



**TURUN
YLIOPISTO**
Kauppakorkeakoulu

GENERATIIVISEN TEKOÄLYN KÄYTTÖKOHTEET JA MAHDOLLISUUDET PANKKISEKTORILLA

Systemaattinen kirjallisuuskatsaus

Oppiaineen Tietojärjestelmätiede
Pro gradu -tutkielma

Laatija:
Tuukka Strömberg

Ohjaajat:
KTT Hannu Salmela

3.6.2025
Turku

Pro gradu -tutkielma

Tietojärjestelmätiede

Tuukka Strömberg

GENERATIIVISEN TEKOÄLYN KÄYTTÖKOHTEET JA MAHDOLLISUUDET PANKKISEKTORILLA

Sivumäärä: 72, liitteet 4

Tämän tutkielman tavoitteena on kartoittaa generatiivisen tekoälyn (GenAI) käyttökohteita, vaikutuksia ja haasteita pankkisektorilla. Tutkimusongelmana on selvittää, millä tavoin generatiivista tekoälyä voidaan hyödyntää pankkien eri toiminnoissa, sekä mitä mahdollisuuksia ja riskejä sen käyttöönottoon liittyy. Taus-talla on tarve ymmärtää, miten tämä nopeasti kehittyvä teknologia muuttaa yhteiskunnallisesti keskeistä ja vahvasti säänneltyä pankkialaa.

Tutkimuksessa hyödynnettiin systemaattista kirjallisuuskatsausta PRISMA-ohjeistuksen mukaisesti. Aineis-tona käytettiin kansainvälisiä tieteellisiä artikkeleita, itse pankkialan raportteja ja konsulttiselvityksiä, jotka käsittelivät generatiivisen tekoälyn sovelluksia pankkialalla. Tarkastelun painopiste oli lyhyen ja keskipitkän aikavälin vaikutuksissa.

Tulosten mukaan keskeisimmät generatiivisen tekoälyn käyttökohteet pankkisektorilla ovat asiakaspalvelun automatisointi, riskienhallinta ja petostentunnistus, sijoituspalvelut sekä operatiivisten prosessien tehostami-nen. GenAI mahdollistaa kustannussäästöjä, tehokkaampaa datan hyödyntämistä ja uusia palvelumalleja, mutta sen käyttöön liittyy myös haasteita esimerkiksi tietosuojan, sääntelyn ja eettisten kysymysten osalta. Tutkimuksen perusteella onnistunut tekoälyn hyödyntäminen vaatii pankkien ja regulaatio-osapuolten tiivistä yhteistyötä sekä selkeitä eettisiä periaatteita.

Tutkielma täydentää aiempaa kirjallisuutta tarjoamalla jäsenneilyn katsauksen alan kehityssuunnista ja nos-taa esiin pankkisektorin erityispiirteitä, kuten sääntelyn merkityksen. Jatkotutkimukselle jää aiheita esimer-kiksi pitkän aikavälin vaikutusten ja käytännön implementointien osalta.

Avainsanat: generatiivinen tekoäly, tekoäly, genAI, AI, pankkisektori, pankkiala, systemaattinen kirjallisuuskatsaus, PRISMA, riskienhallinta, asiakaspalvelu, operatiivinen tehokkuus, petostentorjunta, pankkipalvelut, digitalisaatio

Sisällysluettelo

1	Johdanto	6
1.1	Tutkimuksen tausta ja motivaatio	6
1.2	Tutkimusongelma ja tutkimuskysymykset	8
1.3	Tutkimuksen tavoitteet ja rajaukset	8
1.4	Tutkimuksen merkitys	9
1.5	Tutkimuksen rakenne	10
2	Teoreettinen viitekehys	12
2.1	Generatiivisen tekoälyn yleiskuva	12
2.1.1	Generatiivisen tekoälyn määritelmä ja teknologinen tausta	15
2.1.2	Generatiivisen tekoälyn sovellukset yleisesti	19
2.1.3	Generatiivisen tekoälyn erityispiirteet	21
2.2	Generatiivisen tekoälyn haasteet ja riskit	22
2.3	Pankkisektori yleisesti ja pankkien toiminnan erityispiirteet	24
2.3.1	Asiakaskalvelu ja asiakkuuksien hallinta	25
2.3.2	Maksut ja sitoumukset	26
2.3.3	Lainaaminen, sijoittaminen ja varainhallinta	27
2.3.4	Riskienhallinta ja sääntely	28
2.3.5	Operatiivinen toiminta	28
2.4	Generatiivisen tekoälyn erityispiirteet pankkisektorilla	29
3	Tutkimusmenetelmä	31
3.1	Systemaattinen kirjallisuuskatsaus metodologiana	31
3.2	PRISMA-ohjeisto ja sen soveltaminen	32
3.3	Aineistonkeruu	32
3.3.1	Hakustrategia ja tietokannat	33
3.3.2	Sisällyttämisen- ja poissulkukriteerit	35
3.3.3	Aineiston rajaaminen ja PRISMA-virtauskaavio	36
3.4	Aineiston analyysimenetelmät	39

4 Kirjallisuuskatsauksen tulokset	41
4.1 Generatiivisen tekoälyn käyttökohteet finanssialalla	41
4.1.1 Asiakaspalvelun parantaminen	44
4.1.2 Riskienhallinta ja petostentunnistus	46
4.1.3 Operatiivisen tehokkuuden lisääminen	47
4.1.4 Sijoitukset, lainat ja luotonhallinta	49
4.1.5 Muut käyttökohteet	51
4.1.6 Teknologioista	52
4.2 Haasteet ja riskit	54
4.2.1 Sääntelyn ja tietosuojan kysymykset	56
4.2.2 Eettiset haasteet	57
4.2.3 Teknologiset rajoitukset	59
4.3 Mahdollisuudet ja tulevaisuuden näkymät	61
4.3.1 Strateginen hyöty pankkialalla	62
4.3.2 Kilpailukyvyyn parantaminen	63
5 Tulosten pohdinta	65
6 Johtopäätökset	67
6.1 Tutkimuksen päätelmät ja kontribuutio	67
6.2 Käytännön suositukset pankkisektorille	68
6.3 Tutkimuksen rajoitteet	69
6.4 Ehdotukset jatkotutkimukselle	70
6.5 Lopuksi	71
Lähteet	72
Liitteet	95
Liite 1. Systemaattisen kirjallisuuskatsauksen aineisto	95

Kuvioluettelo

Kuvio 1 Yleiskatsaus generatiivisesta tekoälystä, mukaan lukien luettelo käytetyimmistä malleista, mukailen Bengesi ym. (2024)	14
Kuvio 2 Transformerin arkkitehtuuri (Vaswani ym., 2017)	16
Kuvio 3 Visuaalinen kuvaus yksinkertaisen autoenkooderin neuroverkon arkkitehtuurista, mukailen IBM (2024).	18
Kuvio 4 Käsitteellinen kehys generatiiviselle tekoälylle pankkialalla (mukailen (Ooi ym., 2025))	30
Kuvio 5 PRISMA-virtauskaavio	38
Kuvio 6 Valitun aineiston julkaisujakauma vuosittain	39
Kuvio 7 Valitun aineiston jakauma tietokannoittain	39
Kuvio 8 Havaintokuva erilaisista taloudellisista päättelytehtävistä (mukailen 016)	41
Kuvio 9 Aineistoon valittujen artikkelien teemojen esiintyvyys	42
Kuvio 10 Aineiston yleisimpien teemojen suhteellinen kattavuus	43
Kuvio 11 Tekoälyyn liittyvien riskien jakautuminen Finanssialan ammattilaisten näkökulmasta (N=4, 061)	55
Kuvio 12 Pankkiasiakkaiden näkemys tekoälyn eettisten ohjeistuksien tärkeydestä (061)	59
Kuvio 13 Kuluttajien näkemys siitä, milloin generatiivinen tekoäly tulisi ottaa käyttöön pankkisektorilla (n=51) (031)	62
Kuvio 14 Kuinka pankkialan tärkeimmät 20 työtehtävää tulevat hyötymään generatiivisesta tekoälystä (Accenture (053))	63
Kuvio 15 Generatiivisen tekoälyn käyttökohteet, teknologiat ja toimittajat pankkisektorilla. Visualisointi perustuu systemaattiseen kirjallisuuskatsaukseen ja alan keskeisiin kehityssuuntiin.	69

