa käytetään VPKM-väriluokitusta (taulukko 1), joka ohjaa sekä tarkoituksenmukaisten hoitotuotteiden valintaa että hoitokertojen tiheyttä

(Young 2015, 51–54; Suomen Haavanhoitoyhdistys ry 2019; Terveyskylä 2021b; Krooninen alaraajahaava 2021).

Taulukko 1. VPKM-väriluokitus (Suomen Haavanhoitoyhdistys ry 2019).

Väri	Värin nimi	Kuvaus	Hoitotoimenpiteet
V	Vaaleanpunainen	Epiteelikudos: ihon uloin kerros.	Suojataan ihon ohutta uudiskudosta.
P	Punainen	Granulaatiokudos: terve pienijyväinen uudiskudos, edellytys haavan paranemiselle.	Huolehditaan kosteustasapainosta välttämällä liiallista kosteutta.
K	Keltainen	Fibriinikate: kuollut pehmeä tai sitkeä kudos.	Pehmitetään ja/tai poistetaan fibriinikate.
M	Musta	Nekroottinen kudos: kuollut pehmeä tai kova kudos.	Pehmitetään ja/tai poistetaan nekroottinen kudos.

Vaaleanpunainen on epiteelikudosta eli ihon ulointa kerrosta (kuva 1), jota tulee suojata vaurioitumiselta (Young 2015, 51–54; Suomen Haavanhoitoyhdistys ry 2019; Terveyskylä 2021b; Krooninen alaraajahaava 2021).



Kuva 1. Eitelisoituva haava, jonka ympärillä rasvakarstaa (Krooninen alaraajahaava 2021).

Punainen on granulaatiokudosta eli pienijyväistä uudiskudosta (kuva 2), jonka muodostuminen on edellytyksenä haavan paranemiselle. Tällöin tulee huolehtia kosteustasapainosta, koska pienijyväinen uudiskudos tarvitsee kostean paranemisympäristön. Liiallinen kosteus voi kuitenkin johtaa granulaatiokudoksen liikakasvuun (hypergranulaatio), joka voi kasvaa ympäröivän ihon tason yläpuolelle ja estää haavan epitelisoitumisen. (Young 2015, 51–54; Suomen Haavanhoitoyhdistys ry 2019; Terveyskylä 2021b; Krooninen alaraajahaava 2021.)



Kuva 2. Puhdas pohjainen granuloiva haava (Krooninen alaraajahaava 2021).

Keltaiseksi luokitellussa fibriinikatteisessa haavassa (kuva 3) on pehmeää tai sitkeää kuollutta kudosta, joka tulee pehmittää ja poistaa (Young 2015, 51–54; Suomen Haavanhoitoyhdistys ry 2019; Terveyskylä 2021b; Krooninen alaraajahaava 2021).



Kuva 3. Fibriinikatteinen haava (Krooninen alaraajahaava 2021).

Musta kuvaa nekroottista eli kuollutta kudosta (kuva 4), joka voi olla kovaa tai pehmeää. Tämä nekroottinen kudos tulee pehmittää ja poistaa, mutta raajan alueella sijaitsevassa haavassa täytyy ennen poistoa varmistua riittävästä verenkierrosta. (Young 2015, 51–54; Suomen Haavanhoitoyhdistys ry 2019; Terveyskylä 2021b; Krooninen alaraajahaava 2021.)



Kuva 4. Nekroottista katetta haavapohjassa (Krooninen alaraajahaava 2021).

Lääkärinä tulee konsultoida, jos haavaan liittyy kudosten hapenpuute (iskeeminen haava, nekroottista kudosta raajojen ääreisosissa), haavassa on infektion eli tulehduksen merkkejä (punoitus, kuumotus, turvotus, kivun ja haavaerityksen lisääntyminen) tai haavan alueella on luuta ja/tai jäniteitä näkyvissä. (Young 2015, 51–54; Suomen Haavanhoitoyhdistys ry 2019; Terveyskylä 2021b; Krooninen alaraajahaava 2021.)

Haavan kokoa voidaan mitata viivoittimen avulla haavan pisimmästä ja leveimmästä kohdasta, ja näin saatujen arvojen avulla lasketaan pinta-ala. Toinen tapa on piirtää haavan päälle asetetun läpinäkyvän muovikalvon avulla haavan muoto ja reunat, minkä jälkeen pituuden ja leveyden mittaaminen suoritetaan piirroksen avulla. Tämä planimetriaksi kutsuttu tapa soveltuu haavoille, jotka sijaitsevat kaarevalla pinnalla. Kummassakin edellä mainitussa mittaustavassa on kuitenkin epätarkkuutta, koska haavat ovat usein muodoltaan epäsäännöllisiä. Lisäksi mittaustavat edellyttävät kontaktia haava-alueeseen, mikä voi lisätä tulehdusriskiä sekä tuntua potilaasta epämiellyttävältä tai kivuliaalta. (Howell ym. 2021, 2; Reifs ym. 2023, 2.)

2.2.1 TIMERS-malli

Haavapohjan valmistelulla (wound bed preparation) tarkoitetaan järjestelmällistä ja kokonaisvaltaista lähestymistapaa haavapohjan hoitoon ja arviointiin. Tätä varten on kehitetty kansainvälinen TIMERS-malli (taulukko 2), jonka tarkoituksena on tukea hoitotyön ammattilaisia haavapohjan hoidossa ja arvioinnissa laadukkaan sekä kustannustehokkaan hoidon turvaamiseksi. (Kielo-Viljamaa 2021.)

Taulukko 2. TIMERS-malli (Kielo-Viljamaa 2021).

T	Tissue management (haavan puhdistaminen)
I	Inflammation and infection control (tulehduksen hallinta)
M	Moisture balance (kosteustasapainosta huolehtiminen)
E	Epithelial (edge) advancement (epitelisaation tukeminen)
R	Repair and regeneration (kudosten uusiutumisen tukeminen)
S	Social- and patient-related factors (sosiaaliset ja potilaskohtaiset tekijät)

2.2.2 Esimerkkejä muista mittareista ja arviointimalleista

BWAT-työkalu (Bates-Jensen Wound Assessment Tool), aiemmalta nimeltään PSST (pressure sore status tool), ohjaa käyttäjää haavan sijainnin ja muodon dokumentoinnin lisäksi arvioimaan haavan kokoa, syvyyttä, reunojen selkeyttä, reuna-alueiden onkaloitumista, kuolleen kudokseen laatua ja prosentuaalista osuutta, haavaerityksen laatua ja määrää, ihon väriä sekä turvotuksen ja kovettumien laajuutta haava-alueen ympärillä, granulaatiokudoksen ja epitelisaation prosentuaalista osuutta viitaten haavan parantumiseen. Arvioinnin kohteena olevat osa-alueet pisteytetään viisiportaisella asteikolla. Mitä suurempi pistemäärä, sitä huonompi tulos. Arviointikertojen välillä tapahtuva vertailu auttaa haavan tilanteen kehittymisen ennakkoinnissa. (Bates-Jensen 2001; Harris ym. 2009, 33–34.)

PWAT (Photographic Wound Assessment Tool) on muokattu versio BWAT (PSST) -työkalusta. Arvioitaviin osa-alueisiin kuuluvat haava-alueen reunojen selkeys, kuolleen kudoksen laatu ja prosentuaalinen osuus, haava-alueetta ympäröivän ihon väri sekä granulaatiokudoksen ja epitelisaation prosentuaaliset osuudet. Työkalun avulla on mahdollista toteuttaa haava-alueen arviointi valokuvan perusteella, jolloin haavaan kajoavia toimenpiteitä ei ole tarpeen suorittaa. Työkalun versiossa 2.0 arvioitaviin kohteisiin on lisätty haavan pinta-ala, syvyys ja haavaa ympäröivässä ihossa havaittavat elinkelpoisuuden merkit. Jokainen arvioitava osa-alue pisteytetään asteikolla 0–4, ja pistemäärän suureneminen viittaa haavan huonompiin paranemisedellytyksiin. (Houghton ym. 2000, 22-23; Houghton 2013.)

