



Personointialgoritmien vaikutus mobiilisovellusten käyttäjäkokemukseen

Oulun yliopisto
Tietojenkäsittelytiede
LuK-Tutkielma
Viljam Haanpää
2025

Tiivistelmä

Personointialgoritmit ovat keskeisessä asemassa nykyaikaisissa mobiilisovelluksissa, kuten sosiaalisen median alustoilla, verkkokaupoissa ja suoratoistopalveluissa. Henkilökohtaisen sisällön tarjoaminen on osoittautunut tehokkaaksi keinoksi sitouttaa käyttäjiä ja parantaa heidän käyttäjäkokemustaan. Tämän tutkimuksen tarkoituksena on tutkia, miten personointialgoritmit vaikuttavat mobiilisovellusten käyttäjäkokemukseen, sekä mitä haasteita niiden toteuttamiseen ja vastuulliseen käyttöön liittyy.

Valitsin tämän aiheen, koska kuluttajana minua kiehtoo, miten päivittäin käyttämäni mobiilisovellukset onnistuvat personoimaan näkymän juuri minulle sopivaksi. Lisäksi aihe kiinnostaa minua ammatillisesta näkökulmasta, sillä työskentelen tällä hetkellä mobiilisovellusten kehittämisen parissa, ja haluan syventää ymmärrystäni niiden toiminnasta ja käyttäjäkokemuksen optimoinnista.

Avainsanat

Personointialgoritmit, Mobiilisovellukset, Käyttäjäkokemus, Hyperpersonointi,

Yksityisyydensuoja

Ohjaaja

Lehtori, Mikko Rajanen

Keskeiset käsitteet

CF – *Collaborative Filtering, kollaboratiivinen suodatus*

CBF – *Content-Based Filtering, sisältöpohjainen suodatus,*

HRS – *Hybrid Recommendation Systems, hybridisuodatus*

GDPR – *General Data Protection Regulation,*

DPC – *Data Protection Commission,*

MAB – *Multi-Armed Bandits*

DQN – *Deep Q Network*

Sisällysluettelo

Tiivistelmä	2
Keskeiset käsitteet.....	3
Sisällysluettelo	4
1. Johdanto.....	5
2. Tutkimusmenetelmät	7
3. Personointialgoritmit	8
3.1 Personointialgoritmien historiaa	8
3.2 Personointialgoritmien toimintaperiaatteet.....	8
3.3 Mukautuvat käyttöliittymät.....	10
3.4 Tekoälyn merkitys personoinnissa.....	11
3.5 Personoinnin tuomat haasteet	11
3.5.1 Hyperpersonointi	12
3.5.2 Personointiparadoksi	12
3.5.3 Yksityisyys personoinnin haasteena.....	14
3.5.4 Personointialgoritmien vinouma.....	14
4. Pohdinta.....	16
4.1 Vastaukset tutkimuskysymyksiin	17
4.2 Tutkimuksen rajoitukset	18
5. Johtopäätökset	20
Lähteet.....	21

1. Johdanto

Personointialgoritmit ovat muodostuneet keskeiseksi tekijäksi mobiilisovellusten kehityksessä, sillä ne mahdollistavat käyttäjäkokemuksen räätälöinnin yksilöllisiin mieltymyksiin. Nykyään lähes kaikki suosituimmat digitaaliset palvelut, kuten suoratoistopalvelut, verkkokaupat ja sosiaalinen media, hyödyntävät personointia parantaakseen käyttäjäkokemusta ja lisätäkseen sitoutumista (Zhang et al., 2019). Mobiilisovellukset ovat nykyään keskeinen osa arkea, ja niiden personointialgoritmit vaikuttavat laajasti käyttäjäkokemukseen. Tämä tekee niiden vaikutusten ja haasteiden ymmärtämisestä erityisen tärkeää sekä kehittäjille että käyttäjille. Tekoälyn ja koneoppimisen kehittyminen on mahdollistanut entistä tarkemmat ja reaaliaikaiset suositukset, mikä on muuttanut tapaa, jolla käyttäjät kuluttavat sisältöä (Nama, 2021).

Esimerkiksi Zhangin (2019) tutkimuksen mukaan 80 % Netflixin käyttäjistä valitsee elokuvansa sovelluksen suositusten perusteella, ja YouTube'n etusivun algoritmit ohjaavat jopa 60 % käyttäjien tekemistä videovalinnoista. Tämä osoittaa, kuinka merkittävä rooli personointialgoritmeilla on nykyaikaisessa digitaalisen sisällön kulutuksessa. Koska personoinnin tavoitteena on optimoida käyttäjäkokemusta, on tärkeää tutkia, missä määrin se parantaa käyttäjäkokemusta ja missä tilanteissa se saattaa heikentää sitä. Tutkimuksessa tarkastellaan muun muassa personointialgoritmien vaikutusta käyttäjäkokemuksen sujuvuuteen, kiinnostavuuteen ja käyttäjän sitoutumiseen. Siksi tässä tutkimuksessa pyritään vastaamaan seuraavaan tutkimuskysymykseen:

- Miten personointialgoritmit vaikuttavat käyttäjäkokemukseen mobiilisovelluksissa?

Mobiilisovellusten personointi herättää myös haasteita käyttäjilleen (Piduru, 2022). Käyttäjät ovat entistä tietoisempia siitä, miten heidän tietojaan käytetään, ja peräänkuuluttavat parempaa läpinäkyvyyttä (Kozyreva et al., 2021). Siksi tutkimuksen toisena kysymyksenä pyritään selvittämään:

- Mitä haasteita käyttäjät kohtaavat personointialgoritmeja hyödyntävissä sovelluksissa?

Eryyisesti tutkimuksessa tarkastellaan yksityisyyteen, algoritmiseen vinoumaan ja käyttäjätietojen hallintaan liittyviä haasteita

Tutkielma on jaettu useaan lukuun, joista kukin luku käsittelee aihetta eri näkökulmista. Luvussa 2 käydään läpi tutkimuksessa käytetyt tutkimusmenetelmät sekä tarkastellaan kirjallisuuskatsauksen toteutusta ja aineiston valintaperusteita. Luvussa 3 tarkastellaan erilaisia personointialgoritmeja, kuten kollaboratiivista suodatusta, sisältöpohjaista suodatusta ja hybridiratkaisuja. Lisäksi käsitellään tekoälypohjaisia lähestymistapoja, kuten syväoppimista ja neuroverkkoihin perustuvia suositusjärjestelmiä. Lopuksi kappaleessa käsitellään vielä personointiin liittyviä haasteita, kuten hyperpersonointia, algoritmista vinoumaa ja yksityisyydensuojaan liittyviä kysymyksiä. Neljännessä luvussa käydään läpi tutkimuksen tulokset ja pohditaan niiden merkitystä aiempaan kirjallisuuteen peilaten. Lisäksi arvioidaan tutkimuksen rajoituksia, sekä pohditaan personointialgoritmien tulevaisuuden kehityssuuntia. Viidennessä luvussa esitetään tutkimuksen johtopäätökset ja tehdään yhteenveto tutkielman keskeisistä havainnoista.

Lisäksi luvussa ehdotetaan mahdollisia jatkotutkimusaiheita, jotka liittyvät tutkielman teemaan. Viimeinen luku sisältää kaikki tutkielmassa käytetyt lähteet aakkosjärjestyksessä.

2. Tutkimusmenetelmät

Tässä tutkimuksessa toteutetaan kirjallisuuskatsaus, jossa tarkastellaan olemassa olevan kirjallisuuden perusteella persoonallisuusalgoritmien tarjoamia mahdollisuuksia ja haasteita mobiilikehityksessä. Katsauksessa tarkastellaan myös personoinnin historiaa, sillä sen ymmärtäminen on olennaista kokonaiskuvan hahmottamiseksi. Lisäksi käsitellään tekoälyn hyödyntämistä, sillä se on tutkimuksen toteutusajankohtana erittäin ajankohtainen aihe. Lähdeaineisto on haettu useista tieteellisistä tietokannoista, kuten **Google Scholar, ResearchRabbit, IEEE Xplore ja Scopus**. Suurin osa kirjallisuudesta on valittu viimeisen viiden vuoden ajalta, mutta algoritmien historiaa käsittelevässä osiossa on hyödynnetty myös vanhempia lähteitä, kuten **Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. (2011). Recommender Systems: An Introduction. Cambridge University Press**. Tutkimukseen valittiin vain suomen- tai englanninkielisiä julkaisuja, jotta varmistettiin lähteiden ymmärrettävyys.