Taulukkoluetelo

Taulukko 1 Haasteet generatiivisen tekoälyn käytössä, mukailen (Rathod, 2024)	23
Taulukko 2 Hakutermit	35
Taulukko 3 kelpoisuuskaavat	36
Taulukko 4 Perinteiset ja generatiiviseen tekoälyyn pohjautuvat pankkipalvelut	43
Taulukko 5 Mahdollisuuksia suurten kielimallien käyttöön pankkisektorilla (mukailen 008)	52

1 JOHDANTO

Generatiivinen tekoäly (engl. Generative Artificial Intelligence, AI, GenAI, GAI) on noussut vallankumoukselliseksi paradigmaksi teknologian ja koneoppimisen alalla, sillä sen avulla voidaan luoda monimutkaista ja todenmukaista dataa laskennallisoin keinoin (Kaswan, Dhatteerwal, Kumar, ym., 2023). Sen merkitys heijastuu monille eri aloille, joilla synteettisen datan tuottaminen on edistänyt kehitystä. Generatiivisen tekoälyn kyky luoda uutta sisältöä ja dataa, joka heijastaa reaali maailman tiedon ominaisuuksia, on löytänyt käyttökohteita eriaisisissa ratkaisuisissa, kuten konenäkö, luonnollisen kielen käsittely, musiikin säveltäminen ja lääkkeiden kehittäminen. (Karras ym., 2019).

1.1 Tutkimuksen tausta ja motivaatio

Generatiivinen tekoäly on nopeasti kehittyvä teknologia, joka on herättänyt kiinnostusta monella sektorilla (García-Peñalvo & Vázquez-Ingelmo, 2023). Se on tekoälyn osa-alue, joka perustuu siihen, että teknologialla voi luoda jotain uutta. Generatiivinen tekoäly hyödyntää perinteisen tekoälyn lailla koneoppimistekniikoita luodakseen itsenäisesti sisältöä datan perusteella. (Shalini & Chaya, 2024). Pankkisektori, jossa perinteistäkin tekoälyä voidaan hyödyntää monissa eri toiminnoissa, kuten esimerkiksi asiakaspalvelussa, riskienhallinnassa ja liiketoimintaprosessien automatisoinnissa, tarjoaa mielenkiintoisen kontekstin generatiivisen tekoälyn sovellusten tarkastelulle. Siihen liittyvät teknologiat voivat tarjota merkittävää potentiaalia myös rahoitusanalytiikan tehostamisessa, päätöksentekoprosessien parantamisessa ja synteettisten rahoitustietojen tuottamisessa eri sovelluksia varten (Lee ym., 2024a). McKinseyn raportti *Capturing the full value of generative AI in banking* (2023) korostaa, että pankkisektori voi hyötyä merkittävästi generatiivisen tekoälyn käyttöönotosta, erityisesti asiakaskokemuksen parantamisessa, riskienhallinnassa ja kustannustehokkuuden lisäämisessä. Raportin mukaan pankkien toiminnan tehokkuus voi kasvaa jopa 30 prosenttia, kun samanaikaisesti generatiivinen tekoäly voi mahdollistaa uusien tulovirtojen luomisen tarjoamalla innovatiivisia palveluratkaisuja ja prosessien automatisointia. McKinsey Global Institute (MGI) arvioi pankkisektorin olevan suurimpien hyötyjien joukossa, kun puhutaan generatiivisen tekoälyn käyttöönotosta, vuosittaisen potentiaalisen lisätulon ollessa arvioitu 200–340 miljardia dollaria (Kamalnath ym., 2023). Rahoituspalveluihin kohdistuvista teknologisista toimista voi tulla yksi koko talouden kehityksen kannalta ratkaisevista tekijöistä. Uuden teknologian käyttöönotolla varmistetaan, että pankkipalvelut ovat koko ajan koko väestön saatavilla ja edistetään siten yhteiskunnan osallistavaa kasvua. (Shalini & Chaya, 2024). Generatiiviset tekoälymallit, kuten GPT (engl. Generative Pre-trained Transformer), tarjoavat täysin uudenlaisia mahdollisuuksia datan analysointiin, tekstin tuottamiseen ja käyttäjäkokemuksen parantamiseen. Kanbach ym. (2024) korostavat artikkelissaan, että generatiivisella tekoälyllä on merkittävä potentiaali muuttaa liiketoimintaprosesseja ja parantaa innovatiivisuutta. Synteettisen datan luominen voi olla yksi merkittävimmistä sovelluksista ja pankkisektorilla tätä voidaan

mahdollisesti hyödyntää uusien tuotteiden kehittämisessä sekä asiakasprofiloinnissa. Synteettinen data myös vähentää riippuvuutta arkaluonteisesta kovasta asiakasdatasta, mikä auttaa pankkeja toimimaan sääntelyviranomaisten asettamien vaatimusten mukaisesti. (Reznikov, 2024). Arvioitaessa generatiivisen tekoälyn vaikutusta pankkialaan, on myös huomioitava erilaisia eettisiä näkökohtia, joita tarvitaan riskien mitigoimiseksi ja päätöksenteon ohjaamiseksi (Kalia, 2023).

Generatiivinen tekoäly on mullistava teknologia, joka voi tarjota valtavia etuja pankkisektorilla, mutta sen käyttöönotto edellyttää huolellista suunnittelua, vastuullista käyttöä ja sääntelyn huomioimista. Pankkisektori on tunnetusti erittäin säädelty (Doumpos ym., 2023) ja sen toimintaympäristö on monimutkainen, mikä tekee tekoälyn soveltamisesta haastavaa mutta samalla mahdollisesti hyvin palkitsevaa. Mahdollisuuksien lisäksi generatiivisen tekoälyn käyttöönottoon liittyy myös merkittäviä riskejä ja haasteita, kuten tietoturvaan liittyvät tekijät ja tiukan regulaation noudattaminen (Kaya, 2019), sekä eettiset näkökulmat (Ahmed, 2022). Näiden seikkojen ymmärtäminen on olennaista tekoälyn tehokkaassa hyödyntämisessä pankkialalla.

Generatiivinen tekoäly kattaa laajan valikoiman erilaisia malleja, kuten *varioivia autoenkoodereita* (engl. Variational Autoencoder, VAE), *generatiivisia vastakkaisverkkoja* (engl. Generative Adversarial Network, GAN), *suuria kielimalleja* (engl. Large Language Models, LLM) ja *diffuusiomalleja* (Lee ym., 2024a). Näihin verrattain uusiin teknologioihin liittyvät suomennokset ovat osittain ongelmallisia, joten tässä työssä käytetään paikka paikoin sanojen englanninkielisiä versioita Suomenkielisten sijaan. Tämän katsauksen tavoitteena on antaa kattava yleiskatsaus generatiivisen tekoälyn viimeaikaisista suuntauksista ja edistysaskelista, sekä mahdollisista ongelmista pankkisektorin sovelluksissa.