PUSH (Pressure Ulcer Scale for Healing) on kehitetty painehaavojen seurantaan. Työkalun avulla arvioidaan haavan pinta-alaa (pisteytys 0–10), erityksen määrää (pisteytys 0–3) ja haavapedissä havaittavia kudostyyppejä (pisteytys 0–4). Arvioitavien osa-alueiden pisteet lasketaan yhteen, korkeamman yhteispistemäärän viitatessa huonompaan tilanteeseen. (National Pressure Ulcer Advisory Panel n.d.; Gardner ym. 2005.)

DESIGN-R (depth, exudate, size, inflammation/infection, granulation tissue, necrotic tissue, pocket) on kehitetty Japanissa painehaavojen seurantaan. Työkalu pisteyttää arvioitavan haava-alueen sen syvyyden, erityksen, pinta-alan, tulehdukseen viittaavien merkkien, granulaatiokudoksen ja kuolleen kudoksen prosentuaalisten osuuksien perusteella sekä mahdollisen onkaloitumisen laajuuden mukaan. Pisteytys lähtee nollasta, mutta asteikko vaihtelee arvioitavan osa-alueen ja havaitun oireen vakavuuden mukaan seuraavan portaan ollessa 1–12 pisteen päässä edellisestä. (Japanese Society of Pressure Ulcers 2014.)

3 Koneenään teoreettisia lähtökohtia

Neuroverkkojen tutkimus on saanut alkunsa 1940-luvulla. 1960-luvulla tutkimus- ja kehitystyö on ollut aktiivista, mutta rajoitteita ovat asettaneet tietokoneiden heikko suorituskky ja rajallinen muisti. 1980-luvulla käytössä olivat päättelysääntöihin ja asiantuntijoiden toiminnan jäljittelyyn perustuvat asiantuntijajärjestelmät, joiden ylläpito osoittautui lopulta haasteelliseksi. Seuraavat suuret kehitysaskleet otettiin 2010-luvulla tietomäärien ja laskentatehon kasvaessa huomattavasti. (Council of Europe 2024.)

Koneoppiminen on tekoälyn osa-alue, jossa koneen oppiminen perustuu annettuihin pohjatietoihin ja käyttäjän toimintaan. Oppiminen voi olla ohjattua, ohjaamatonta tai vahvistettua. Ohjatussa oppimisessa opetukseen käytetään luokiteltua aineistoa ja tavoitteena on koneen suorittama luokittelu samankaltaiselle (ei samalle) aineistolle. Ohjatussa oppimisessa tavoitedata voi olla joko luokittelu ryhmiin tai jatkuvan datan tapauksessa regressio. Ohjaamattomassa oppimisessa koneen tavoitteena on löytää raakadatasta samankaltaisuuksia ja suhteita syötteiden välillä. Vahvistetussa oppimismallissa kone saa palautetta ympäristöstään ja oppii toimimaan niin, että positiivisen palautteen määrä kasvaa ja negatiivisen osuus vähenee. (Tuominen 2024.)

Neuroverkot rakentuvat useista rinnakkain toimivista suhteellisen yksinkertaisista prosessointiyksiköistä, jotka kykenevät suorittamaan määriteltäviä laskentatehtäviä toisistaan riippumatta. Näistä yksinkertaisista osasista muodostuu valtavia tietomääriä samanaikaisesti prosessoimaan kykenevä neuroverkkoarkkitehtuuri. Neuronit sekä tallentavat että prosessoivat tietoa. Yksittäinen neuroni saa syötteen, suorittaa määritellyn laskutoimituksen ja tuottaa tästä tulosteen. Neuroverkkorakenteessa tämä tuloste voi toimia syötteenä seuraavalle neuronille, jolle on määriteltä oma laskutehtävänsä. Neuronien toimintaa ohjataan syötteiden painokertoimia ja vakiotermejä säätämällä sekä tehtävästä riippuen erilaisia aktivointifunktioita käyttämällä. Takaisinvirtausalgoritmin avulla neuronin on mahdollista verrata saatua tulostetta tavoiteltuun arvoon, huomioida virhe ja säätää painokertoimia

pienimmän virheen ja parhaan lopputuloksen löytämiseksi. (Elements of AI 2024.)

Neuroverkon onnistunut opettaminen edellyttää suurta määrää laadukasta, kommentoitua opetusdataa ja tämän kanssa samankaltaista, muttei samaa testidataa, jolla todennetaan neuroverkon oppiminen. Opetuksessa on tavallista hyödyntää toistoja, eli opetusdata kulkee neuroverkon läpi useita (kymmeniä-satoja) kertoja. Liian pieni opetusdatan ja toistojen määrä voi johtaa alisovitukseen, jolloin neuroverkko ei käytännössä opi mitään. Ylisovitus taas on seurausta liian useista toistoista liian pienellä, yksipuolisella tai epätarkoituksenmukaista informaatiota sisältävällä opetusdatalla. Opetusdataa ei saa käyttää testausvaiheessa. Tavanomaisesti datasetti jaetaan ennen opetusta ja testausta osiin, esimerkiksi opetukseen 70–80 % ja testausta varten 20–30 % datasta, jolloin molempien settien tulee olla yhtä edustavia tavoitteena olevan opittavan asian kannalta. (Stanford University School of Engineering 2017; Jopling 2021, 1.)

Syväoppimisen mahdollistavat konvoluutioneuroverkot rakentuvat useista kerroksista: konvoluutiokerroksessa määritellyn kokoinen ja painokertoimiltaan yksilöllinen filtti käy kuvasyötteen läpi järjestelmällisesti etsien tiettyjä kuvapiirteitä, joiden avulla voidaan tunnistaa monimutkaisempia ja suurempia kokonaisuuksia syötteestä. Konvoluutiokerrokset sijoitetaan neuroverkossa alimmille tasoille, jotka käsittelevät suoraan syötekuvien pikseleitä. Konvoluutiokerrosten väliin saatetaan sijoittaa kokoomakerroksia, jotka tiivistävät seuraaville kerroksille syötteeksi tarkoitetun datan määrää. Tällä pystytään vähentämään esimerkiksi ylisovitusta (overfitting), jossa neuroverkko oppii opetukseen käytetyn datan piirteitä liian hyvin, eikä kuitenkaan pysty yleistämään havaintojaan ja suoriutuu heikosti testidatan kohdalla. Lopussa luokittelun suorittaa aktivointifunktio, jonka valinta riippuu tarvittavien luokkien määrästä. Konenäköä voidaan hyödyntää kohteiden, toimintojen, aktiivisuuden ja liikkeen tunnistamisessa, ihmiskehon asennon tunnistamisessa sekä semanttisessa segmentaatiossa eli aineiston osittamisessa. (Stanford University School of Engineering 2017; Voulodimos ym. 2018, 1-2.)

4 Konenäön hyödyntäminen haavahoidossa

Tekoälyn ja konenäön käyttö lääketieteen ja hoitotyön päätöksenteon tukena tulee lisääntymään lähitulevaisuudessa. Haavojen hoidossa hyödynnetään visuaalisen informaation tulkintaa, ja tähän käytettävien algoritmien toiminta perustuu kohteiden luokitteluun, havaitsemiseen ja segmentointiin eli aineiston osittamiseen. (Jopling ym. 2021, 1.)