Kirjallisuuskatsauksessa käytetään tieteellisiä julkaisuja, kuten vertaisarvioituja artikkeleita ja konferenssijulkaisuja. Lähteiden valinnassa on hyödynnetty hakusanoja ja niiden yhdistelmiä, kuten **personalization, algorithm, mobile, development, adaptive, user experience, recommender, application**. Hakuprosessi toteutettiin iteratiivisesti, eli hakusanoja tarkennettiin ja muokattiin saatujen tulosten perusteella. Lähteiden ei edellytetty käsittelevän suoraan mobiilisovelluksia, vaan mukaan otettiin myös laajempia tutkimuksia, jotka käsitelivät, esimerkiksi tekoälyn roolia personoinnissa tai personointiin liittyviä haasteita. Sen sijaan personoinnin vaikutuksia mainontaan ja markkinointiin käsittelevät tutkimukset rajattiin pois, vaikka niitä löytyi runsaasti.

Lähteiden tieteellinen taso on varmistettu Julkaisufoorumin julkaisukanavahaun avulla, ja niiden on todettu olevan vähintään perustasoa (1). Lisäksi osa lähteistä on arvioitu muiden tieteellisesti hyväksytyjen menetelmien avulla. Tällä keinolla pyritään varmistamaan lähdekirjallisuuden luotettavuus.

3. Personointialgoritmit

Personointialgoritmit ovat nykypäivänä digitaalisten palveluiden keskeinen osa, sillä niiden avulla mobiilisovellukset voivat mukauttaa sisältöä käyttäjän toimintatapojen ja mieltymysten perusteella. Jannach ym. (2011) kuvailevat personointialgoritmeja järjestelminä, jotka analysoivat käyttäjätietoa tarjotakseen yksilöllisesti räätälöityjä suosituksia. Tämän teknologian avulla sovellukset voivat parantaa käyttökokemusta ja lisätä käyttäjien sitoutumista.

Sundar ym. (2023) osoittivat, että käyttäjäpersoonallisuus vaikuttaa siihen, kuinka tehokkaasti personointialgoritmit onnistuvat sitouttamaan käyttäjiä. Heidän tutkimuksessaan havaittiin, että ekstrovertit käyttäjät reagoivat paremmin dynaamisiin ja interaktiivisiin suosituksiin, kun taas introvertit suosivat henkilökohtaisempaa ja vähemmän aggressiivista personointia. Tämä korostaa personointialgoritmien merkitystä mobiilisovelluskehityksessä ja niiden roolia käyttäjäkokemuksen optimoinnissa.

3.1 Personointialgoritmien historiaa

Personointialgoritmien kehitys voidaan jäljittää 1990-luvulle, jolloin ensimmäiset suositusjärjestelmät kehitettiin auttamaan käyttäjiä informaatiotulvassa. Sitten nämä järjestelmät ovat kehittyneet merkittävästi ja muodostavat nykyisin keskeisen osan mobiilisovellusten käyttäjäkokemuksen optimointia (Jannach et al., 2011).

Ensimmäiset suositusjärjestelmät käyttivät kollaboratiivista suodatusta (CF), jossa hyödynnettiin käyttäjien aiempia arvioita uusien suositusten luomiseksi. Aluksi käyttäjät antoivat itse arvioita sisällöstä, minkä avulla etsittiin samankaltaisia käyttäjiä. Myöhemmin kehitettiin automatisoituja menetelmiä, jotka mahdollistivat suositusten laajentamisen suuremmille käyttäjämäärille ja verkkoympäristöille (Jannach et al., 2011).

1990-luvun lopulla personointijärjestelmät siirtyivät kaupalliseen käyttöön, ja ensimmäiset massiivisesti skaalautuvat suositusjärjestelmät otettiin käyttöön verkkokaupoissa ja suoratoistopalveluissa.

3.2 Personointialgoritmien toimintaperiaatteet

Adomaviciuksen ja Tuzhilinin (2005) tutkimus tarjoaa kattavan katsauksen yleisimpiin personointialgoritmeihin, joista yksi keskeisimmistä on sisältöpohjainen suodatus (CBF). Tämä menetelmä analysoi kohteiden ominaisuuksia, kuten avainsanoja, kategorioita ja metatietoja, ja suosittelee käyttäjälle sisältöä, joka muistuttaa hänen aiemmin suosimiaan kohteita. Sisältöpohjainen suodatus perustuu vahvasti informaation hakemisen (information retrieval) ja informaation suodattamisen (information filtering) teorioihin. Sen taustalla on oletus, että käyttäjä tulee todennäköisesti pitämään sisällöstä, joka on samankaltaista aiemmin suosimansa kanssa.

Vaikka sisältöpohjainen suodatus on tehokas erityisesti tekstipohjaisessa sisällössä, sillä on myös merkittäviä haasteita. Yksi keskeinen ongelma on ns. kylmäkäynnistysongelma (cold start problem), jossa uusille käyttäjille ei voida tarjota tarkkoja suosituksia ilman aiemmin kerättyä käyttäjädataa. Lisäksi menetelmä voi johtaa liialliseen erikoistumiseen (overspecialization), jolloin käyttäjälle suositellaan ainoastaan samankaltaisia kohteita hänen aiempien valintojensa perusteella. Tämä voi rajoittaa uusien ja monipuolisten suositusten saamista. Esimerkiksi musiikin suoratoistopalvelu voi suositella käyttäjälle ainoastaan tiettyä genreä tai artistia, mikä voi estää uusien musiikkityylien löytämisen (Adomavicius & Tuzhilin, 2005). Lisäksi sisältöpohjainen suodatus kohtaa enemmän haasteita monimutkaisempien sisältötyyppien, kuten kuvien, videoiden ja äänitiedostojen, analysoinnissa.

Näistä haasteista huolimatta sisältöpohjainen suodatus on laajasti käytetty menetelmä, joka toimii hyvin tilanteissa, joissa käyttäjäprofiilista on riittävästi tietoa ja suositeltavan sisällön ominaisuudet voidaan selkeästi määrittellä.

Toinen keskeinen lähestymistapa suositusjärjestelmissä on kollaboratiivinen suodatus (CF), joka eroaa sisältöpohjaisesta suoduksesta siinä, että se ei perustu kohteiden sisällöllisiin ominaisuuksiin, vaan käyttäjien arvioihin ja niiden samankaltaisuuksiin. Menetelmän perusajatuksena on, että käyttäjät, joilla on aiemmin ollut samanlaisia mieltymyksiä, suosivat todennäköisesti myös jatkossa samoja kohteita. Käyttäjä saa suosituksia sisällöistä, joista muut samankaltaiset käyttäjät ovat pitäneet. Yhtenä esimerkkinä tästä lähestymistavasta (Adomavicius ja Tuzhilin, 2005) mainitsevat Amazonin kirjasuositusjärjestelmän, joka hyödyntää kollaboratiivista suodatusta käyttäjien ostokäyttäytymisen ja arvioiden perusteella.

Kollaboratiivisen suodatuksen vahvuutena pidetään sen kykyä tarjota monipuolisia ja käyttäjälähtöisiä suosituksia ilman, että kohteiden rakenteellisia ominaisuuksia, kuten avainsanoja tai metatietoja, tarvitsee analysoida. Tämä tekee menetelmästä joustavamman ja mahdollistaa **piilevien yhteyksien** tunnistamisen käyttäjien arviointimallien perusteella.