Tekoälyä on käytetty pankkisektorilla jo ennen generatiivisen tekoälyn nousua. Ennen generatiivisten tekoälymallien kehittymistä analyysin tukena käytettiin perinteisiä menetelmiä, jotka keskittyivät esimerkiksi talousraporttien tulkintaan ja osakekurssien ennustamiseen. Näissä menetelmissä hyödynnettiin usein niin kutsuttua bag-of-words-lähestymistapaa, jossa luodaan sanavektoreita, mutta joka ei kyennyt huomioimaan sanojen kontekstia lauseissa ja suuremmissa kokonaisuuksissa. Suurten kielimallien (LLM) käyttämä transformer-arkkitehtuuri taas mahdollistaa monimutkaisten riippuvuussuhteiden ymmärtämisen sanojen välillä, mikä tuottaa tarkempia ja kontekstuaalisesti rikkaampia tuloksia. Tämän ansiosta generatiivisen tekoälyn mallit, kuten suuret kielimallit, ovat osoittaneet suurta potentiaalia rahoitusalan eri tehtävien kehittämisessä. Viime vuosina tutkimus generatiivisen tekoälyn soveltamisesta näihin tehtäviin on kasvanut merkittävästi ja samalla on tutkittu sekä saavutettuja tuloksia että teknologiaan liittyviä riskejä. (Lee ym., 2024a).

Generatiivinen tekoäly voi siis mahdollisesti tarjota pankkisektorille merkittäviä mahdollisuuksia. Vaikka teknologian potentiaali on laaja, sen käyttöön liittyy myös merkittäviä riskejä. Motivaationa tälle tutkimukselle on sekä tämän hajanaisen tiedon yhdistäminen että lisääntyneen tutkimustarpeen täyttäminen. AI Index Report (2024) ja ECIS (2024) korostavat molemmat, että tutkimus ei ole pysynyt nopean teknologisen kehityksen tahdissa ja että generatiivisen tekoälyn käytännön sovelluksia organisaatioissa on vielä tutkittava syvällisemmin. Tämän työn tavoitteena on tarjota systemaattinen

katsaus generatiivisen tekoälyn mahdollisuuksiin, haasteisiin ja vaikutuksiin pankkisektorilla, mikä tukee niin tutkimusta kuin käytännön sovelluksia.

1.2 Tutkimusongelma ja tutkimuskysymykset

Tämän tutkimuksen tutkimusongelmana on selvittää, miten generatiivista tekoälyä voidaan hyödyntää pankkisektorilla tehokkaasti. Aiemmat tutkimukset ovat keskittyneet pääosin teknologian yleisiin sovelluksiin ja mahdollisuuksiin, mutta sen erityispiirteitä pankkialalla ei ole systemaattisesti analysoitu. Tutkimus on hajanaista ja sitä tulee jatkuvasti lisää. Tämä tutkimus pyrkii täyttämään tämän aukon tuomalla systemaattisen kirjallisuuskatsauksen keinoin yhteen aiemmin tehtyä tutkimusta ja kartoittamalla generatiivisen tekoälyn keskeisiä käyttökohteita, vaikutuksia ja siihen liittyviä haasteita pankkisektorilla.

Tutkimus jakautuu kolmeen pääkysymykseen, jotka ohjaavat systemaattista kirjallisuuskatsausta:

1. Mitkä ovat generatiivisen tekoälyn yleisimmät käyttökohteet pankkisektorilla?
2. Miten generatiivinen tekoäly vaikuttaa pankkisektorin toiminnan tehokkuuteen ja tarkkuuteen?
3. Mitä haasteita ja riskejä liittyy generatiivisen tekoälyn käyttöönottoon pankkisektorilla?

Tavoitteena on tunnistaa, millä tavoin generatiivista tekoälyä hyödynnetään pankkien eri toiminoissa, kuten asiakaspalvelussa, petosten havaitsemisessa ja riskienhallinnassa. Lisäksi selvitetään, millaisia uusia mahdollisuuksia teknologia tarjoaa tulevaisuudessa pankkisektorilla. Toisella kysymyksellä pyritään selvittämään, kuinka generatiivinen tekoäly voi tehostaa pankkitoimintaa, parantaa prosessien tarkkuutta ja edistää kustannustehokkuutta. Tarkastelussa ovat myös sen vaikutukset asiakaskokemukseen ja liiketoiminnan tuloksellisuuteen. Viimeisen tutkimuskysymyksen tavoitteena on tunnistaa tekoälyn käyttöön liittyvät suurimmat ongelmat, kuten tietosuojaa, sääntelyyn liittyvät rajoitteet ja eettiset kysymykset, sekä kartoittaa keinoja näiden haasteiden ratkaisemiseksi.

1.3 Tutkimuksen tavoitteet ja rajaukset

Tämän tutkimuksen päätavoitteena on kartoittaa generatiivisen tekoälyn sovelluskohteet ja vaikutukset pankkisektorilla. Aikanäkökulmana käytetään lyhyttä ja keskipitkää aikaväliä. Tutkimuksessa pyritään vastaamaan kolmeen keskeiseen kysymykseen: mitkä ovat generatiivisen tekoälyn yleisimmät käyttökohteet pankkisektorilla, miten se vaikuttaa pankkien toiminnan tehokkuuteen ja tarkkuuteen, sekä mitkä ovat teknologian käyttöönottoon liittyvät haasteet ja riskit. Näiden kysymysten avulla tutkimus pyrkii tarjoamaan kokonaisvaltaisen kuvan generatiivisen tekoälyn roolista pankkialalla ja tukemaan sen strategista ja vastuullista hyödyntämistä.

Tarkastellussa kirjallisuudessa generatiivisen tekoälyn pankkisektorin sovelluksia tarkastellaan pääasiassa lyhyen ja keskipitkän aikavälin vaikutusten kautta. Pitkän aikavälin tarkasteluja on huomattavasti vähemmän, ja niihin sisältyy paljon epävarmuutta esimerkiksi teknologian kehityksestä ja pankkialan muutoksista. Tämän vuoksi myös tämän tutkimuksen rajaus painottuu lyhyen ja keskipitkän aikavälin vaikutuksiin, sillä näistä on saatavilla luotettavampaa ja laajemmin käsiteltyä tietoa. Lyhyen ja keskipitkän aikavälin tarkastelu mahdollistaa konkreettisten ja käytännönläheisten johtopäätösten tekemisen pankkisektorilla havaittavista trendeistä ja teknologian hyödyistä. Pitkän aikavälin vaikutuksia voidaan kuitenkin lyhyesti käsitellä kontekstin ja mahdollisuuksien näkökulmasta, mutta syvällisempi analyysi jää aiheen tuoreuden ja tiedon rajallisuuden vuoksi tämän tutkimuksen ulkopuolelle.

Metodologisesti tutkimus toteutetaan systemaattisena kirjallisuuskatsauksena PRISMA:n mukaisesti, mikä mahdollistaa aiemman kirjallisuuden kattavan ja järjestelmällisen analyysin. Aineistona käytetään pääasiassa englanninkielisiä tieteellisiä artikkeleita ja raportteja, jotka keskittyvät pankkisektorin teknologisiin sovelluksiin, vaikutuksiin ja haasteisiin. Tutkimus keskittyy erityisesti perinteisiin pankki-instituutioihin, eikä tarkastele muita finanssialan toimialoja, kuten vakuutus- tai sijoitustoimintaa tarkasti, eikä myöskään finanssisektoria kokonaisuutena. Viittauksia muihin finanssialan toimijoihin tai finanssisektoriin kokonaisuutena tutkimuksessa voi esiintyä. Tämä rajaus mahdollistaa syvällisen analyysin pankkisektorin erityispiirteistä ja tarpeista.