4.1 Aiemmat tutkimukset

Aldaz ym. (2015, 1–21) tutkivat koulutustarkoituksiin käytettävän nuken haavakuvien tallentamista laboratorio-olosuhteissa käyttäen silmälasien tavoin kasvoille asetettavaa Google Glass -ratkaisua, jolla kuvien otto perustui eleiden tunnistamiseen ja äänikomentoihin. Tämä kädet vapaaksi jättävä toimintamalli mahdollisti kuvan ottajalle kuvattavan kohteen asennon parantelun ja mittaukseen käytettävän viivoittimen asettelun kuvausalueelle. Laseissa olevalla viivakoodinlukijalla testipotilaan henkilötiedot luettiin ennen kuvausta ja varmistettiin tietojen tallentuvan oikealle henkilölle, kuvauksen jälkeen ottajan oli mahdollista tallentaa kommentteja kuvauksen kohteesta puheentunnistuksen avulla. Ratkaisun suorituskykyä ja käytettävyyttä verrattiin artikkelin kirjoitushetkellä laajasti käytettyyn älypuhelimella toimivaan Epic Haiku -tuotteeseen. Testaukseen osallistuneiden hoitajien (n = 16) esiin tuomia etuja Google Glassiin perustuvassa ratkaisussa olivat mahdollisuus steriiliin toimintaan käsien ollessa vapaina, helppokäyttöisyys yleisesti ja kuvanottokyky. Vertailun toisella tuotteella vahvuuksia olivat jonkin verran parempi kuvan laatu ja kuvien esikatselumahdollisuus ennen tallennusta potilastietojärjestelmään. Google Glassiin perustuvaan ratkaisuun liittyviä kehitysehdotuksia olivat digitaalisen viivoittimen lisääminen, puheentunnistuksen kouluttaminen alaan liittyvällä sanastolla ja haavan historiatietojen haku laseihin nähtäville reaaliaikaisen vertailun mahdollistamiseksi. Tutkijat lisäävät vielä tietosuojaan liittyvät parannukset jatkokehityksessä ennen kuin käyttö aidossa toimintaympäristössä olisi mahdollista.

Goto ym. (2017, 129–133) tutkivat painehaavojen kolmiulotteista mittausta mobiililaitteeseen yhdistetyn infrapunasensorin ja konenäköalgoritmien avulla. Tämä haavan mittaukseen kehitetty inSight-laite suoriutui hyvin haavan pituuden, leveyden ja pinta-alan mittauksesta verrattuna perinteisiin menetelmiin, mutta haavan syvyyden ja tilavuuden määrittämisessä oli suuria eroja. Tutkimuksessa havaittiin laitteelle olevan haastavaa tunnistaa ulkomuodoltaan vaihtelevia haavan reunoja, mikä todennäköisesti aiheutti erot jälkimmäisissä mittaustuloksissa verrattuna perinteisiin menetelmiin. Lisäksi tutkijat toteavat tutkimuksen kohteena olevan potilasaineiston pieneksi ($n = 3$) ja jatkotutkimukset tarpeellisiksi.

Sánchez-Jiménez ym. (2019, 1–4) kehittivät Python-ohjelmointikieleen perustuvia sovelluksia, joiden tarkoituksena oli mitata haavojen kokoa ja rakennetta. Kehitystyön kohteena olivat kaksi sovellusversiota, joista toisen syötteenä toimivat valokuvat ja toisessa videotiedostot. Molemmissa sovelluksissa haavan koon määrittäminen edellytti käyttäjän toimia, joko kuvamateriaaliin merkittävien referenssipisteiden ja niiden välisen etäisyyden määrittämiseen ennalta tai vakiokokoisien referenssimerkien asettamista kuvausalueelle. Lisäksi käyttäjän tuli ohjata sovelluksen toimintaa haava-alueen erottamiseksi ympäröivästä ihosta. Esitellyn kehitystyön tunnistettiin olevan vielä alkuvaiheessa, mutta sen mahdollisuuksia tulevaisuudessa hoito- ja tutkimustyön tukena sekä hoitomuotojen vaikuttavuuden seurannassa pidettiin lupaavina.

Hsu ym. (2019, 1–20) pyrkivät kehitystyössään luomaan koneoppimiseen perustuvaa ratkaisua kirurgisten haavojen etäseurantaan. Ratkaisun perusperiaatteena oli vaihtelevissa valaistusolosuhteissa ja eri älypuhelinmalleilla kerättyjen haavakuvien avulla tapahtuva haava-alueen segmentointi reunojen ja värierojen perusteella sekä klusteroinnin eli samankaltaisiin piirteisiin perustuvan ryhmittelyn hyödyntäminen. Lisäksi pyrittiin tunnistamaan mahdolliseen infektiin viittaavia merkkejä. 293 valokuvaa jaoteltiin opetus- ja testidataseiteiksi. Tutkimuksessa todettiin kehitetyn mallin olevan riittävän luotettava etäseurantakäyttöön. Toimintatavan

hyödyntämiseksi kehitystyö jatkui haavojen automaattitulkinnan mahdollistavan sovelluksen ja käyttöön liittyvän verkkosivuston kehitystyöllä.

Alzubaidi ym. (2020, 1–21) selvittivät työssään siirto-oppimisen (transfer learning) hyödyntämismahdollisuuksia syväoppimismallien kouluttamisessa. Tutkijat totesivat, että laadukkaan opetusdatan hankinta on vaikeaa ja laajoja resursseja vaativaa. Tutkimuksessa arkkitehtuuriltaan sekä perinteisiä että rinnakkaisia konvoluutioneuroverkkoja koulutettiin erilaisilla aineistolla, jotka sisälsivät haavakuvia sekä ihmisistä että eläimistä. Tavoitteena oli tunnistaa haava-alue terveestä ihosta. Tutkimuksessa todettiin, että mallien esiopettamisella saavutettiin parempia tuloksia verrattuna suoraan alusta asti tavoiteaineistolla koulutettuun malliin. Lisäksi todettiin, että esiopetus pienelläkin otoksella tavoiteaihepiirin kanssa saman alueen opetusaineistosta saatiin parempia tuloksia, kuin suurella otoksella toisen aihepiirin opetusaineistosta.

Lucas ym. (2020, 641–661) kokoavat artikkelissaan kirjoitushetkellä ajankohtaisia ratkaisuja haavojen arviointiin ja seurantaan. Haavojen arvioinnissa tulee huomioda pinta-alan ja syvyyden lisäksi eri kudostyyppien esiintyminen ja laajuus haavapedillä. Kirjoittajat toteavat, että tekoälyyn perustuvien ratkaisujen käytön vakiintuminen hoitotyön ammattilaisten keskuudessa edellyttää käyttäjäystävällisiä, helposti mukana kuljetettavia ja kustannustehokkaita tuotteita, esimerkiksi älypuhelimeen asennettavia sovelluksia. Tärkeää on myös järjestelmien yhdistettävyyks olemassaoleviin potilastietojärjestelmiin.

Goyal ym. (2020, 728–739) ovat kehittäneet konvoluutioneuroverkkopohjaisen arkkitehtuurin DFUNetin diabeettisten jalkahaavojen ja terveen ihon erotteluun valokuvien perusteella. Neuroverkon kouluttamisessa hyödynnettiin datan augmentointia, ja kirjoittajien tavoitteena on ollut tulevaisuudessa asettaa kehitetty opetusaineisto julkisesti saataville. Jatkokehitystarpeiksi artikkelissa todetaan kuvien luokittelun ja haavojen havaitsemisen, tunnistamisen ja luokittelun automatisoinnin, mobiililaitteilla toimivan käyttäjäystävällisen ratkaisun kehittämisen ja tässä työssä kehitetyn ratkaisun laajentamisen myös muiden haavatyyppeiden tunnistamiseen ja luokitteluun.

Niri ym. (2021, 1–11) tutkivat kolmiulotteisen (3D) mallintamisen ja useista eri katselukulmista otettujen haavakuvien vaikutuksia syvän neuroverkon kykyyn erottaa haava-alue ympäröivästä terveestä ihosta. Tutkimuksessa verrattiin keskenään myös eri strategioita, jotka perustuivat kameran etäisyyteen haava-alueesta tai katselukulman jyrkkyyteen. Kuvat otettiin mobiililaitteen kameralla. Tutkimuksessa todettiin, että useiden katselukulmien hyödyntäminen tuotti parempia erottelukykyyn liittyviä tuloksia yksittäiseen kuvauskulmaan perustuvaan malliin verrattuna. Jatkokehitysideana todettiin, että samaa toimintamallia olisi tulevaisuudessa mahdollista hyödyntää myös haavapohjan eri kudostyyppien tunnistamisessa ja erottelussa.