Vaikka kollaboratiivinen suodatus on laajasti käytetty ja tehokas menetelmä, se kohtaa myös merkittäviä haasteita. kuten sisältöpohjainen suodatus myös kollaboratiivisen suodatuksen keskeinen ongelma on jo aiemmin mainittu kylmäkäynnistysongelma, jossa uusista käyttäjistä ei ole riittävästi tietoa, mikä vaikeuttaa heidän sijoittamistaan samankaltaisten käyttäjien ryhmiin ja näin ollen myös suositusten tuottamista. Lisäksi menetelmä on vahvasti riippuvainen käyttäjäarvioinneista, mikä voi vaikuttaa suositusten tarkkuuteen erityisesti silloin, kun arviointidataa on saatavilla vain rajallisesti. (Adomavicius & Tuzhilin, 2015) antavat hyvän esimerkin elokuvien suosittelujärjestelmästä, jossa tietyt elokuvat jäävät suositusjärjestelmän ulkopuolelle vain siitä syystä, että niitä on arvioinut vain pieni joukko käyttäjiä. Näin ollen, vaikka nämä elokuvat saisivat korkeita arvioita, niitä suositellaan vain harvoin, koska suositusjärjestelmä ei pysty tunnistamaan niiden suosiota laajemman käyttäjäkunnan keskuudessa.

Kuten aikaisemmin todettiin, että sisältöpohjainen suodatus ja kollaboratiivinen suodatus, kohtaavat erilaisia haasteita, kuten kylmäkäynnistysongelman, tietojen harvuuden (sparsity) ja harvinaisten kohteiden suosittelun vaikeuden. Tämän vuoksi

hybridisuodatus (hybrid recommendation systems, HRS) on noussut yleiseksi lähestymistavaksi, jossa yhdistetään useita suositusmenetelmiä niiden yksittäisten heikkouksien kompensoimiseksi ja suositusten tarkkuuden parantamiseksi (Adomavicius & Tuzhilin, 2005).

Hybridimalleja voidaan toteuttaa useilla eri tavoilla riippuen käyttötarkoituksesta ja suositusjärjestelmän tavoitteista. Yksi yleisimmistä lähestymistavoista on painotettu yhdistelmä (weighted hybridization), jossa eri menetelmien suosituksia yhdistetään ja niille annetaan eri painoarvoja suositusten muodostamisessa. Tämä mahdollistaa joustavan mallin, jossa esimerkiksi sisältöpohjainen suodatus voi ohjata suosituksia tilanteissa, joissa käyttäjästä ei ole vielä riittävästi tietoa, ja kollaboratiivinen suodatus voi vahvistaa suosituksia, kun käyttäjän arvioita kertyy enemmän. Toinen lähestymistapa on vaihtoehtoinen hybridimalli (switching hybridization), jossa järjestelmä valitsee tilanteen mukaan parhaiten toimivan algoritmin. Esimerkiksi uusille käyttäjille voidaan käyttää sisältöpohjaista suodatusta, kun taas aktiivisemmille käyttäjille suositukset voidaan tuottaa kollaboratiivisella suodatuksella.

Hybridisuodatuksen etuna on sen kyky parantaa suositusten tarkkuutta yhdistämällä eri lähestymistapoja. Tämä mahdollistaa paremman kylmäkäynnistysongelman hallinnan, sillä uusille käyttäjille voidaan tarjota suosituksia ilman laajaa aiempaa käyttödataa. Hybridimallit pyrkivät helpottamaan kylmäkäynnistysongelmaa hyödyntämällä monipuolisempia tietolähteitä käyttäjästä, kuten sijaintitietoja, sosiaalisen median profiileista saatavaa dataa ja aiempia käyttäytymismalleja. Lisäksi hybridimallit auttavat ratkaisemaan tietojen harvuuden ongelman yhdistämällä käyttäjäarvioita ja sisällön ominaisuuksia, mikä tekee harvinaisten kohteiden suosittelemisesta helpompaa.

Hybridimalleja hyödynnetään laajasti eri aloilla, kuten **e-commerce**, **suoratoistopalvelut**, **uutissuosituks**, **oppimislustat** ja **sosiaalinen media**. Esimerkiksi **Amazon**, **Netflix** ja **Spotify** käyttävät hybridimalleja tarjotakseen yksilöllisiä suosituksia yhdistämällä käyttäjäarvot ja sisältöperusteiset analyysit (Bodduluri et al., 2024). Hybridijärjestelmien suosio on edelleenkin kasvussa, sillä ne tarjoavat yksilöllisempiä ja tarkempia suosituksia käyttäjille kuin yksittäiset algoritmit (Doe & Smith, 2023).

3.3 Mukautuvat käyttöliittymät

Khamaj ja Ali (2024) korostavat, että mukautuvat käyttöliittymät voivat parantaa käyttäjäkokemusta tekemällä sovelluksista intuitiivisempia ja yksilöllisempiä. Perinteiset käyttöliittymät ovat kaikille samanlaisia, mikä voi tehdä niistä kömpelöitä, koska ne eivät ota huomioon käyttäjän omia tapoja ja mieltymyksiä. Sen sijaan tekoälyyn ja vahvistusoppimiseen perustuvat järjestelmät, kuten (DQN), mukautuvat reaaliajassa käyttäjän toiminnan perusteella. Tämä tarkoittaa, että käyttöliittymä voi esimerkiksi tuoda eniten käytetyt toiminnot paremmin esille ja piilottaa turhat elementit. Näin käyttäjän ei tarvitse itse säätää asetuksia tai etsiä tarpeellisia toimintoja, vaan käyttöliittymä oppii ja mukautuu käyttäjälle automaattisesti. Tällainen personointi vähentää turhaa säätämistä, nopeuttaa tehtävien suorittamista ja tekee käyttökokemuksesta sujuvamman. Samaa ideaa hyödyntävät jo monet suosittu palvelut,

kuten Netflix ja Amazon, jotka muokkaavat suosituksia ja sisältöä sen mukaan, mitä käyttäjä todennäköisesti haluaa nähdä. Mukautuvat käyttöliittymät voivat siis tehdä sovelluksista käyttäjäystävällisempiä (Khamaj & Ali, 2024).

3.4 Tekoälyn merkitys personoinnissa

Tekoälyn merkitys on myös kasvanut personointialgoritmien toteutuksissa merkittävästi. Tekoälyn avulla personointialgoritmit voivat oppia ja ymmärtää käyttäytymistä (user behaviour) tehokkaammin. Nama (2021) korostaa, että tekoälyyn perustuvien personointialgoritmien käyttö voi lisätä käyttäjien sitoutumista jopa 20 % ja pidentää keskimääräisiä käyttöaikoja, mikä parantaa sovellusten yleistä arvostusta. Samalla personointialgoritmien hyödyntämisessä ilmenee merkittäviä haasteita. Esimerkiksi käyttäjien yksityisyydensuojan varmistaminen on kriittistä tekoälyjärjestelmissä, erityisesti tilanteissa, joissa kerätään ja analysoidaan käyttäjädataa (Nama, 2021). Teknologisten ratkaisujen yhteensopivuus eri laitteiden ja käyttöympäristöjen kanssa puolestaan vaatii kehittäjiltä erityistä huomiota sovellusten optimoimiseksi ilman suorituskyvyn heikkenemistä (Nama, 2021).

Personointialgoritmien kehitys on kehittynyt merkittävästi tekoälyn ja koneoppimisen innovaatioiden ansiosta. Perinteiset menetelmät, kuten yhteistyösuodatus ja sisältöpohjaiset suodatusmallit, ovat laajentuneet hybridiratkaisuihin, joissa yhdistellään eri tekniikoiden vahvuuksia. Tämän kehityksen ansiosta on onnistuttu ratkaisemaan aiemmin haastavia ongelmia, kuten uuden käyttäjän tai sisällön "cold start" -haaste. Nykyään kehittyneet järjestelmät hyödyntävät syviä hermoverkkoja ja kontekstipohjaisia menetelmiä, jotka mahdollistavat entistä älykkäämmän ja tarkemman personoinnin.