1.4 Tutkimuksen merkitys

Pankkisektori on yhteiskunnallisesti keskeinen toimiala, jonka vakaus, kehitys ja innovaatioiden kautta saavutetut hyödyt tai toiminnan riskit heijastuvat laajasti muuhun yhteiskuntaan ja talouteen. Pankkitoiminnan erityispiirteet, kuten tiukka sääntely, datavetoisuus ja keskeinen rooli, tekevät siitä tärkeän kohteen tutkia uusien teknologioiden, kuten generatiivisen tekoälyn, käyttöönoton näkökulmasta. Generatiivisen tekoälyn potentiaali pankkisektorilla on merkittävä, sillä se tarjoaa uusia tapoja tehostaa operatiivisia prosesseja, parantaa asiakaskokemusta ja hallita riskejä. Automatisoimalla monimutkaisia tehtäviä, kuten lainahakemusten käsittelyä ja tietojen analysointia, generatiivinen tekoäly voi vähentää kustannuksia ja lisätä tehokkuutta. Kuten mainittua, McKinsey (2023) arvioi, että generatiivisen tekoälyn täysimittainen käyttöönotto voi kasvattaa pankkisektorin vuotuista liikevaihtoa 200–340 miljardilla dollarilla ja parantaa pankkien toiminnan tehokkuutta jopa 30 prosenttia. Tämä tekee teknologian hyödyntämisestä keskeisen strategisen tavoitteen perinteisille pankkilaitoksille.

Akateemisesti tutkimus vastaa merkittävään tiedonpuutteeseen generatiivisen tekoälyn sovelluksista pankkisektorilla pyrkimällä yhdistämään aiemmat aiheen tutkimukset. Kuten AI Index Report (2024) tuo esille, että tutkimus ei ole pysynyt yritysmaailman kehityksen tahdissa ja painottaa tarvetta systemaattisille analyyseille, jotka kartoittavat tekoälyn käytännön sovelluksia. Tämä tutkimus pyrkii

täyttämään tämän tarpeen tarjoamalla järjestelmällisen katsauksen, joka yhdistää hajanaista tietoa generatiivisen tekoälyn vaikutuksista pankkisektorilla.

Generatiivisen tekoälyn kehitys ja sen käyttöönotto pankkisektorilla on ollut poikkeuksellisen nopeaa, mikä tekee tutkimusalueesta erityisen nuoren ja dynaamisen. Tämän vuoksi kirjallisuuskatsauksen laatiminen on tärkeää paitsi tiedon kokoamisen, myös tutkimusagendan suuntaamisen näkökulmasta. Kirjallisuuskatsaukset voivat tarjota ajantasaisen kokonaiskuvan siitä, mitä ilmiöstä jo tiedetään ja mitkä osa-alueet kaipaavat jatkotutkimusta. Tällä tavoin tutkimus tukee myös tulevien tutkimusaiheiden määrittelyä nopeasti muuttuvalla alueella. Lisäksi tutkimuksella voi olla yhteiskunnallista merkitystä, sillä generatiivinen tekoäly voi parantaa pankkipalveluiden saavutettavuutta ja tukea kestäviä tavoitteita. Synteettisen datan hyödyntäminen voi vähentää riippuvuutta arkaluonteisista asiakastiedoista, mikä auttaa pankkeja täyttämään tiukat tietosuojavaatimukset ja lisäämään palveluiden turvallisuutta (Reznikov, 2024). ECIS (2024) korostaa, että tekoälyn vaikutukset pankkisektorilla ulottuvat operatiivisesta tehokkuudesta aina strategiaan kehitysmahdollisuuksiin, joilla voidaan vahvistaa pankkien kilpailukykyä ja innovatiivisuutta. Tämä tutkimus pyrkii tarjoamaan syvällisen ymmärryksen näistä mahdollisuuksista ja siten edistämään pankkien digitalisaatiota ja liiketoiminnan kasvua.

1.5 Tutkimuksen rakenne

Tämä tutkielma koostuu kuudesta luvusta, jotka etenevät loogisesti tutkimusaiheen taustasta ja teoreettisista lähtökohdista metodologian ja itse tulosten analyysin kautta johtopäätöksiin. Ensimmäisessä luvussa esitellään tutkimuksen taustat ja motivaatio, tutkimuskysymykset, tavoitteet ja rajaukset sekä tutkimuksen merkitys. Luvussa perustellaan, miksi generatiivisen tekoälyn roolia pankkisektorilla on tarpeellista tutkia ja miten tämä tutkimus täydentää aiempaa kirjallisuutta.

Toinen luku muodostaa tutkimuksen teoreettisen viitekehyksen ja käsittelee generatiivisen tekoälyn keskeisiä käsitteitä, sen sovelluksia pankkisektorilla sekä aiempaa tutkimusta aiheesta. Lisäksi tarkastellaan pankkialan erityispiirteitä, jotka vaikuttavat tekoälyn käyttöönottoon ja hyödyntämiseen. Kolmannessa luvussa kuvataan tutkimuksen metodologinen toteutus. Siinä käydään läpi systemaattisen kirjallisuuskatsauksen menetelmät, aineistonkeruu ja analyysitavat PRISMA-ohjeistusta hyödyntäen sekä arvioidaan tutkimuksen luotettavuutta ja mahdollisia rajoitteita.

Neljäs luku esittelee tutkimustulokset ja tarkastelee generatiivisen tekoälyn sovelluskohteita, vaikutuksia ja käyttöönottoon liittyviä haasteita pankkisektorilla systemaattisen kirjallisuuskatsauksen pohjalta. Tulokset jäsenetään tutkimuskysymysten mukaisesti. Viides luku keskittyy tulosten tarkasteluun ja vertailuun aiempaan kirjallisuuteen, minkä pohjalta pohditaan generatiivisen tekoälyn merkitystä pankkisektorille ja sen tulevaisuuden näkymiä. Lisäksi luvussa arvioidaan pankkien mahdollisuuksia hyödyntää teknologiaa strategisesti ja tarkastellaan sen käyttöönottoon liittyviä haasteita.

Viimeinen, kuudes luku kokoaa yhteen tutkimuksen keskeiset havainnot ja johtopäätökset. Tässä luvussa arvioidaan tutkimuksen kontribuutiota niin tieteelliselle tutkimukselle kuin käytännön sovelluksille ja annetaan suosituksia jatkotutkimukselle.

2 TEOREETTINEN VIITEKEHYS

Tässä luvussa tarkastellaan tutkimuksen teoreettista viitekehystä, joka muodostaa perustan generatiivisen tekoälyn tarkastelulle pankkisektorilla. Kuten tutkimuksessa on aiemmin jo tullut esille, generatiivinen tekoäly on siis tekoälyn osa-alue, joka pystyy tuottamaan uutta dataa ja sisältöä. Sen sovellukset ulottuvat monille aloille, mukaan lukien pankkisektorin asiakaspalvelu, riskienhallinta ja rahoitusanalytiikka. (Bai ym., 2024). Pankkisektori tarjoaa erityisen kiinnostavan kontekstin teknologian hyödyntämiselle, sillä se on tunnetusti tiukasti säännelty ja dataintensiivinen toimiala (Rupeika-Apoga & Eleftherios, 2020).