Gutierrez ym. (2021, 1–14) tutkivat haavojen havainnointia kolmiulotteisen (3D) mallintamisen ja lämpökuvauksen yhdistelmällä. Tutkimus suoritettiin kuudella (6) potilaalla käyttäen kuluttajakäyttöön tarkoitettuja, helposti liikuteltavia ja edullisia laitteita eli lämpökameraa ja mobiililaitetta. Tuloksina todettiin, että menetelmien yhdistäminen edistää oikean kuvauskulman löytämistä ja lämpötilan seuranta on mahdollista käyttää haavan paranemisprosessin arvioinnissa. Tulokset todettiin johdonmukaisiksi, mutta potilasaineiston olevan hyvin suppea ja jatkotutkimukset perusteltuja.

Ferreira ym. (2021, 1–19) kehittivät työssään mobiililaitteella toimivan prototyypin haavan koon arviointiin ja mahdollistamaan potilaan sekä haavahoitoon osallistuvien terveydenhuollon ammattilaisten välisen kommunikaation etäyhteyksien avulla. Haavasta otettu valokuva kävi läpi monivaiheisen käsittelyprosessin. Koon määrittämiseksi käytettiin valokuvan metatietoja kuten resoluutiota sekä kuvan ottaneen henkilön suorittamia mittaustietoja haava-alueesta, ja näiden avulla suoritettiin muunnokset mitattujen arvojen ja pikselimäärien välillä. Toisessa vaiheessa kehitettiin mobiilisovellus, jonka avulla potilas pystyi toimittamaan itse ottamansa kuvan haavasta terveydenhuollon ammattilaisen arvioitavaksi. Kliinikko suoritti haavan koon määrittämisen sovelluksen avulla ja pystyi tarvittaessa kommunikoimaan potilaan kanssa sähköpostitse. Sovelluksen käyttöliittymä vaihteli ulkoasultaan ja toiminnoiltaan käyttäjän profiiliin (potilas/terveydenhuollon ammattilainen)

mukaisesti. Kehitetyn ratkaisun rajoitteiksi tunnistettiin pieni potilasmäärä ($n = 10$), kuvien laadun, kuvausetäisyyden ja valaistusolosuhteiden vaihteluiden vaikutukset tuloksiin sekä potilaiden vaihtelevat valmiudet mobiilisovelluksien käyttöön. Jatkokehityksen osalta todettiin tarve suuremmalle kuva-aineistolle ja kuvausalueelle asetettavalle referenssimerkille etäisyyden määrittämiseksi luotettavalla tavalla. Lisäksi korostettiin terveydenhuollon ammattilaisten osallistumisen olevan keskeistä tulevaisuuden kehitysprojekteissa.

Howellin ym. (2021, 1–12) tutkimuksen tavoitteena oli kehittää kehysympäristö tekoälyyn perustuvien, haavanhoidon tukena käytettävien digitaalisten ratkaisujen arviointiin. Tutkimuksessa vertailtiin tekoälyn ja kokeneen klinikon suoritumista haava-alueen koon ja granulaatiokudoksen prosentuaalisen osuuden tunnistamisessa anonymisoitujen haavakuvien ($n = 199$) perusteella. Vertailu tapahtui virhejakauman perusteella, eikä tilastollisesti merkitsevää eroa todettu. Tutkimuksessa virheen mahdollisuus kasvoi pienten haava-alueiden kohdalla sekä tekoälyn että klinikon suorittamassa arvioinnissa. Haasteeksi todettiin eroavaisuudet klinikoiden suorittamien arviointien välillä ja tutkimuksessa käytettyjen haavakuvien laadullinen vaihtelu. Tutkimuksen suorittajat toteavat tekoälypohjaisten ratkaisujen jatkokehitystarpeen kroonisten haavojen hoidon tehostamiseksi ja parempien lopputulosten saavuttamiseksi.

Doulamis ym. (2021, 1–23) määrittelivät tutkimuksessaan tekniset vaatimukset ja laatuvaatimukset noninvasiiviselle eli kudoksiin kajoamattomalle laitteelle, jolla voidaan seurata diabeettisia haavoja niin kotiooloissa kuin ammattilaistoiminnassakin. Laitteen toiminta perustuu hyperspektri- ja lämpökameroihin, joilla tutkitaan kudosten happeutumiseen liittyviä biomarkkereita ja arvioidaan mikroverenkierron tilaa sekä riskiä uusien haavojen syntymiselle. Tavoitteena kustannustehokas ratkaisu, joka soveltuisi myös potilaiden omaan käyttöön. Artikkelin kirjoittamishetkellä ratkaisun validointi oli toteutumassa lähitulevaisuudessa eurooppalaisessa yhteistyössä.

Chan ym. (2022) tutkivat koneoppimisen ja konenäön käyttöä palovammojen seurannassa. Konvoluutioneuroverkkoa koulutettiin digitaalisilla värikuvilla palovamman syvyyden luokitteluun, granulaatiokudoksen tunnistamiseen

ja palovamman laajuuden mittaamiseen. Mallia testattiin oikean potilaan palovamman säännöllisessä seurannassa, jossa kuvat otettiin älypuhelimien kameralla. Seurannassa malli mittasi palovamman kokoa luotettavasti kuvausalueelle asetetun vertailumerkin avulla ja klinikan vakioiduissa valaistusolosuhteissa. Malli tunnisti myös granulaatiokudoksen vähenemisen ennustaen palovamman paranemista, mikä todettiin myös kliinisessä seurannassa.

Mohammed ym. (2022, 1–14) tutkivat tekoälyyn perustuvan ratkaisun vaikutusta ajankäyttöön haavan arvioinnissa verrattuna klinikon manuaalisesti suorittamaan arviointiin. Päätoimisesti erilaisten haavojen seuranta ja hoitoa suorittavat terveydenhuollon ammattilaiset ($n = 5$) suorittavat haavojen ($n = 115$) arvioinnin sekä manuaalisesti (haavojen luokittelu, kuvaaminen ja mittaaminen, pinta-alan laskeminen ja tietojen tallentaminen potilastietojärjestelmään) että mobiililaitteessa toimivaa tekoälypohjaista sovellusta Swiftiä käyttäen ja mittasivat molempiin menetelmiin tarvittavan ajan. Tutkimuksessa todettiin, että haavan kuvaaminen, koon mittaaminen ja pinta-alan määrittäminen toteutuivat merkittävästi nopeammin tekoälyä hyödyntämällä. Tekoälyä käyttämällä haavan arviointiin tarvittiin puolet vähemmän aikaa ja laadukkaan haavakuvan ottaminen onnistui huomattavasti useammin ensimmäisellä yrityksellä manuaalisiin menetelmiin verrattuna. Tutkimuksen rajoitteiksi todettiin sen suorittaminen yksittäisessä avoterveydenhuollon yksikössä, jolloin tulokset eivät välttämättä ole suoraan yleistettävissä kaikkiin potilasryhmiin ja terveydenhuollon toimijoiden osaamiseen digitaalisten työvälineiden hyödyntämisessä.

Ramachandram ym. (2022) vertaavat artikkelissaan klinikoiden ($n = 5$) ja kahteen konvoluutioneuroverkkoarkkitehtuuriin perustuvan älypuhelimella käytettävän sovelluksen suoriutumista haavapedin kudostyyppien tunnistamisessa ja määrällisten osuuksien arvioinnissa.