3.5 Personoinnin tuomat haasteet

Vaikka personointialgoritmit parantavat käyttäjäkokemusta, ne tuovat mukanaan haasteita, kuten hyperpersonointi, personointiparadoksi, yksityisyydensuojan ongelmat ja algoritmisten vinoumat.

Piduru (2022) osoittaa, että käyttäjät ovat entistä tietoisempia tietojensa käytöstä ja vaativat enemmän hallintaa ja läpinäkyvyyttä teknologia yrityksiltä. Ontañón ja Zhu (2021) puolestaan kuvaavat personointiparadoksia, jossa algoritmit voivat rajoittaa käyttäjän valinnanvapautta vahvistamalla aiempia mieltymyksiä. Bozdagin (2013) mukaan algoritmit voivat myös luoda suodatuskuplia, jolloin käyttäjät altistuvat vain samanmieliselle sisällölle.

Nämä haasteet korostavat tarvetta kehittää vastuullisempia algoritmeja, jotka huomioivat yksityisyyden, valinnanvapauden ja sisällön monipuolisuuden. Seuraavissa alaluvuissa käsitellään näitä ongelmia tarkemmin.

3.5.1 Hyperpersonointi

Tilannetta, jossa käyttäjästä kerätään alustalla runsaasti tietoa ja sitä hyödynnetään erittäin tarkkaan räätälöityjen suositusten ja sisältöjen tarjoamiseen, kutsutaan hyperpersonoinniksi. Hyperpersonointi eroaa staattisesta personoinnista merkittävästi, sillä se muokkaa sisältöä ja suosituksia reaaliajassa käyttäjän vuorovaikutusten perusteella. Joissakin tapauksissa algoritmit pystyvät jopa ennakoimaan käyttäjän tulevia tarpeita ja käyttäytymistä. (Vemuganti, 2025).

Hyperpersonointi on luonteeltaan dynaamista, sillä se hyödyntää jatkuvasti karttuvaa tietoa käyttäjästä. Tämä jatkuva oppiminen mahdollistaa personoinnin tarkentumisen jokaisen käyttökerran myötä, jolloin käyttäjälle tarjottu kokemus kehittyy entistä yksilöllisemmäksi ja relevantimmaksi. (Vemuganti, 2025).

Vemugantin (2025) tutkimuksessa havaittiin myös niin kutsuttu tarkkailuefekti (*surveillance effect*). Käyttäjät, jotka olivat tietoisia hyperpersonoinnista ja siitä, että heidän toimintaansa seurataan, olivat alttiimpia muokkaamaan tietoisesti omaa käyttäytymistään sovelluksissa.

3.5.2 Personointiparadoksi

Tilannetta, jossa personointi vaikuttaa käyttäjän omiin mielipiteisiin, ajatuksiin tai käyttäytymiseen, kutsutaan personointiparadokseksi. Ontañónin ja Zhoun (2021) tutkimuksessa tämä ilmiö käsitellään kahden keskeisen mekanismin avulla: itseään vahvistavat kehät ja muuttuvat kohteet.

Itseään vahvistavat kehät syntyvät, kun personointialgoritmit vahvistavat käyttäjän olemassa olevia mieltymyksiä ja rajoittavat samalla vaihtoehtojen moninaisuutta. Eg, Tønnesen ja Tennfjord (2022) tuovat esiin, että monet käyttäjät eivät ole tietoisia siitä, miten algoritmit muokkaavat heidän saamaansa sisältöä, mutta samalla he kokevat käyttökokemuksen paranevan, koska sisältö tuntuu heille sopivalta. Tämä voi johtaa tilanteeseen, jossa käyttäjälle tarjotaan yhä enemmän samantyyppistä sisältöä hänen aiemman vuorovaikutuksensa perusteella, vaikka hänen kiinnostuksen kohteensa saattaisivat muuttua.

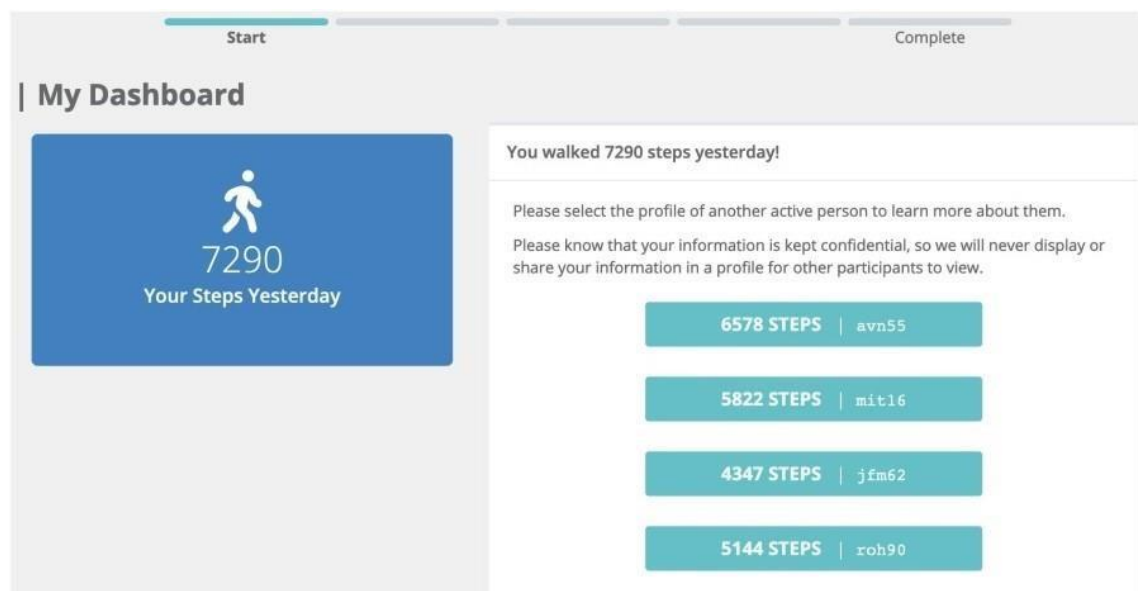
Lisäksi tutkimuksen mukaan monet käyttäjät eivät aktiivisesti säädä tai muokkaa some-alustojen personointiasetuksia, vaan kuluttavat passiivisesti algoritmien tarjoamaa sisältöä. Tämä voi vahvistaa "**digitaalista mukavuusluetta**", jossa käyttäjä altistuu vain hänelle jo valmiiksi sopiville sisällöille ja välttää uusia näkökulmia (Eg et al., 2022).

Toinen mekanismi, muuttuvat kohteet, viittaa siihen, että personointi itsessään muuttaa käyttäjän käyttäytymistä ja mieltymyksiä. Tämä luo haasteen algoritmile, koska käyttäjän alkuperäinen malli ei enää vastaa hänen uusia tarpeitaan. Tällainen ilmiö on erityisen näkyvä järjestelmissä, joissa pyritään vaikuttamaan käyttäjän käyttäytymiseen, kuten liikunta- tai terveyssovelluksissa. Näissä ympäristöissä käyttäjän toimintaan vaikuttava personointi voi johtaa siihen, että käyttäjän malli kehittyy jatkuvasti, mikä vaikeuttaa tarkkojen ja toimivien suositusten tarjoamista pitkällä aikavälillä.

Ontañón ja Zhu (2021) havainnollistivat näitä mekanismeja tutkimalla mukautuvia liikuntasovelluksia. Tutkimuksessa käyttäjät saivat vertailutietoa omasta fyysisestä aktiivisuudestaan suhteessa muihin käyttäjiin. Personoinnin tavoitteena oli lisätä käyttäjän motivaatiota fyysiseen aktiivisuuteen, mutta samalla havaittiin, että järjestelmä vaikutti merkittävästi käyttäjien käyttäytymiseen, mikä korosti sekä itseään vahvistavien kehiin että muuttuvien kohteiden ongelmaa. Tutkijat pyrkivät ratkaisemaan näitä haasteita muun muassa suunnittelemalla järjestelmän neutraaliksi ja päivittämällä käyttäjämalleja dynaamisesti.