Luvun tavoitteena on tuoda esille keskeiset käsitteet ja ratkaisut, jotka liittyvät generatiivisen tekoälyn soveltamiseen pankkialalla. Aluksi esitellään generatiivisen tekoälyn yleiskuvaa ja sen erityispiirteitä, kuten suurten kielimallien ja synteettisen datan luomisen keinoja. Sen jälkeen tarkastellaan lyhyesti teknologian käyttöön liittyviä haasteita ja riskejä, kuten tietosuojaa, sääntelyä ja eettisiä kysymyksiä. Lisäksi luvussa syvennytään lyhyesti niihin pankkisektorin erityispiirteisiin, jotka vaikuttavat generatiivisen tekoälyn käyttöönottoon, kuten sääntelyvaatimuksiin ja asiakastiedon käsitteelyyn. Lopuksi tarkastellaan, miten generatiivisen tekoälyn erityispiirteet voivat näkyä juuri pankkisektorilla ja mitä hyötyjä teknologia voi tarjota kyseiselle toimialalle.

2.1 Generatiivisen tekoälyn yleiskuva

Generatiivinen tekoäly edustaa tekoälyn lupaavaa uutta suuntaa, joka pystyy parantamaan tuottavuutta ja mullistamaan viestintää ja työnkulkua eri aloilla. Kuten teknologian nimikin tuo ilmi, kyseessä on eräänlainen tekoäly, joka on kykenevä tuottamaan (generoimaan) uutta sisältöä, kuten tekstiä, puhetta, kuvia, videoita, koodia tai musiikkia. OpenAI:n tarjoama ChatGPT on tutkimuksen kirjoittamishetkellä todennäköisesti tunnetuin generatiivisen tekoälyn sovellus tekstin ja kuvien tuottamiseen. Yhä useampia generatiivista tekoälyä hyödyntäviä sovelluksia on helposti saatavilla, kuten Adoben Firefly kuvia, Metan Voicebox ääntä ja Beautiful.ai:n DesignerBot erilaisia diaesityksiä varten. (R. Singh ym., 2025).

Generatiiviset mallit ovat tärkeä erilaisten mallien luokka tekoälyn saralla. Toisin kuin perinteiset mallit, jotka pyrkivät yhdistämään syötetyn datan (inputin) ja tulosdatan (outputin) soveltamalla ominaisuuksia, generatiivisten mallien tavoitteena on oppia käytetyn harjoitusdatan jakauma ja tuottaa uusia tuloksia, joilla on samanlaisia ominaisuuksia. (Zeng ym., 2023) Teknologia hyödyntää kehittyneitä neuroverkko pohjaisia malleja, kuten suuria kielimalleja, generatiivisia vastakkaisverkkoja ja diffuusiomalleja, joista jokainen tuo ainutlaatuisia ominaisuuksia ja sovelluksia generatiivisen tekoälyn kehitykseen (Routray ym., 2024). LLM-mallit, kuten OpenAI:n kehittämä ChatGPT, on koulutettu valtavilla tietomäärillä, mikä mahdollistaa niiden kyvyn ymmärtää ja tuottaa luonnollista kieltä. Muita suosittuja malleja ovat mm. Googlen Bard ja Anthropicin Claude. Generatiivinen tekoäly on

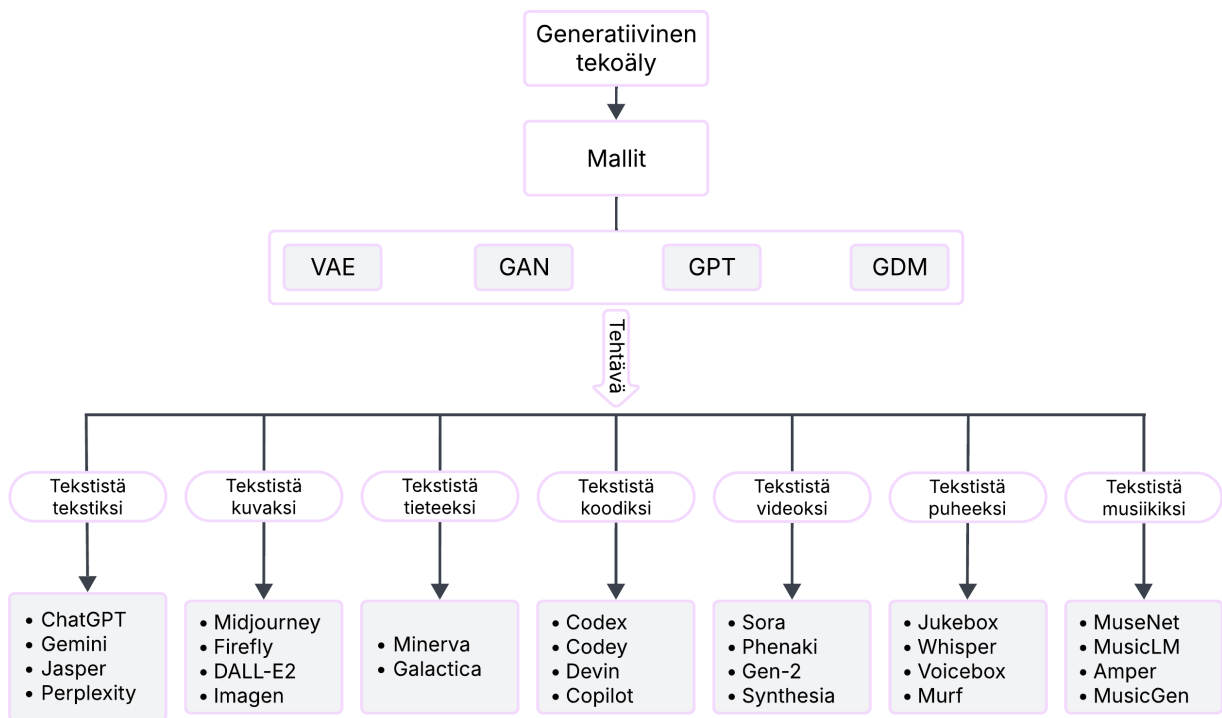
osoittanut erityistä potentiaalia asiakaspalvelun automatisoinnissa ja parantamisessa monilla toimialoilla. Suurten kielimallien, kuten ChatGPT:n, käyttö mahdollistaa asiakkaiden tarpeisiin räätälöidyt, reaaliaikaiset vastaukset ja ratkaisujen tarjoamisen. Tällaiset chatbot-pohjaiset järjestelmät vähentävät manuaalista työkuormaa, nopeuttavat vastausaikoja ja tarjoavat yhdenmukaista palvelua riippumatta vuorokaudenajasta. Lisäksi ääniavusteiset generatiiviset mallit, kuten Metan tarjoama Voicebox, laajentavat asiakaspalvelun saavutettavuutta tarjoamalla puhekäyttöliittymiä, jotka voivat olla erityisen hyödyllisiä asiakkaille, joilla on erityistarpeita tai jotka muusta syystä suosivat puhekommunikaatiota tekstipohjaisten kanavien sijaan. Näiden teknologioiden avulla voidaan luoda saumaton ja monikanavainen asiakaspalvelukokemus, joka yhdistää tekstin, äänen ja visuaaliset elementit. (R. Singh ym., 2025).

GAN-mallit puolestaan hyödyntävät kahden verkon, generaattorin ja diskriminaattorin välistä kilpailua synnyttääkseen realistisia kuvia ja muita sisältöjä. (Zeng ym., 2023). Pankkisektorilla GAN-verkkoja voidaan hyödyntää realistisen taloudellisen aikasarjadataan luomiseen, mikä voi olla hyödyllistä erilaisissa sovelluksissa, kuten riskinhallinnassa, algoritmisessa kaupankäynnissä tai stressitilauksessa. Luomalla synteettistä dataa, joka peilaa todellisen taloudellisen datan tilastollisia ominaisuuksia, nämä mallit voivat antaa pankkilaitoksille mahdollisuuden tehdä analyysejä vaarantamatta arkaluonteisia tietoja. (Eckerli & Osterrieder, 2021).