Konvoluutioneuroverkkopohjainen sovellus (Swift Skin and Wound) on koulutettu huomattavan suurella ja sisällöltään laajalla luokitellulla kuva-aineistolla, luokiteltu lääkinnälliseksi laitteeksi ja käytössä tuhansissa

organisaatioissa Pohjois-Amerikassa. Laitteen käyttö edellyttää haavan läheisyyteen kiinnitettävää tarraa (HealX) referenssimerkiksi. Kliinikoiden suorittamien arviointien välillä esiintyi huomattavaa vaihtelua, eniten epitelisaatiokudoksen tunnistamisessa. Swiftin suorittama luokittelu tapahtui älypuhelimella lähes reaaliaikaisesti. Sovelluksen käyttötarkoitus on tiedon keruu, ei diagnoosiin tai hoitomuodon valintaan liittyvä päätöksenteko. Kirjoittajien sidonnaisuuksista on todettava, että usempi heistä on tutkimuksen suoritushetkellä ollut Swift Medical Inc:n palveluksessa.

Zhang ym. (2022, 79502–79515) kartoittavat artikkelissaan kirjallisuuteen perustuen eri syväoppimismallien käyttöä kuva-aineistojen luokittelu-, tunnistus- ja segmentointitehtäviin, arvioivat julkisesti saatavilla olevien datasettien laatua ja kokoavat datan esikäsittelyyn käytettyjä lähestymistapoja. Syväoppimismallit soveltuvat hyvin edellä lueteltuihin tehtäviin ja voivat parantaa terveydenhuollon ammattilaisten tehokkuutta diagnostiikassa sekä tukea rajallisia terveydenhuollon resursseja. Kuva-aineistojen analysointiin syväoppimisen käytöllä on nähtävissä lupaavia tuloksia. Haasteiksi on tunnistettu laajan ja sisällöltään edustavan, standardoidun julkisen kuva-aineiston puuttuminen, aineiston luokitteluun tarvittavan asiantuntijatyön korkeat kustannukset ja suurta laskentatehoa edellyttävien ratkaisujen yhteensopivuus käyttäjäystävällisten mobiililaitteiden kanssa.

Reifs ym. (2023, 1–12) esittelevät artikkelistaan kirjoitushetkellä käytössä olleita laitteita ja sovelluksia haava-alueen arviointiin. Esitellyistä ratkaisuista osa on luokiteltu lääkinällisiksi laitteiksi. Mittaukset toteutetaan kaksi- tai kolmiulotteisesti ja yhdessä tuotteessa hyödynnetään infrapunakameraa haava-alueen lämpötilan määrittämiseksi. Toteutetussa tutkimuksessa vertailtiin eri konvoluutioneuroverkkopohjaisten mallien suoriutumista haava-alueen tunnistamisessa, koon määrittämisessä ja kudostyyppien luokittelussa älypuhelimien kameralla otetuista kuvista. Tulokset olivat perinteisiin toimintatapoihin verrattuna parempia, mutta virheille altistivat vaihtelevat valaistusolosuhteet ja referenssimerkin paikan vaihtuminen.

Kairys ym. (2023, 1–29) ovat tehneet systemaattisen kirjallisuuskatsauksen kotioloissa suoritettavien diabeettisten jalkahaavojen seurantaedellytyksistä tekoälyratkaisujen avulla. Katsauksessa arvioitiin julkisesti saatavilla olevia kuva-aineistoja, menetelmiä kuva-aineiston esikäsittelyyn, datan augmentointia eli kuva-aineiston kasvattamista ja piirteiden poimintaa. Katsauksessa todettiin tuleviksi tutkimustarpeiksi vaihtelevissa olosuhteissa otettujen kuvien esikäsittelyn strategian parantaminen, datan augmentoinnin hyväksyttävän tason määrittäminen ja opetusaineiston kasvattaminen yhdistelemällä eri julkisista lähteistä saatavilla olevaa dataa. Lisäksi ehdotettiin ohjaamattoman tai löyhästi ohjatun syväoppimismallin kehittämistä semanttiseen segmentaatioon.

Das ym. (2023, 1–17) kokoavat katsauksessaan tavoitteita diabeettisten jalkahaavojen tunnistamisen automatisoinnin saavuttamiseksi. Artikkelissa on todettu syväoppimiseen perustuvien konvoluutioneuroverkkojen olevan lupaavampia verrattuna perinteisiin koneoppimismalleihin. Tulevaisuuden kehityskohteiksi on todettu opetusdatan annotoinnin eli tietoa kuvailevan metatiedon tuottamisen automatisointi, syväoppimismallien suorituskyvyn ja luotettavuuden parantaminen, ratkaisujen soveltuvuus mobiililaitteilla käytettäväksi ja potilaan kotoa käsin suoritettavan seurannan mahdollistamiseksi. Lisäksi tulisi kehittää kuvien esikäsittelytekniikoita segmentoinnin tehostamiseksi ja virheiden analysointia, jotta olisi mahdollista minimoida valaistusolosuhteiden sekä kuvien ottamiseen käytetyn laitteiston vaihtelusta johtuvat virhelähteet.

Khalil ym. (2023, 1–21) kehittivät uutta konvoluutioneuroverkkopohjaista mallia hiertymähaavojen ja iskeemisten eli hapenpuutteesta johtuvien diabeettisten jalkahaavojen automaattiseen luokitteluun. Opetuksessa hyödynnettiin augmentoitua dataa. Vertailussa aiemmin kehitettyihin ratkaisuihin mallilla saavutettiin lupaavia tuloksia. Tutkimuksen rajoitteiksi todettiin rajallinen opetusdatan määrä ja ylisovituksen seurauksena heikko yleistettävyys etnisesti eroaviin väestöryhmiin.

Ahsan ym. (2023, 1–10) vertailivat tutkimuksessaan eri konvoluutioneuroverkkomallien suoriutumista diabeettisten jalkahaavojen

iskemian eli hapenpuutteen ja infektion eli tulehduksen tunnistamisessa. Tulokset olivat lupaavia, mutta mallit tunnistivat paremmin hapenpuutteeseen kuin tulehdukseen viittaavia merkkejä. Tutkimusryhmä on asettanut tulevaksi tavoitteekseen tulehdukseen viittaavien merkkien paremman tunnistamisen konvoluutioneuroverkkoratkaisun avulla.

Curti ym. (2024, 1–9) kehittivät työssään toimintokokonaisuuden, jossa esikoulutettu syväoppimismalli suoritti haavojen arviointia älypuhelimella otettujen valokuvien perusteella ja pisteytti ne PWAT-työkalun asteikon mukaisesti. Neuroverkon suorittamaa pisteytystä verrattiin klinikoiden suorittamaan pisteytykseen ja uudella datasetillä suoritetussa testauksessa todettiin neuroverkon oppiman ennustemallin korkea suorituskyyky. Mallin suorittama piirteiden poiminta kohdistui sekä varsinaiseen haava-alueeseen että haavaa ympäröivään ihoon. Pisteytyksessä ei huomioitu haavojen koon määrittämistä, koska tämä olisi edellyttänyt vakioituja kuvausolosuhteita ja vaikuttanut rajoittavasti järjestelmän käytettävyyteen aidoissa hoitotyön ympäristöissä. Tutkimustulosten tulkinassa rajoitteiksi tunnistettiin väestöpohjan kansallisen edustavuuden rajallisuus, opetusmateriaalissa PWAT-asteikon ääripäiden puuttuminen ja valokuvien ottoon käytetyn laitteiston sekä valaistusolosuhteiden yksipuolisuus.

Kolli ym. (2024, 1–18) tutkivat eri neuroverkoarkkitehtuurien ja regressiomallien yhdistelmien kykyä ennustaa haavan paranemiseen kuluva aikaa. Ennusteen perusteena käytettiin haava-alueen ja sitä ympäröivän terveen ihon erottamisen lisäksi haavapedissä havaittavia kudostyypppejä (granulaatiokudos, fibriinikate ja nekroottinen kudos) sekä niiden laajuutta. Mallien opetuksessa ja testauksessa käytettiin sekä luokittelemattomia että aikasarjaluokiteltuja digitaalisia värikuvia, jotka edustivat sekä ihmisillä että koirilla esiintyviä haavoja. Testatuilla malleilla todettiin suorituskyyvyn paranevan, kun opettamiseen käytettiin augmentoitua dataa eli kasvatettua kuva-aineistoa, jossa alkuperäistä aineistoa on suurennettu lisäämällä esimerkiksi kierrettyjä ja peilikuvaksi käännettyjä versioita alkuperäisistä kuvista aineistoon.