Myös Karolus, J., Schemmer, S., De Vito Dabbs, A., ja Consolvo, S. (2021) tutkivat personointiparadoksia liikuntasovellusten yhteydessä. Heidän tutkimuksessaan suunniteltiin selainpohjainen sovellus, johon käyttäjien päivittäiset askelmäärät tallentuivat automaattisesti. Tutkimuksessa tarkasteltiin, kuinka personoinnin avulla muokatut sosiaaliset vertailut vaikuttavat käyttäjien motivaatioon ja fyysiseen aktiivisuuteen.

Personointimekanismi perustui (MAB) algoritmiin, joka mukautti päivittäin esitettyjä vertailukohteita käyttäjien aiempien mieltymysten ja reaktioiden perusteella. Käyttäjät jaettiin kokeelliseen ja kontrolliryhmään, joista ensimmäiselle esitettiin personoituja vertailukohteita ja jälkimmäiselle satunnaisia vertailuja.



Kuva 1. Kuvankaappaus käyttäjän profiilista. (Karolus et al., 2021)

Tutkimus osoitti, että personointi voi johtaa kahteen ristiriitaiseen ilmiöön: itseään vahvistaviin kehiin, joissa algoritmi lukitsee käyttäjän tiettyihin käyttäytymismalleihin, sekä muuttuvien kohteiden ongelmaan, jossa käyttäjän mieltymykset muuttuvat personoinnin seurauksena. Näiden ilmiöiden hallinta on keskeinen haaste personointijärjestelmien suunnittelussa.

Personointiparadoksi korostaa, kuinka tärkeää on tasapainottaa käyttäjämallien tarkkuus ja järjestelmän vaikutus käyttäjäkokemukseen. Tämä vaatii jatkuvaa tutkimusta sekä käytännön kokeiluja algoritmien pitkän aikavälin vaikutuksista.

3.5.3 Yksityisyys personoinnin haasteena

Yksityisyydensuoja on keskeinen haaste personointialgoritmien kehityksessä ja käytössä. Pidurun (2022) tutkimus tuo esiin, että sosiaalisen median personointialgoritmit tasapainoilevat käyttäjäkokemuksen parantamisen ja yksityisyyden säilyttämisen välillä. Algoritmit keräävät jatkuvasti tietoa käyttäjien toiminnasta, kuten klikkauksista, sisällön kulutuksesta ja vuorovaikutuksesta, muodostaen näin yksityiskohtaisia käyttäjäprofileja. Tämä mahdollistaa erittäin kohdennetut suositukset, mutta samalla herättää huolta tietosuojasta ja käyttäjien kontrollista omaan dataansa. Tutkimuksen mukaan käyttäjät ovat yhä tietoisempia datan keräämisestä ja peräänkuuluttavat suurempaa läpinäkyvyyttä sekä mahdollisuuksia hallita, miten heidän tietojaan käytetään.

Eget et al. (2022) vahvistavat tämän havainnon osoittamalla, että algoritmien läpinäkyvyyttä voi vähentää käyttäjien luottamusta digitaalisiin palveluihin. Heidän tutkimuksensa mukaan monet käyttäjät eivät ymmärrä, miten heidän tietojaan hyödynnetään, ja tämä voi johtaa epäluottamukseen sekä algoritmien ohjaaman sisällön kyseenalaistamiseen. Lisäksi tutkimus nostaa esiin niin kutsutun tarkkailuefektin (surveillance effect), jossa tietoisuus datan keräämisestä voi vaikuttaa käyttäjien toimintaan – he saattavat esimerkiksi sensuroida omaa käyttäytymistään tai rajoittaa sovellusten käyttöä yksityisyyden säilyttämiseksi. Tämä voi paradoksaalisesti heikentää käyttäjäkokemusta, vaikka personoinnin tavoitteena on tehdä palveluista intuitiivisempia ja käyttäjälähtöisempiä.

Yksi mahdollinen ratkaisu tietosuojan ja personoinnin väliseen ristiriitaan on federated learning -menetelmä, jossa data pysyy käyttäjän laitteella eikä sitä siirretä keskuspalvelimelle. Tämä mahdollistaa algoritmien oppimisen käyttäjän käyttäytymisestä ilman, että henkilötietoja tallennetaan keskitetysti. Tutkimukset osoittavat, että tällaiset hajautetut koneoppimismenetelmät voivat merkittävästi parantaa tietosuojaa, säilyttäen samalla personoinnin tuomat hyödyt (Bonawitz et al., 2019).

Lisäksi käyttäjien suhtautuminen personointiin ja yksityisyyteen on monimutkaista. Ilmiö, jota kutsutaan privacy paradox -nimellä, kuvaa käyttäjien ristiriitaista käyttäytymistä: he ilmaisevat huolta tietosuojastaan mutta jatkavat kuitenkin palveluiden käyttöä. (Acquisti et al., 2015). Eget et al. (2022) tukevat tätä havaintoa ja korostavat, että käyttäjien algoritmien tietoisuus on usein kontekstisidonnaista – käyttäjät voivat olla huolissaan yksityisyydestään, mutta samalla mukautuvat algoritmien tuottamaan sisältöön, koska se koetaan henkilökohtaisesti relevanttina. Tämä korostaa tarvetta kehittää personointialgoritmeja, jotka tarjoavat käyttäjille paremman läpinäkyvyyden ja hallinnan omiin tietoihinsa liittyen ilman, että käyttökokemus kärsii.

3.5.4 Personointialgoritmien vinouma

Bozdagin (2013) tutkimus tarkastelee personointialgoritmien aiheuttamaa vinoumaa ja sen vaikutuksia tiedonvälitykseen ja käyttäjien kokemuksiin digitaalisessa ympäristössä. Tutkimus perustuu ajatukseen, että algoritmiset järjestelmät, vaikka ne usein mielletään neutraaleiksi ja objektiivisiksi, sisältävät sekä teknisiä että inhimillisiä vinoumia. Vinoumat voivat johtua algoritmien suunnittelijoiden tekemistä valinnoista, teknisistä rajoitteista tai käyttäjän vuorovaikutuksesta järjestelmän kanssa (s. 209–211).

Tutkimus esittelee algoritmisen portinvartijuuden mallin, joka yhdistää perinteisen portinvartijuuden käsitteen digitaalisen tiedonsuodatuksen prosesseihin. Malli osoittaa, että algoritmit eivät ainoastaan suodata tietoa teknisin perustein, vaan heijastavat myös inhimillisiä arvovalintoja ja prioriteetteja. Tämä voi johtaa siihen, että käyttäjille esitetään sisältöä, joka vahvistaa heidän olemassa olevia näkemyksiään ja rajoittaa altistumista vaihtoehtoisille näkökulmille. Tätä ilmiötä kutsutaan **suodatuskuplaksi** (filter bubble) (s. 213–217).

Bozdag tuo esiin useita tapoja, joilla vinoumat ilmenevät personointialgoritmeissa:

Tiedon valinta ja priorisointi: Algoritmit voivat painottaa suositumpia tietolähteitä tai sisältötyyppejä, mikä voi syrjäyttää vähemmän tunnetut tai vähemmän suosittuja näkökulmia sisältävät lähteet (s. 215–216).

Käyttäjämallien rakentaminen: Käyttäjien vuorovaikutuksesta kerätty tieto vaikuttaa siihen, millaista sisältöä heille jatkossa näytetään. Kuitenkin käyttäjien eksplisiittisesti antamat tiedot (esim. kiinnostuksen kohteet) voivat jäädä ajan myötä vanhentuneiksi, ja implisiittiset tiedot (esim. klikkaushistoria) voivat johtaa yksipuoliseen sisällön näyttämiseen (s. 213–214).

Eettiset ja sosiaaliset haasteet: Algoritmien läpinäkyvyyden puute, käyttäjän autonomian rajoittaminen ja tiedon monimuotoisuuden kaventuminen herättävät kysymyksiä algoritmien oikeudenmukaisuudesta ja yhteiskunnallisista vaikutuksista (s. 220–221).