Yksi merkittävimmistä edistysaskelista generatiivisessa tekoälyssä on diffuusiomallien käyttöönotto. Nämä mallit ovat osoittautuneet erityisen tehokkaiksi kuvageneroinnissa ja synteettisen datan tuottamisessa. Diffuusiomallit perustuvat prosessiin, jossa satunnaista kohinaa lisätään dataan ja sitä poistetaan asteittain, mikä mahdollistaa erittäin realististen ja monimutkaisten sisältöjen luomisen. (Zeng ym., 2023). Tämä menetelmä on keskeinen esimerkiksi DALL-E- ja Stable Diffusion -malleissa, jotka ovat mullistaneet kuvageneroinnin ja sisältötuotannon prosesseja (Routray ym., 2024). Diffuusiomallit tarjoavat merkittäviä etuja pankkisektorilla erityisesti synteettisen taloudellisen datan generoinnissa. Sattarov ym. (2023) esittelevät tutkimuksessaan FinDiff-mallin, joka on suunniteltu tuottamaan realistista synteettistä dataa säilyttäen alkuperäisen datan tilastolliset ominaisuudet. Tämä mahdollistaa esimerkiksi taloudellisten skenaarioiden mallintamisen, stressitestien suorittamisen ja petosten havaitsemisen ilman, että luovutetaan arkaluonteisia asiakastietoja. Näin ollen diffuusiomallit voivat auttaa pankkeja noudattamaan tiukkoja tietosuojasäädöksiä, kuten GDPR:ää, samalla kun ne hyödyntävät data-analytiikkaa päätöksenteon tukena. FinDiff-mallin avulla voidaan myös edistää yhteistyötä eri pankkien ja tutkimuslaitosten välillä jakamalla synteettistä dataa ilman, että vaarannetaan yksityisyyttä tai luottamuksellisuutta. Tämä edistää innovaatioita ja parantaa riskienhallintaa pankkisektorilla.

Generatiivisen tekoälyn, kuten suurten kielimallien ja diffuusiomallien, soveltaminen voi tarjota merkittäviä mahdollisuuksia, mutta niihin liittyy myös huomattavia energia- ja laskentatehokkuuden haasteita. Nämä teknologiat ovat hyvin laskentaintensiivisiä, sillä niiden koulutus ja käyttöönotto vaativat suuria määriä laskentatehoa ja energiaa. Tämä voi aiheuttaa merkittäviä kustannuksia, erityisesti niillä aloilla, jotka hyödyntävät tekoälyä laajasti reaaliaikaisessa päätöksenteossa ja suurten

tietomassojen analysoinnissa. (Routray ym., 2024). Koneoppimisalgoritmit vaativat tyypillisesti suuria määriä dataa ja laskentatehoa, mikä johtaa algoritmien huomattavaan energiankulutukseen, veden kulutukseen harjoitusdataa sisältävien datakeskusten jäähdyttämiseen ja kasvihuonekaasupäästöjen lisääntymiseen. On arvioitu, että GPT-3:n harjoittaminen 500 miljardin sanan tietokannalla vaati aikanaan 1287 MWH virtaa ja 10 000 tietokonesirua. Lisäksi tämä koulutus tuotti noin 550 tonnia hiilidioksidia. GPT-4:n kehittämiseen käytettiin noin 570 kertaisesti energiaa verrattuna aiempaan versioon. Lisäksi jokainen ChatGPT-keskustelu kuluttaa sen päättelyaikana 5 W LED-lampun yli tunnin käyttöajan vastaavan määrän energiaa. (Bolón-Canedo ym., 2024). Maailmanlaajuisesti tekoälyyn keskittyvien datakeskusten osuus maailman sähkönkysynnästä on kirjoitushetkellä noin 0,3 prosenttia, mutta datakeskusten määrän ja niiden osuuden sähkönkysynnästä oletetaan kasvavan lähivuosina. Kansainvälinen energiajärjestö (IEA, 2023) ennustaa, että datakeskusten maailmanlaajuinen sähkönkysyntä yli kaksinkertaistuu vuosien 2022 ja 2026 välisenä aikana ja nousee yli 1 000 terawattituntiin (TWh) viimeistään vuonna 2026, mikä johtuu erityisesti tekoälyn energiantarpeen vähintään kymmenkertaistumisesta vuosina 2023–2026. (IEA, 2024).



Kuvio 1 Yleiskatsaus generatiivisesta tekoälystä, mukaan lukien luettelo käytetyimmistä malleista, mukailen Bengesi ym. (2024)

2.1.1 *Generatiivisen tekoälyn määritelmä ja teknologinen tausta*

Erilaiset työkalut, joista suurimpana ChatGPT, ovat demokratisoineet pääsyn suuriin kielimalleihin ja mahdollistaneet ihmisen kaltaisen sisällön luomisen. Generatiivisen tekoälyn käsitteelle ei kuitenkaan ole yleisesti hyväksyttyä määritelmää, mikä voi johtaa väärinkäsityksiin. Vaikka mallia, joka tuottaa mitä tahansa tuotosta, voidaan teknisesti pitää generatiivisena, tekoälyn tutkimusyhteisö varaa termin usein monimutkaisille malleille, jotka tuottavat laadukasta, ihmisen kaltaista materiaalia. (García-Peñalvo & Vázquez-Ingelmo, 2023). Nämä mallit oppivat ymmärtämään harjoitusdatan sisältämiä malleja ja rakenteita, minkä jälkeen ne tuottavat uutta dataa, jolla on samankaltaisia ominaisuuksia. Generatiiviseen tekoölyyn kuuluu erilaisia malleja, jotka on räätälöity tiettyihin tehtäviin tai median tuottamisen muotoihin. Kuten mainittua tunnetuimmat tyypit ovat generatiiviset vastakkaisverkot (engl. Generative Adversarial Networks, GAN), transformer-mallit (engl. Generative Pretrained Transformers, GPT), variaationaaliset autoenkooderit (engl. Variational Autoencoders, VAE) ja generatiiviset diffuusiomallit (engl. Generative Diffusion Models, GDM). (Sengar ym., 2024). Seuraavissa kappaleissa käsitellään näitä tarkemmin.

Generatiiviset vastakkaisverkot, teknologia jonka alun perin esitteli Jürgen Schmidhuber artikkelissaan ”Adversarial Artificial Curiosity (Schmidhuber, 1990) ja jota Goodfellow kumppaneineen (2014) tarkensi, ovat nykyisin käytetyin generatiivisen tekoälyn tekniikka. GAN käyttää neuroverkkoa. Toinen verkko, jota kutsutaan generaattoriksi, syntetisoi sisällön ja toinen verkko, diskriminaattori, arvioi generaattorin sisällön aitoutta (eli ovatko esimerkiksi generaattorin luomat kasvot luonnolliset vai vääristyneet). Verkot toistavat tätä generointi-diskriminointisykliä, kunnes generaattori tuottaa sisältöä, jota diskriminaattori ei pysty erottamaan aidosta ja synteettisestä. (Jovanović & Campbell, 2022). Tässä generatiivisessa vastakkaisverkkoasetelmassa uutta on se, että se ei ole riippuvainen raskaasti annotoidusta harjoitusdatasta (Sengar ym., 2024). Yleisimpiä käyttökohteita näille vastakkaisverkkoteknologioille ovat kuvien ja videoiden luominen sekä niiden manipulointi, grafiikka-valokuva-käännökset, resoluution parantaminen ja tekstin kääntäminen puheeksi, sekä muun synteettisen datan luonti (Dilmegani, 2024). Pankkisektorilla tekoälyn ja syväoppimismallien käytön otto voi olla hankalaa koska niihin tarvitaan suuri määrä laadukasta harjoitusdataa (Ryll et al., 2020). Tätä hankaloittaa mm. rahoitustapahtumatietojen monimutkaisuus, sektorin regulaatio sekä tietosuojatarpeet. Ratkaisu tähän voi olla käyttää synteettistä dataa, joka on keinotekoisesti tuotettua eikä poimittu todellisista asiakastapahtumista. (Karst ym., 2024a).