4.2 Käytännön sovellukset

Konenäköä ja tekoälyä hyödyntäviä ratkaisuja on esitelty taulukossa (taulukko 3), joka erillisenä liitteenä (liite 1). Osa ratkaisuista on luokiteltu lääkinällisiksi laitteiksi Yhdysvaltain elintarvike- ja lääkeviraston FDA:n (Food and Drug Administration) rekisterissä. (Aldaz ym. 2015, 3–4; Lucas ym. 2020, 644–647; Reifs ym. 2023, 2–3.)

4.3 Konenäön mahdollisuudet

Artikkelikatsauksen perusteella tekoälyn ja konenäön käytölle kroonisten haavojen hoidossa on löydettävissä useita puoltavia tekijöitä.

Tekoälyratkaisujen käyttö on vähemmän altis mittaustekniikoissa tapahtuville vaihteluille ja niistä seuraaville virheille. Tekoäly voi tukea haavahoidon ja seurannan tasalaatuisen dokumentaation toteutumista sekä lyhentää merkittävästi eri vaiheisiin käytettyä aikaa. Konenäköön perustuvien ratkaisujen käyttö ei välttämättä edellytä kontaktia haava-alueeseen, mikä vähentää potilaan kokemaa kipua, epämukavuutta ja tulehdusriskiä.

4.4 Konenäön rajoitteet

Lähes kaikissa edellä luvussa 4.1 käsitellyissä tutkimuksissa tunnistettiin tarve kameran suoralle kulmalle haava-alueeseen nähden, jotta pinta-alan ja tilavuuden määrittäminen olisi mahdollista. Lisäksi mittausten suorittaminen edellytti kuvausalueelle haavan läheisyyteen asetettavaa referenssimerkkiä, kuten viivoitinta tai koon ja/tai värimäärittelyn tueksi kehitettyä tarraa.

Terveystietojen ja sensitiivisen datan käsittely asettaa omia erityisvaatimuksiaan kehitettävien ratkaisujen tietoturvalle. Konenäköön perustuvien ratkaisujen laajemman hyödyntämisen ja käytön vakiinnuttamisen ehdottomana edellytyksenä on määrällisesti suuri, laadukas ja sisällöllisesti kattava opetusaineisto, jollaista ei tällä hetkellä ole julkisesti saatavilla.

5 Lopuksi

Tekoälyn ja konenäön soveltamismahdollisuudet kroonisten haavojen hoidossa ovat olleet useiden tutkimusten aiheena ja tuloksiltaan lupaavia.

Tekoälypohjaisten ratkaisujen vakiintuminen osaksi hoitotyön menetelmiä edellyttää vielä pitkäjänteistä tutkimus- ja kehitystyötä sekä laajaa, laadukasta ja sisällöltään kattavaa opetusaineistoa. Tulevaisuudessa ratkaisu voisi löytyä synteettisestä datasta eli tekoälyn luomista haavakuvista, mutta tämänkin toteutumisen edellytyksenä on riittävän ja aitoihin potilastietoihin perustuvan opetusdatan saatavuus. Terveystietoihin kuuluvaksi luokiteltavat haavakuvat ovat tarkasti suojattuja, käyttö vahvasti säänneltyä ja yleisen tietosuoja-asetuksen (GDPR) alaista toimintaa.

Sosiaali- ja terveysalan rajalliset resurssit voisivat tulevaisuudessa hyötyä kustannustehokkaasta tavasta käyttää tekoälyyn perustuvia ratkaisuja.

Yhdenmukaisen, tasalaatuisen dokumentaation ja seurannan mahdollistavat ratkaisut voisivat myös parantaa potilasturvallisuutta ja potilaiden elämänlaatua. Ratkaisujen tulisi olla helposti käyttöön otettavissa esimerkiksi mobiililaitteisiin asennettavina sovelluksina, ja toimia erilaisissa hoitotyön toteutukseen liittyvissä toimintaympäristöissä.

Lähteet

Ahsan, M.; Naz, S.; Ahmad, R.; Ehsan, H. & Sikandar, A. 2023. A Deep Learning Approach for Diabetic Foot Ulcer Classification and Recognition. *Information* 2023, 14, 36, 1–10.

Aldaz, G.; Shluzas, L. A.; Pickham, D.; Eris, O.; Sadler, J.; Joshi, S. & Leifer, L. 2015. Hands-Free Image Capture, Data Tagging and Transfer Using Google Glass: A Pilot Study for Improved Wound Care Management. *PLoS ONE* 2015, 10(4): e0121179, 1–21.

Alzubaidi, L.; Fadhel, M. A.; Al-Shamma, O.; Zhang, J.; Santamaría, J.; Duan, Y. & Oleiwi, S. R. 2020. Towards a Better Understanding of Transfer Learning for Medical Imaging: A Case Study. *Applied Sciences* 2020, 10, 4523, 1–21.

Bates-Jensen, B. 2001. Bates-Jensen Wound Assessment Tool. Instructions for use. Viitattu 12.04.2024.

https://aci.health.nsw.gov.au/_data/assets/pdf_file/0010/388243/22.-Bates-Jensen-wound-assessment-tool-BWAT.pdf

Chan, H. O.; Joshi, R.; Morzycki, A.; Pun, A. C.; Wong, J. N. & Hong, C. 2022. Using Computer Vision-Based Algorithms Trained on Mobile-Device Camera Images for Monitoring Burn Wound Healing. *Journal of Burn Care & Research*, 2022 Apr; 43 (Suppl 1): S64. Viitattu 28.01.2024.

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8945745/>

Council of Europe 2024. History of Artificial Intelligence. Viitattu 12.05.2024.

<https://www.coe.int/en/web/artificial-intelligence/history-of-ai>

Curti, N.; Merli, Y.; Zengarini, C.; Starace, M.; Rapparini, L.; Marcelli, E.; Carlini, G.; Buschi, D.; Castellani, G. C.; Piraccini, B. M.; Bianchi, T. & Giampieri, E. 2024. Automated Prediction of Photographic Assessment Tool in Chronic Wound Images. *Journal of Medical Systems* 2024, 48:14, 1–9.

Das, S. K.; Roy, P.; Singh, P.; Diwakar, M.; Singh, V.; Maurya, A.; Kumar, S.; Kadry, S. & Kim, J. 2023. Diabetic Foot Ulcer Identification: A Review. *Diagnostics* 2023, 13, 1998, 1–17.

Doulamis, A.; Doulamis, N.; Angeli, A.; Lazaris, A.; Luthman, S.; Jayapala, M.; Silbernagel, G.; Napp, A.; Lazarou, I.; Karalis, A.; Hoveling, R.; Terzopoulos, P.;

Yamas, A.; Georgiadis, P.; Maulini, R. & Muller, A. 2021. A Non-Invasive Photonics-Based Device for Monitoring of Diabetic Foot Ulcers: Architectural/Sensorial Components & Technical Specifications. *Inventions* 2021, 6, 27, 1–23.

Elements of AI 2024. Neuroverkot. Tekoälyn perusteet -verkkokurssi 2024. MinnaLearn, Helsingin yliopisto. Viitattu 15.04.2024.
<https://course.elementsofai.com/fi/>

Ferreira, F.; Pires, I. M.; Ponciano, V.; Costa, M.; Villasana, M. V.; Garcia, N. M.; Zdravevski, E.; Lameski, P.; Chorbev, I.; Mihajlov, M. & Trajkovic, V. 2021. Experimental Study on Wound Area Measurement with Mobile Devices. *Sensors* 2021, 21, 5752, 1–19.