Eg et al. (2022) käsittelevät myös algoritmien vaikutusta tiedon monimuotoisuuteen ja informaation vääristymiseen. Heidän tutkimuksensa mukaan sosiaalisen median algoritmit eivät ainoastaan optimoi käyttäjäkokemusta, vaan ne myös priorisoivat sisältöä kaupallisten tavoitteiden mukaisesti. Tämä voi tarkoittaa, että käyttäjät saavat eniten näkyviin sellaisia sisältöjä, jotka ovat algoritmin näkökulmasta **sitouttavia**, mutta eivät välttämättä tasapainoisia tai objektiivisia.

Tutkimuksessa havaittiin, että käyttäjien kokemus **kaikukammiosta** voi johtua sekä algoritmien toiminnasta että käyttäjien omista sisällön kulutustottumuksista. Tämä tarkoittaa, että vaikka algoritmi suodattaisi sisältöä käyttäjän aiempien mieltymysten perusteella, käyttäjät myös itse aktiivisesti hakeutuvat samantyyppisen sisällön pariin, mikä vahvistaa suodatuskuplan vaikutusta.

Eg et al. (2022) korostavat, että algoritmien läpinäkyvyyden puute tekee vinoumien vaikutusten havaitsemisesta vaikeampaa. Monet käyttäjät eivät esimerkiksi tiedä, miksi he näkevät tiettyä sisältöä, eivätkä osaa arvioida, kuinka paljon heidän digitaalinen ympäristönsä on muovautunut algoritmien perusteella.

4. Pohdinta

Tämän kirjallisuuskatsauksen tavoitteena oli tarkastella personointialgoritmien vaikutusta mobiilisovellusten käyttäjäkokemukseen sekä niiden mukanaan tuomia haasteita. Tulokset osoittavat, että personointialgoritmit ovat keskeinen osa nykyaikaisia digitaalisia palveluita, ja niiden merkitys tulee kasvamaan vain entisestään tulevaisuudessa. Tämä korostaa tarvetta ymmärtää paitsi personoinnin tuomia hyötyjä, mutta myös siihen liittyviä eettisiä, teknologisia ja yhteiskunnallisia haasteita.

Yritysten ja organisaatioiden on tärkeää arvioida personoinnin vaikutuksia, sekä yksilön että yhteisön tasolla, jotta teknologioita voidaan kehittää vastuullisesti ja eettisesti kestävämmiksi. Personointialgoritmit voivat merkittävästi parantaa käyttäjäkokemusta tarjoamalla yksilöllisempiä ja käyttäjälle relevantimpia sisältöjä, mutta samalla ne voivat vaikuttaa käyttäjien päätöksentekoon, tiedonsaantiin ja digitaaliseen ympäristöön.

Yksi keskeinen haaste on, että käyttäjät eivät usein tiedosta, miksi he näkevät tiettyä sisältöä sosiaalisessa mediassa. Algoritmien läpinäkyvyyden puute vaikeuttaa niiden vaikutusten hahmottamista, ja käyttäjillä ei ole selkeää käsitystä siitä, miten heidän digitaalinen ympäristönsä muovautuu heidän toimintansa perusteella. Tämä voi johtaa siihen, että käyttäjät kuluttavat sisältöä passiivisesti ilman, että heillä on mahdollisuutta arvioida tai kyseenalaistaa algoritmien tekemiä valintoja.

Näin ollen personointia hyödyntävien järjestelmien suunnittelussa on huomioitava paitsi tekninen tehokkuus, mutta myös läpinäkyvyys ja käyttäjän autonomian säilyttäminen. Algoritmien toiminnan ymmärrettävyyttä voidaan parantaa esimerkiksi selkeämmillä käyttöliittymillä, joissa käyttäjälle annetaan enemmän hallintamahdollisuuksia ja tietoa siitä, millä perusteella sisältöjä suositellaan. Läpinäkyvyyden lisääminen ei ainoastaan tue käyttäjän valinnanvapautta, vaan se voi myös kasvattaa luottamusta digitaalisiin palveluihin ja vähentää algoritmien aiheuttamia vääristymiä tiedonsaannissa.

Useat tutkimukset ovat tuoneet esiin hyperpersonoinnin mahdolliset haittavaikutukset käyttäjäkokemukseen. Vemugantin (2025) tutkimuksen mukaan hyperpersonointi voi pitkällä aikavälillä heikentää käyttäjien itsemääräämisoikeutta vaikuttamalla heidän päätöksentekoonsa ja rajoittamalla altistumista vaihtoehtoisille näkökulmille.

Personoinnin tulisi myös olla **sensitiivistä ja tilannetietoista**, jotta se ei aiheuta käyttäjälle epämukavuutta tai epäasiallisia suosituksia. Esimerkiksi sisältöpohjainen suodatus on tehokas menetelmä verkkokaupoissa, joissa se voi tarjota käyttäjälle samankaltaisia tuotteita kuin hän on aiemmin ostanut. Kuitenkin tietyissä konteksteissa tämä lähestymistapa voi johtaa epäasianmukaisiin tai jopa loukkaaviin suosituksiin. Esimerkiksi, jos käyttäjä on ostanut muistoadresseja hautajaisia varten, järjestelmä saattaa myöhemmin suositella hänelle hauta-arkkuja tai muita suruun liittyviä tuotteita.

Tämänkaltaisissa tilanteissa on keskeistä, että personointijärjestelmät pystyvät tulkitsemaan sisällön kontekstia ja ymmärtämään käyttäjän tarpeiden tilapäisyyden. Tekoälypohjaiset ratkaisut voivat tarjota tässä merkittävää lisäarvoa, sillä ne kykenevät analysoimaan käyttäjän käyttäytymistä laajemmin ja erottamaan lyhytaikaiset, satunnaiset ostokäyttäytymiseen liittyvät toiminnot käyttäjän pitkäaikaisista kiinnostuksen kohteista.

Monet käyttäjät eivät myöskään aktiivisesti muokkaa tai säädä some-alustojen personointiasetuksia, vaan kuluttavat passiivisesti algoritmien tarjoamaa sisältöä. Tämä passiivinen kuluttaminen voi luoda "digitaalisen mukavuusalueen", jossa käyttäjä saa vain hänelle ennestään tuttuja ja turvallisia sisältöjä, mikä voi rajoittaa uuden tiedon omaksumista ja vaikuttaa käyttäjän maailmankuvaan.

Jotta personointialgoritmien vaikutuksia voidaan ymmärtää syvällisemmin, on tärkeää tarkastella niiden pitkän aikavälin vaikutuksia käyttäytymiseen, mielipiteiden muodostumiseen ja digitaaliseen vuorovaikutukseen. Lisäksi on olennaista kehittää personointimalleja, jotka tukevat läpinäkyvyyttä, monipuolisuutta ja käyttäjän itsemääräämisoikeutta. Näiden näkökulmien huomioiminen voi auttaa luomaan digitaalisia palveluita, jotka eivät ainoastaan paranna käyttäjäkokemusta, vaan myös edistävät oikeudenmukaista ja vastuullista teknologista kehitystä.

4.1 Vastaukset tutkimuskysymyksiin

Personointialgoritmit vaikuttavat käyttäjäkokemukseen monin tavoin, ja niiden vaikutukset voivat olla sekä positiivisia että negatiivisia. Tästä syystä tutkimuskysymykseen **“Miten personointialgoritmit vaikuttavat käyttäjäkokemukseen mobiilisovelluksissa?”** ei ole yksiselitteistä vastausta.