Transformerit tekoälytekniikkana on ensimmäisenä esitelty Ashish Vaswani kollegoineen vuonna 2017 (Vaswani ym., 2017). Transformereja käytetään yleisesti generatiivisten tekoälymallien, kuten generatiivisten esivalmennettujen transformereiden (GPT) rakentamiseen, jotka kykenevät tuottamaan johdonmukaista ja kontekstin kannalta merkityksellistä tekstiä (Sengar ym., 2024). GPT-mallit tuottavat tekstiä eri kielillä ja pystyvät luomaan ihmiseltä kuulostavia sanoja, lauseita ja kappaleita lähes kaikista aiheista ja kirjoitustyyleistä. Tuotokset ulottuvat vakuuttavista uutisartikkeleista ja esseistä asiakaspalvelun chat-robottien keskusteluihin tai videopelien hahmoihin. Malleista on kehitetty

uusia uudempia sukupolvia ja jokaisessa niistä on lisätty parametrien määrää ja ne on myös koulutettu edellistä laajemmalla verkkotekstijoukolla. Yksi tuore esimerkki on OpenAI:n GPT-3, joka hämmästytti tekoälymaailmaa kirjoittamalla ilman ihmisen apua vakuuttavan artikkelin siitä, että tiedemiehet löysivät Andien vuoristosta yksisarvislauman. (Jovanović & Campbell, 2022). Nämä Transformer-pohjaiset generatiiviset mallit voivat tarjota pankkisektorille monia mahdollisuuksia, esimerkiksi asiakaspalvelun, riskienhallinnan ja petosten ehkäisyn saralla. Transformerimallit voivat tehostaa pankkitoimintaa tarjoamalla älykkäitä chatbotteja, jotka parantavat asiakaskokemusta ja vähentävät palvelukustannuksia. Lisäksi nämä mallit voivat analysoida asiakkaiden taloudellisia tietoja ja tarjota yksilöllisiä tuotesuosituksia sekä optimoida lainapäätöksiä ja luottoriskien hallintaa analysoimalla asiakkaiden maksukykyä laajoista tietoaaineistoista. Transformerit voivat mahdollisesti myös havaita petoksia tunnistamalla epätyypillisiä käyttäytymismalleja ja arvioimalla poikkeamia reaaliajassa, mikä parantaa pankkien kykyä torjua talousrikoksia ja kyberuhkia. Lisäksi niitä voidaan hyödyntää markkinointistrategioissa luomalla yksilöllisiä viestintätapoja asiakkaille, mikä voi lisätä asiakasuskollisuutta ja myyntiä. Pankkien operatiivista tehokkuutta voidaan lisätä transformerien avulla automatisoimalla asiakirjojen käsittelyä ja analysointia, mikä säästää aikaa ja resursseja. Vaikka teknologian käyttöönotto tuo mukanaan haasteita, kuten tietosuojakysymyksiä ja mallien eettisiä rajoitteita, transformerien hyödyntäminen pankkisektorilla voi merkittävästi parantaa palveluiden laatua, riskienhallintaa ja asiakaskokemusta tulevaisuudessa. (B. Singh, 2024).

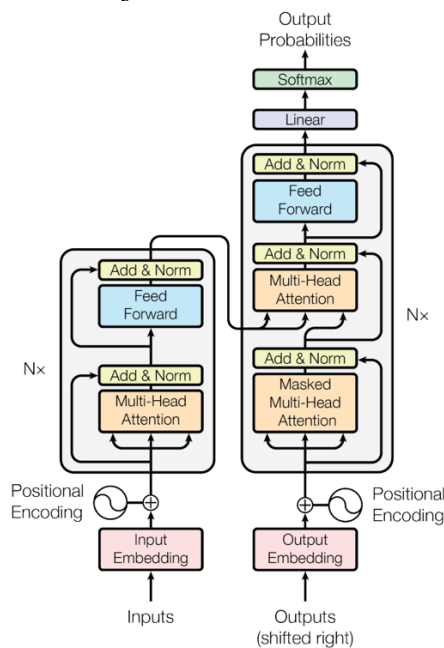
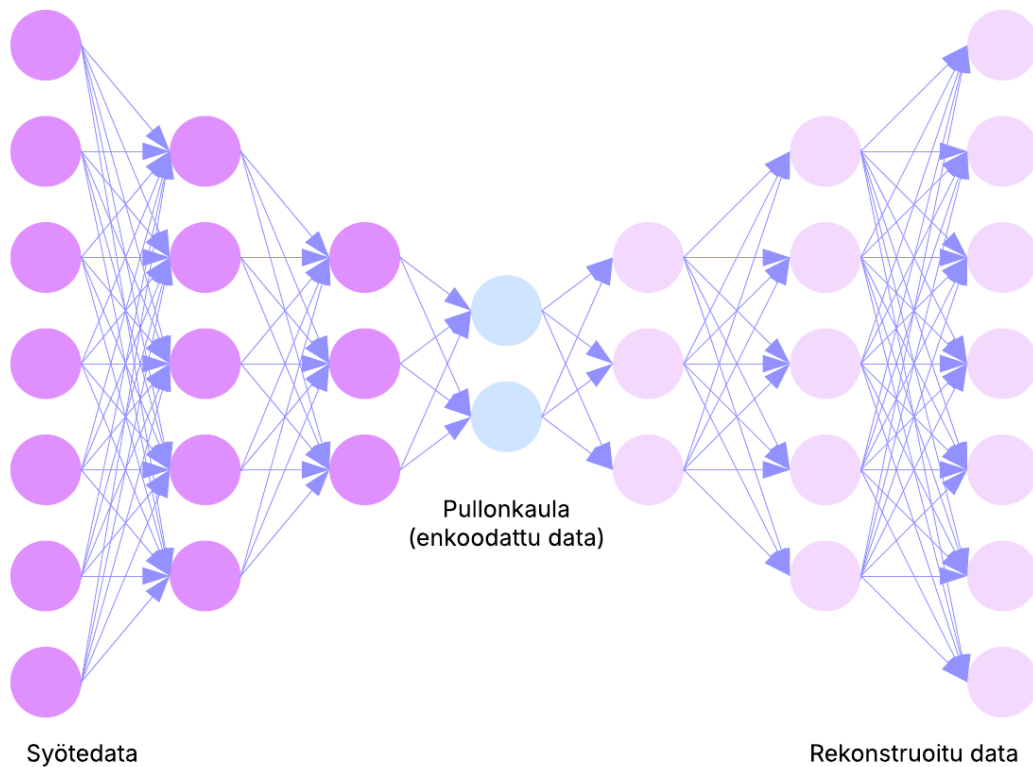


Figure 1: The Transformer - model architecture.