Gardner, S. E.; Frantz, R. A.; Bergquist, S. & Shin, C. D. 2005. A prospective study of the pressure ulcer scale for healing (PUSH). *The journals of gerontology. Series A, Biological sciences and medical sciences*, Jan 2005, 60(1), 93-7. Viitattu 12.04.2024. <https://pubmed.ncbi.nlm.nih.gov/15741289/>

Goto, T.; Nakagami, G.; Nakai, A.; Noyori, S.; Sasaki, S.; Hayashi, C.; Miyagaki, T.; Akamata, K. & Sanada, H. 2017. Utility of a three-dimensional wound measurement device in pressure ulcers. *Chronic Wound Care Management and Research* 2017:4, 129–133.

Goyal, M.; Reeves, N. D.; Davison, A. K.; Rajbhandari, S.; Spragg, J. & Yap, M. H. 2020. DFUNet: Convolutional Neural Networks for Diabetic Foot Ulcer Classification. *IEEE Transactions on emerging topics in computational intelligence*, October 2020, vol.4, no. 5, 728–739.

Gutierrez, E.; Castañeda, B.; Treuillet, S. & Hernandez, I. 2021. Multimodal and Multiview Wound Monitoring with Mobile Devices. *Photonics* 2021, 8, 424, 1–14.

Harris, C.; Bates-Jensen, B.; Parslow, N.; Raizman, R. & Singh, M. 2009. The Bates-Jensen Wound Assessment Tool (BWAT): Development of a Pictorial Guide for Training Nurses. *Wound Care Canada*, volume 7, number 2, 2009, 33–38. Viitattu 12.04.2024.
https://www.southwesthealthline.ca/healthlibrary_docs/b.6.1c.bates-jensenwoundassessmttoolarticle.pdf

Houghton, P. E.; Kincaid, C. B.; Campbell, K. E.; Woodbury, M. G. & Keast, D. H. 2000. Photographic Assessment of the Appearance of Chronic Pressure and Leg Ulcers. *Ostomy/Wound Management* 2000, 46(4), 20–30. Viitattu 12.04.2024.

https://www.southwesthealthline.ca/healthlibrary_docs/b.9.3c.pwatresources.pdf

Houghton, P. E. 2013. Photographic Wound Assessment Tool (PWAT). Version 2.0 Revised. Viitattu 12.04.2024. <https://estim4wounds.ca/wp-content/uploads/2013-Revised-PWAT-drop-down-menu.pdf>

Howell, R. S.; Liu, H. H.; Khan, A. A.; Woods, J. S.; Lin, L. J.; Saxena, M.; Saxena, H.; Castellano, M.; Petrone, P.; Slone, E.; Chiu, E. S.; Gillette, B. M. & Gorenstein, S. A. 2021. Development of a Method for Clinical Evaluation of Artificial Intelligence-Based Digital Wound Assessment Tools. *JAMA Network Open* 2021; 4(5):e217234, 1–12. Viitattu 28.01.2024.

https://jamanetwork.com/journals/jamanetworkopen/fullarticle/2779954?utm_campaign=articlePDF&utm_medium=articlePDFlink&utm_source=articlePDF&utm_content=jamanetworkopen.2021.7851

Hsu, J.-T.; Chen, Y.-W.; Ho, T.-W.; Tai, H.-C.; Wu, J.-M.; Sun, H.-Y.; Hung, C.-S.; Zeng, Y.-C.; Kuo, S.-Y. & Lai, F. 2019. Chronic wound assessment and infection detection method. *BMC Medical Informatics and Decision Making* 2019, 19:99, 1–20.

Japanese Society of Pressure Ulcers 2014. DESIGN-R scoring manual. Japanese Society of Pressure Ulcers. Department of Gerontological Nursing/Wound Care Management, Graduate School of Medicine, The University of Tokyo.

Jopling, J. K.; Pridgen, B. C. & Yeung, S. 2021. Setting Assessment Standards for Artificial Intelligence Computer Vision Wound Annotations. *JAMA Network Open* 2021; 4(5):e217851, 1–3.

Kairys, A.; Pauliukiene, R.; Raudonis, V. & Ceponis, J. 2023. Towards Home-Based Diabetic Foot Ulcer Monitoring: A Systematic Review. *Sensors* 2023, 23, 3618, 1–29.

Khalil, M.; Naeem, A.; Naqvi, R. A.; Zahra, K.; Moqurrah, S. A. & Lee, S.-W. 2023. Deep Learning-Based Classification of Abrasion and Ischemic Diabetic

Foot Sores Using Camera-Captured Images. *Mathematics* 2023, 11, 3793, 1–21.

Kielo-Viljamaa, E. 2021. Haavapohjan systemaattista valmistelua varten kehitetty kansainvälinen TIMERS-malli. Käypä hoito -artikkeli, Helsinki: Suomalainen Lääkäriseura Duodecim, 2021. Viitattu 28.01.2024.
<https://www.kaypahoito.fi/nix02884>

Kolli, A.; Wei, Q. & Ramsey, S. A. 2024. Predicting Time-to- Healing from a Digital Wound Image: A Hybrid Neural Network and Decision Tree Approach Improves Performance. *Computation* 2024, 12, 42, 1–18.

Krooninen alaraajahaava 2021. Käypä hoito -suositus. Suomalaisen Lääkäriseuran Duodecimin ja Suomen Ihotautilääkäriyhdistyksen asettama työryhmä. Helsinki: Suomalainen Lääkäriseura Duodecim, 2021. Viitattu 28.01.2024. www.kaypahoito.fi

Lucas, Y.; Niri, R.; Treuillet, S.; Douzi, H. & Castaneda, B. 2020. Wound Size Imaging: Ready for Smart Assessment and Monitoring. *Advances in Wound Care*, volume 10, number 11, 641–661.

Mohammed, H. T.; Bartlett, R. L.; Babb, D.; Fraser, R. D. J. & Mannion, D. 2022. A time motion study of manual versus artificial intelligence methods for wound assessment. *PLoS ONE* 2022, 17(7): e0271742, 1–14.

National Pressure Ulcer Advisory Panel n.d. Pressure Ulcer Scale for Healing (PUSH). PUSH Tool 3.0. PUSH Tool Version 3.0: 9/15/98. Viitattu 12.04.2024.
<https://www.sralab.org/sites/default/files/2017-06/push3.pdf>

Niri, R.; Gutierrez, E.; Douzi, H.; Lucas, Y.; Treuillet, S.; Castaneda, B. & Hernandez, I. 2021. Multi-View Data Augmentation to Improve Wound Segmentation on 3D Surface Model by Deep Learning. *IEEE Access* 2021, volume 9, 1–11.

Ramachandram, D.; Ramirez-GarciaLuna, J. L.; Fraser, R. D. J.; Martínez-Jiménez, M. A.; Arriaga-Caballero, J. E. & Allport, J. 2022. Fully Automated Wound Tissue Segmentation Using Deep Learning on Mobile Devices: Cohort Study. *JMIR Mhealth Uhealth* 2022, Apr; 10(4): e36977. Viitattu 13.04.2024.
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9077502/?report=printable>

Reifs, D.; Casanova-Lozano, L.; Reig-Bolano, R. & Grau-Carrion, S. 2023. Clinical validation of computer vision and artificial intelligence algorithms for wound measurement and tissue classification in wound care. *Informatics in Medicine Unlocked* 37 (2023) 101185, 1–12.

Sánchez-Jiménez, D.; Buchón-Moragues, F.; Escutia-Muñoz, B. & Botella-Estrada, R. 2019. Development of Computer Vision Applications to Automate the Measurement of the Dimensions of Skin Wounds. *Proceedings* 2019, 19, 18, 1–4.