Useat tutkimukset osoittavat, että personointialgoritmit voivat parantaa käyttäjäkokemusta tarjoamalla yksilöllisiä ja osuvampia suosituksia, mikä lisää sovelluksen hyödyllisyyttä ja käytettävyyttä. Esimerkiksi Zhang et al. (2019) havaitsivat, että syväoppimiseen perustuvat suositusjärjestelmät parantavat käyttäjien sitoutumista ja tuovat lisäarvoa erityisesti suoratoistopalveluissa ja verkkokaupoissa. Samoin Sundar, Sharma ja Kim (2023) osoittivat, että käyttäjän persoonallisuuteen sopivaksi mukautetut sisällöt lisäävät käyttäjäkokemuksen positiivisuutta ja kasvattavat käyttöhalukkuutta.

Vaikka personointialgoritmit voivat lisätä käyttäjien sitoutumista ja pidentää sovelluksen käyttöaikaa, ne saattavat myös rajoittaa käyttäjien altistumista monipuoliselle sisällölle ja vahvistaa kapeakatseista ajattelua.

Tutkimuskysymykseen **“Mitä haasteita käyttäjät kohtaavat personointialgoritmeja käytävissä sovelluksissa?”** löytyi useita haasteita tarkastelluista tutkimuksista. Vaikka monet haasteet, kuten yksityisydensuoja ja suodatuskuplat, liittyvät ensisijaisesti eettisiin ja yhteiskunnallisiin kysymyksiin, ne heijastuvat myös suoraan käyttäjäkokemukseen.

Eryteisesti käyttäjiä huolestuttaa personointia hyödyntävien sovellusten vaikutus heidän yksityisyyteensä. Moni kokee epävarmuutta siitä, kuinka heidän käyttäytymistään seurataan ja mihin heidän henkilötietojaan käytetään. Vaikka Euroopassa toimivat yritykset ovat sitoutuneet **GDPR**-säädösten mukaiseen tietojen säilyttämiseen ja hallintaan, useat tapaukset ovat paljastaneet näiden sääntöjen rikkomuksia.

Esimerkiksi vuonna 2023 Irlannin tietosuojaviranomainen (DPC) määräsi Meta Platforms Ireland Limitedille (Meta IE) 1,2 miljardin euron sakon GDPR:n rikkomisesta. Sakko liittyi käyttäjätietojen siirtoihin Yhdysvaltoihin vakiosopimuslausekkeiden (SCC)

perusteella 16. heinäkuuta 2020 jälkeen, mikä rikkoi EU:n tietosuojamääräyksiä. (European Data Protection Board [EDPB], 2023) Tämä oli suurin koskaan määrätty GDPR-sakko. Tällaiset tapaukset voivat heikentää käyttäjien luottamusta sovelluksiin ja lisätä epävarmuutta siitä, kuinka heidän tietojaan käsitellään, mikä osaltaan vaikuttaa negatiivisesti käyttäjäkokemukseen. Luottamuksen heikkeneminen voi puolestaan johtaa käyttäjien siirtymiseen vaihtoehtoisiin palveluihin tai tietojen jakamisen rajoittamiseen, mikä voi vaikuttaa myös yritysten kykyyn kehittää tarkempia ja käyttäjäystävällisempiä suositusjärjestelmiä.

Personointia hyödyntävien yritysten tulisi lisätä läpinäkyvyyttä käyttäjätietojen käsittelyssä ja säilytyksessä vahvistaakseen käyttäjien luottamusta. Selkeä ja avoin tiedottaminen datan käytöstä edistäisi turvallisuuden tunnetta ja parantaisi näin käyttäjäkokemusta.

Yksi tutkimuksessa esiin nousseista haasteista on personointialgoritmien aiheuttama vinouma, joka vaikuttaa merkittävästi käyttäjäkokemukseen. Algoritmit ohjaavat käyttäjiä kuluttamaan samankaltaista sisältöä ja voivat samalla rajata pois vaihtoehtoisia näkökulmia. Tämä ilmiö on erityisen havaittavissa sosiaalisen median lyhytvideoformaatissa, jossa käyttäjä saattaa ajautua suodatuskuplaan altistuen vain tietyn tyyppiselle sisällölle. Tämä voi vähentää sisällön monipuolisuutta ja kaventaa käyttäjän kokemusta sovelluksesta, mikä pitkällä aikavälillä saattaa heikentää koettua käyttäjäarvoa ja vähentää sovelluksen käyttöhalukkuutta.

Tähän ongelmaan on alettu kehittämään ratkaisuja, ja monet yritykset, kuten Google ja Facebook, ovat ottaneet käyttöön **"Why am I seeing this?"** ("Miksi näen tämän?") selityssivustoja, joiden tarkoituksena on selventää käyttäjälle, miksi näkevät kyseistä sisältöä. Näiden toimintojen avulla käyttäjät voivat saada yksityiskohtaisempaa tietoa siitä, miksi tiettyä sisältöä suositellaan heille (Burgess et al., 2024). Tällaiset ratkaisut voivat lisätä algoritmien läpinäkyvyyttä ja parantaa käyttäjien ymmärrystä personoinnin toimintaperiaatteista. Lisäksi ne tarjoavat käyttäjille mahdollisuuden vaikuttaa siihen, millaista sisältöä heille suositellaan jatkossa, mikä voi osaltaan lisätä käyttäjän hallinnan tunnetta ja vahvistaa luottamusta sovellusten personointijärjestelmiin.

4.2 Tutkimuksen rajoitukset

Tutkimuksen rajoitteisiin kuuluu se, että mobiilisovellusten personointi on suhteellisen tuore ilmiö, ja sen kehitys etenee nopeasti erityisesti tekoälyn kehittymisen myötä. Tästä syystä tämän tutkielman tiedot ja lähteet voivat vanhentua nopeastikin, mikä asettaa haasteita tutkimuksen ajantasaisuudelle. Lisäksi tutkimus on toteutettu kirjallisuuskatsauksena, eikä siihen sisälly omaa empiiristä aineistoa, minkä vuoksi tutkimuksen tulokset pohjautuvat täysin olemassa olevaan kirjallisuuteen. Tämä voi vaikuttaa siihen, kuinka syvällisesti käyttäjäkokemusta voidaan analysoida, sillä ilman käyttäjä tutkimusta ei voida tarkasti arvioida, miten eri henkilöryhmät kokevat personoinnin vaikutukset.

Tutkimuskysymyksiin vastattaessa kävi ilmi, että personoinnin vaikutukset käyttäjäkokemukseen ovat monimutkaisia ja tilannekohtaisia, mikä vaikeuttaa yksiselitteisten johtopäätösten tekemistä. Tulokset ovat näin ollen aina jossain määrin tulkinnanvaraisia, ja niiden yleistettävyyttä riippuu, sekä tutkimusaineiston kattavuudesta että tarkasteltavista sovelluskonteksteista.

Lisäksi on huomioitava, että tutkimuksessa tarkasteltu kirjallisuus keskittyy pääasiassa, suuriin teknologiayrityksiin ja sektoreihin, kuten sosiaaliseen mediaan ja verkkokauppoihin. Tämä voi rajata ymmärrystä siitä miten personointialgoritmeja käytetään pienempien sektorien sovelluksissa, kuten koulutuksen, rekrytoinnin tai työelämän konteksteissa.

5. Johtopäätökset

Tutkielma tarjosi yleiskatsauksen siitä, kuinka personointialgoritmit vaikuttavat mobiilisovellusten käyttäjäkokemukseen sekä millaisia haasteita niiden käyttöön liittyy. Tutkimuksessa tarkasteltiin personointialgoritmien hyötyjä ja haittoja, mukaan lukien niiden vaikutukset käyttäjien sitoutumiseen, yksityisyydensuojaan ja päätöksentekoprosesseihin. Lisäksi tutkimus tarkasteli personointialgoritmien perustoimintaperiaatteita ja algoritmisten vinoumien mahdollisia vaikutuksia käyttäjäkokemukseen.