Stanford University School of Engineering 2017. CS231n, Lecture Collection 1–16. Viitattu 05.03.2024.

https://www.youtube.com/watch?v=vT1JzLTH4G4&list=PLf7L7Kg8_FNxHATtLwDceyh72QQL9pvpQ

Suomen Haavanhoitoyhdistys ry 2019. Avoimen haavan VPKM-väriluokitushelpperi. Suomen Haavanhoitoyhdistys ry, 2019. Viitattu 06.04.2024.

https://www.shhy.fi/wp-content/uploads/2021/03/SHHY_PDF_hoitosuositukset_helpperit_VPKM_2019.pdf

Terveyskylä 2021a. Mikä on haava? Haavatalo, Terveyskylä 2021. Viitattu 12.02.2024. <https://www.terveyskyla.fi/haavatalo/tietoa-haavoista/johdanto-haavoihin/mik%C3%A4-on-haava>

Terveyskylä 2021b. Haavan paikallishoitotuotteen valinta. Haavatalo, Terveyskylä 2021. Viitattu 05.04.2024.

<https://www.terveyskyla.fi/haavatalo/tietoa-haavoista/haavan-paikallishoidon-perusteet/haavan-paikallishoitotuotteen-valinta>

Tuominen, H. 2024. Johdatus tekoälyn taustalla olevaan matematiikkaan. Kurssimateriaali, Jyväskylän yliopisto 2024. Viitattu 15.04.2024.

<https://tim.jyu.fi/lecture/kurssit/tie/tiep1000/tekoaly-mat/moniste#DKUvbnUuGytQ>

Voulodimos, A.; Doulamis, N.; Doulamis, A. & Protopapadakis, E. 2018. Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*, volume 2018, ID 7068349, 1-13.

Young, T. 2015. Accurate Assessment of Different Wound Tissue Types. *Wound Essentials* 2015, vol 10, no1, 51–54.

Zhang, R.; Tian, D.; Xu, D.; Qian, W. & Yao, Y. 2022. A Survey of Wound Image Analysis Using Deep Learning: Classification, Detection, and Segmentation. IEEE Access 2022, volume 10, 79502–79515.

Tekoälyyn ja konenäköön perustuvia ratkaisuja

Taulukko 3. Haavojen arviointiin kehitettyjä ratkaisuja (Aldaz ym. 2015, 3–4; Lucas ym. 2020, 644–647; Reifs ym. 2023, 2–3).

Tuotenimi	Kuvaus	Muuta	Lähde
Pictzar CDM®, Pictzar PRO®	Ohjelma mittaa haavan kokoa digitaalisten valokuvien avulla, viivoitin asetettava kuvausalueelle.	Ei tarvitse tietoa kameran ja kuvattavan kohteen välisestä etäisyydestä.	Reifs ym. 2023.
Wound Matrix®	Etähoitoon käytetty ohjelma, mittaa ihovaurioiden pinta-alaa.	Ensisijaisesti yritysten ja organisaatioiden käyttöön.	Reifs ym. 2023.
WoundWiselQ®	Ohjelma haavojen koon mittaukseen.	Yhteensopiva vain iOS-käyttöjärjestelmän kanssa.	Reifs ym. 2023.
Visitrak™	Lääkinnällinen laite, määrittää haavan koon kaksikerroksisen kalvon avulla jäljennetystä haavan muodosta. Puhdas kalvokerros asetetaan laitteen luettavaksi, käyttäjä määrittää haavan reunat manuaalisesti laitteen näytöltä.	FDA II	Reifs ym. 2023; Lucas ym. 2020.
SilhouetteMobile™	Lääkinnällinen laite, käyttää laserskannerin	FDA I	Reifs ym.

Tuotenimi	Kuvaus	Muuta	Lähde
	ja kameran yhdistelmää yhdistettynä mobiililaitteeseen. Laserilla kartoitetaan haavan pinnan muoto, mobiililaite luo 3D-mallin haavasta. Käyttäjä piirtää laitteelle haavan reunat ja pinta-ala lasketaan.		2023; Lucas ym. 2020.
AreaMe®	Mobiilisovellus, mittaa haavan koon 1x1cm verkon avulla. Haavan reunat määritettävä edeltävästi läpinäkyvän kalvon avulla. Datan siirto potilastieto-järjestelmään.	Luo graafisen esityksen haava-alueen muutoksista.	Reifs ym. 2023.
NDKare®	Mobiilisovellus haavan koon määrittämiseen.	2D- ja 3D-mittaukset.	Reifs ym. 2023.
imitoMeasure®	Digitaalinen haavan mittaus.	Ei tarvetta skaalaamiselle (referenssille).	Reifs ym. 2023.
WoundVue®	Haavan pinta-alan ja tilavuuden määrittäminen sekä kudostyyppien luokittelu.	-	Reifs ym. 2023.
Planimetor®	Haava-alueen mittaaminen haavan ympärille aseteltavien	-	Reifs ym. 2023.

Tuotenimi	Kuvaus	Muuta	Lähde
	kalibraatiomerkkien avulla.		
Swift Wound®	Sovellus toimii yhdessä infrapunakameran kanssa, mittaa haava-alueen lämpötilaa ja arvioi mittauksen tarkkuutta.	-	Reifs ym. 2023.
WoundZoom	Erikoissuunniteltu tabletti sisäänrakennetulla 3D-sensorilla. Määrittää haavan mitat ja ohjelma laskee pinta-alan ja tilavuuden.	Ammattilaisille mahdollisuus lämpökartan luontiin.	Lucas ym. 2020.
InSight	iPad-mobiililaitteen kanssa toimiva värisensori ja kuvankäsittelyohjelma.	3D-mallinnus, kudostyyppien tunnistus, haava-alueen erottaminen taustasta.	Lucas ym. 2020.
i:X Wound Intelligence	Takaisin heijastuvaan näkyvään valoon (fluoresenssi) perustuva kuvantamismenetelmä. Kannettava kosketusnäytöllinen laite.	Bakteerien havaitsemiseen. Laitteen lähettämä violetti valo näyttää haavan vihreänä ja haitalliset bakteerit punaisena.	Lucas ym. 2020.
SnapshotNIR	Infrapunavalolla arvoidaan hemoglobiiniin sitoutuneen hapen	Haavan paranemis-edellytysten arviointi.	Lucas ym. 2020.

Tuotenimi	Kuvaus	Muuta	Lähde
	osuutta ja kudosten happeutumista haava-alueella.		
HyperView™	Pinnallisten kudosten happeutumisen arviointiin käytetty laite.	FDA II	Lucas ym. 2020.
PeriCam PSI NR	Infrapunakuvantamista hyödyntävä ratkaisu kudosten verenkierron kartoittamiseen.	Vaatii kuljetusvälineen ja liikuteltavan kiinnitysvarren.	Lucas ym. 2020.
Scout solution	Visuaalista ja infrapunakuvantamista yhdistävä laite, haavan rakenteen ja biologisten muuttujien määrittäminen lämpötilaerojen avulla.	-	Lucas ym. 2020.
Epic Haiku	Älypuhelimessa toimiva mobiilisovellus haavojen kuvaamiseen ja tietojen siirtämiseen potilastietojärjestelmään. Tekstikuvaus syötetään manuaalisesti.	Kuvat eivät tallennu mobiililaitteen muistiin tietosuojasyistä.	Aldaz ym. 2015.
MOWA (Mobile Wound Analyzer)	Haavojen kuvaaminen, pinta-alan laskeminen ja kudostyyppien tunnistus.	Android-laitteille, ei yhdistettävissä potilasjärjestelmiin.	Aldaz ym. 2015.
Google Glass	Päähän silmälasien kaltaisesti asetettava laite otettujen kuvien ja	Koulutus- ja konsultaatiokäytössä hyviä kokemuksia.	Aldaz ym. 2015.

Tuotenimi	Kuvaus	Muuta	Lähde
	ympäristön tarkasteluun samanaikaisesti.		
MAVIS III	Kameran avulla haavan pinta-alan, tilavuuden ja ympäryksen mittaust.	Ammattilaiskäyttöön, korkea hinta ja koulutustarve.	Aldaz ym. 2015.