Tutkielma vahvisti olemassa olevia näkemyksiä personointialgoritmien keskeisestä roolista mobiilisovelluksissa ja toi esiin uusia yksityiskohtia niiden mahdollisista vaikutuksista käyttäjäkokemukseen. Se korosti algoritmien merkitystä käyttäjien sitouttamisen ja käyttökokemuksen parantamisen kannalta, mutta myös niiden mukanaan tuomia haasteita, kuten hyperpersonointia, suodatuskuplia ja yksityisyyden suojaan liittyviä ongelmia. Tutkielma toi esiin tarpeen kehittää personointialgoritmeja vastuullisemmaksi ja käyttäjälähtöisemmäksi, erityisesti läpinäkyvyyden ja käyttäjän autonomian näkökulmasta.

Tutkielman esille nostamat aiheet voivat lisätä keskustelua personointialgoritmien ja käyttäjäkokemuksen risteyskohdasta sekä tarjota kokonaiskuvan algoritmien hyödyistä ja haasteista. Se tuo esiin erityisesti yksityisyydensuojan merkityksen ja algoritmisten päätösten läpinäkyvyyden tarpeen käyttäjien luottamuksen säilyttämiseksi. Lisäksi tutkielma avaa näkökulmia siihen, miten algoritmien vaikutuksia voidaan hallita ja miten käyttäjille voidaan tarjota enemmän kontrollia heidän personointiprosessiinsa.

Mahdollisia jatkotutkimusaiheita voisivat olla empiiriset tutkimukset, jotka tarkastelevat personointialgoritmien vaikutuksia todellisissa käyttötilanteissa ja vertailevat eri algoritmisten lähestymistapojen tehokkuutta käyttäjäkokemuksen optimoinnissa. Lisäksi olisi hyödyllistä tutkia, miten käyttäjät suhtautuvat eri personointimenetelmiin ja missä määrin he kokevat algoritmien vaikutukset positiivisina tai negatiivisina. Toinen kiinnostava jatkotutkimuksen kohde voisi olla personointialgoritmien eettiset näkökulmat, erityisesti niiden vaikutus käyttäjän autonomiaan ja päätöksentekoon. Kuten tutkimuksen rajoitukset -kappaleessa **todettiin**, tutkimusta on tehty vähemmän pienemmistä toimialoista, joten olisi hyödyllistä tarkastella eri käyttäjäryhmien kokemuksia. Tämä auttaisi ymmärtämään paremmin, miten personointi vaikuttaa eri käyttäjäsegmentteihin ja millaisia eroja käyttäjien välillä ilmenee.

Lähteet

Acquisti, A., Brandimarte, L., & Loewenstein, G. (2015). Privacy and human behavior in the age of information. *Science*, 347(6221), 509-514. <https://doi.org/10.1126/science.aaa1465>

Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734–749. <https://doi.org/10.1109/TKDE.2005.99>

Bodduluri, K. C., Palma, F., Kurti, A., Jusufi, I., & Löwenadler, H. (2024). *Exploring the landscape of hybrid recommendation systems in e-commerce: A systematic literature review*. *IEEE Access*, 12, 28273-28296. <https://doi.org/10.1109/ACCESS.2024.3365828>

Bonawitz, K., Eichner, H., Grieskamp, W., Huba, D., Ingerman, A., Ivanov, V., Kiddon, C., Konečný, J., Mazzocchi, S., McMahan, B., Overveldt, T. V., Petrou, D., Ramage, D., & Roselander, J. (2019). Towards federated learning at scale: System design. *Proceedings of Machine Learning and Systems*. <https://arxiv.org/abs/1902.01046>

Bozdag, E. Bias in algorithmic filtering and personalization. *Ethics Inf Technol* 15, 209–227 (2013). <https://doi.org/10.1007/s10676-013-9321-6>

Burgess, J., Carah, N., Angus, D., Obeid, A., & Andrejevic, M. (2024). Why am I seeing this ad? The affordances and limits of automated user-level explanation in Meta’s advertising system. *New Media & Society*, 26(9), 5130-5149. <https://doi.org/10.1177/14614448241251796>

European Data Protection Board. (2023, May 22). €1.2 billion fine for Facebook as a result of EDPB binding decision. *European Data Protection Board*. https://edpb.europa.eu/news/news/2023/12-billion-euro-fine-facebook-result-edpb-binding-decision_en

Eg, R., Tønnesen, Ö. D., & Tennfjord, M. K. (2023). A scoping review of personalized user experiences on social media: The interplay between algorithms and human factors. *Computers in Human Behavior Reports*, 9, 100253. <https://doi.org/10.1016/j.chbr.2022.100253>

Hutmacher, F., & Appel, M. (2023). The psychology of personalization in digital environments: From motivation to well-being – A theoretical integration. *Review of General Psychology*, 27(1), 26-40. <https://doi.org/10.1177/10892680221105663>

Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. (2011). *Recommender systems: An introduction*. Cambridge University Press. <https://www.cambridge.org/9780521493369>

Karolus, J., Schemmer, S., De Vito Dabbs, A., & Consolvo, S. (2021). Personalization paradox in behavior change apps: Lessons from a social comparison-based personalized app for physical activity. *Proceedings of the ACM on Human-Computer Interaction*, 5(CSCWI), Article 60. <https://doi.org/10.1145/3449190>

- Khamaj, A., & Ali, A. M. (2024). Adapting user experience with reinforcement learning: Personalizing interfaces based on user behavior analysis in real-time. *Alexandria Engineering Journal*, 95, 164–173. <https://doi.org/10.1016/j.aej.2024.03.045>
- Kim, J., Park, S., & Lee, H. (2020). Federated evaluation of on-device personalization. *Journal of Machine Learning Research*, 21(1), 123–145. <https://arxiv.org/abs/1910.10252>
- Kozyreva, A., Lorenz-Spreen, P., Hertwig, R., et al. (2021). Public attitudes towards algorithmic personalization and use of personal data online: Evidence from Germany, Great Britain, and the United States. *Humanities and Social Sciences Communications*, 8, 117. <https://doi.org/10.1057/s41599-021-00787-w>
- Nama, P. (2021). *Enhancing user experience in mobile applications through AI-driven personalization and adaptive learning algorithms*. *World Journal of Advanced Engineering Technology and Sciences*, 3(2), 83–94. <https://doi.org/10.30574/wjaets.2021.3.2.0064>
- Nwanna, M., Offiong, E., Ogidan, T., Fagbohun, O., Ifaturoti, A., & Fasogbon, O. (2025). AI-driven personalisation: Transforming user experience across mobile applications. *Journal of Artificial Intelligence, Machine Learning and Data Science*, 3(1), 1920–1929. <https://doi.org/10.51219/JAIMLD/maxwell-nwanna/425>
- Ontañón, S., & Zhu, J. (2021). The personalization paradox: The conflict between accurate user models and personalized adaptive systems. *Companion of the 2021 International Conference on Intelligent User Interfaces (IUI '21)*, 64–66. <https://doi.org/10.1145/3397482.3450734>
- Piduru, B. R. (2022). Evaluating personalization algorithms in social media: Balancing user engagement and privacy. *Journal of Artificial Intelligence & Cloud Computing*, 1(4), 1–5. [https://doi.org/10.47363/JAICC/2022\(1\)194](https://doi.org/10.47363/JAICC/2022(1)194)
- Sharma, R., Lee, J., & Park, H. (2021). Preserving privacy in personalized models for distributed mobile services. *Journal of Privacy and Data Security*, 10(3), 210–225. <https://ieeexplore.ieee.org/document/9546513/>
- Sundar, S., Sharma, R., & Kim, T. (2023). Our nudges, our selves: Tailoring mobile user engagement. *Proceedings of the 2023 International Conference on Human-Computer Interaction*, 45–50. https://link.springer.com/chapter/10.1007/978-3-031-42293-5_3
- Udd, V. (2024). *Tekoälypohjaisen chatbotin vaikutus käyttäjäkokemukseen* [Master's thesis, University of Jyväskylä]. *Jyväskylä University Digital Repository*. https://urn.fi/URN:NBN:fi_jyu-202403212539
- Vemuganti, R. (2025). Privacy, hyper-personalization, and autonomy harms. *SSRN*. <https://doi.org/10.2139/ssrn.4072059>
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning-based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 52(1), 1–38. <https://doi.org/10.1145/3285029>