Kuvio 2 Transformerin arkkitehtuuri (Vaswani ym., 2017)

Varioivat autoenkooderit (VAE) ovat valvottoman (engl. unsupervised learning) koneoppimisen neuroverkkomalli, jotka koodaa syöttötiedon enkooderin avulla alempiulotteiseen esitystapaan ja

käyttää sitten dekooderia dekadaamaan sen takaisin alkuperäiseen muotoonsa vähentäen samalla rekonstruktiovirhettä (Bank ym., 2021). Tätä alempiulotteista esitystapaa kutsutaan ”pullonkaulaksi”, koska se on mallin neuroverkon kapein kohta, jossa mallin täytyy tiivistää suuri määrä alkuperäistä dataa pienempään ja yksinkertaisempaan esitykseen. Tämä tapahtuu, kun kooderi muuntaa syötteen matalan ulottuvuuden latenttitilaan, josta dekooderi yrittää palauttaa alkuperäisen datan. (Dodda, 2024; IBM, 2024). VAE:t ovat koneoppimisessa käytettäviä generatiivisia malleja, jotka tuottavat uutta dataa muunnelmina syötetystä datasta, johon ne on koulutettu. Tämän lisäksi ne suorittavat myös muille autoenkoodereille yhteisiä tehtäviä, kuten kohinanpoistoa. Kuten monet muutkin autoenkooderit, myös varioivat autoenkooderit ovat syväoppimismalleja, jotka koostuvat kooderista, joka oppii eristämään tärkeät muuttujat harjoitusdatasta ja dekooderista, joka käyttää näitä muuttujia syötetyn datan rekonstruoimiseen. Siinä missä useimmat autoenkooderiarkkitehtuurit kuitenkin koodaavat muuttujien kiinteän esityksen, VAE:t koodaavat jatkuvan, todennäköisyyteen perustuvan esityksen. Tämän ansiosta VAE voi paitsi rekonstruoida tarkasti alkuperäisen syötteen, ne voivat myös käyttää variatiivista päättelyä uusien, alkuperäistä syötetietoa muistuttavien tietonäytteiden tuottamiseen. (IBM, 2024). Variationaalisia autoenkoodereita voidaan hyödyntää pankkisektorilla erityisesti petosten ja poikkeavuuksien tunnistamisessa. VAE:t luovat todennäköisyyspohjaisen esityksen pankkitoiminnan datasta, minkä avulla ne voivat havaita epätyypillisiä tapahtumia, jotka saattavat viitata mm. petoksiin tai tietoturvariskeihin. Koska VAE:t oppivat datan normaalin jakauman, ne pystyvät tunnistamaan poikkeamia esimerkiksi asiakaskäyttäytymisessä tai maksutapahtumissa, mikä voi auttaa ennakoimaan ja estämään petollisia siirtoja ennen niiden toteutumista. Lisäksi VAE:t voivat generoida synteettistä dataa, jota voidaan hyödyntää pankkien riskianalyyysissa ja järjestelmien kouluttamisessa. Synteettinen data mahdollistaa uusien petosmuotojen simuloinnin ilman, että käytetään oikeita asiakastietoja, mikä on tärkeää sekä tietosuojan että sääntelyvaatimusten kannalta. Näiden ominaisuuksien ansiosta variationaaliset autoenkooderit voivat parantaa pankkien turvallisuutta ja tehokkuutta yhdistämällä perinteisten luokittelualgoritmien tarkkuuden generatiivisten mallien joustavuuteen. (Tanvirahmedshuvo ym., 2024).



Kuvio 3 Visuaalinen kuvaus yksinkertaisen autoenkooderin neuroverkon arkkitehtuurista, mukailen IBM (2024).

Generatiiviset diffuusiomallit (GDM) on suunniteltu parantamaan yksinkertaisemman GAN-tekniikan suorituskykyä ja uuden tekniikan esitteli Kingma kumppaneineen (Kingma ym., 2016; Sengar ym., 2024). Ne syntetisoivat eli luovat uutta sisältöä ottamalla harjoitusdatajakautuksen, lisäämällä siihen vähitellen kohinaa ja sitten oppimalla miten data saadaan takaisin, kohinan lisäysprosessin käänteisenä prosessina. Tällä tavoin dataa luodaan satunnaisesti otetusta kohinasta opitun kohinanpoistoprosessin avulla. (Jovanović & Campbell, 2022). Diffuusiomalleilla pystytään ratkaisemaan haasteita, joita esiintyy esimerkiksi variaationaalisissa autoenkoodereissa, kuten jakaumien yhteensovittaminen, tarjoamalla vakaampi koulutustavoite ja ratkaisemalla laskennallisia rasitteita (Cao ym., 2023; Pang ym., 2024). Viimeaikaiset tutkimukset ovat laajentaneet diffuusiomallien sovelluksia useille aloille, joissa tarvitsee generoida uutta dataa, kuten äänenkäsittelyyn, konenäköön ja laskennalliseen biologiaan. Näissä sovelluksissa diffuusiomallit tarjoavat joustavan tavan mallintaa korkean ulottuvuuden dataa ja toimivat generointimalleina, jotka voivat aktiivisesti ohjata uusien otosten generointia haluttujen ominaisuuksien suuntaan. Ohjatun generoinnin avulla diffuusiomalleja voidaan säätää tuottamaan tiettyjä ominaisuuksia sisältäviä otoksia ilman, että mallin parametreja tarvitsee päivittää,

mikä tekee niistä tehokkaita ja monipuolisia työkaluja moniin tehtäviin. (Chen ym., 2024a). Diffuusiomallit voivat tarjota pankkisektorille merkittäviä mahdollisuuksia erityisesti riskienhallinnan, asiakasanalytiikan ja petosten tunnistamisen saralla. Myös generatiivisia diffuusiomalleja voidaan hyödyntää rahoitusdatan synteettiseen generointiin, jolloin ne voivat mallintaa ja tuottaa realistisia mutta yksityisyyden suojaamia tietoja esimerkiksi taloudellisten stressitestien ja petostentorjunnan tarpeisiin. (Sattarov ym., 2023). Lisäksi diffuusiomalleihin perustuvat järjestelmät voivat parantaa taloudellisten aikasarjojen analysointia ja ennustamista poistamalla niistä kohinaa, mikä auttaa tunnistamaan piileviä trendejä ja parantamaan sijoituspäätösten tarkkuutta (Wang & Ventre, 2024). Näiden lisäksi diffuusiomalleja voidaan hyödyntää riskianalyyssissä ja sääntelyvaatimusten mallintamisessa, sillä ne pystyvät simuloimaan erilaisia talousskenaarioita ja arvioimaan pankkien vakautta eri markkinaolosuhteissa (Chen ym., 2024b).

2.1.2 Generatiivisen tekoälyn sovellukset yleisesti

Kuten tässäkin tutkimuksessa on jo käynyt ilmi, generatiivinen tekoäly on nopeasti kehittyvä teknologia, jolla on laaja kirjo sovelluksia eri aloilla kuten kuvantamisessa, luonnollisen kielen käsittelyssä, tietämyksenhallinnassa ja synteettisen datan tuotannossa. Erilaiset mallit, kuten generatiiviset vastakaisverkot, variationaaliset autoenkooderit ja transformeripohjaiset kielimallit tarjoavat kehittyneitä menetelmiä tiedon analysointiin ja uusien sisältöjen luomiseen. Viime vuosina teknologian sovellukset ovat laajentuneet erityisesti lääketieteeseen, tietoturvaan, rahoitusalaan, multimediaan ja ohjelmistokehitykseen, mikä osoittaa sen monialaisen merkityksen. (Sengar ym., 2024).

Yksi merkittävimmistä sovelluksista on kuvantamisen ja kuvakäännöksen automatisointi. Generatiivinen tekoäly pystyy muuntamaan kuvia eri formaattien välillä, parantamaan kuvien laatua ja tuottamaan esimerkiksi synteettisiä lääketieteellisiä kuvia. Esimerkiksi GAN-mallit, kuten Pix2Pix (Henry ym., 2021) ja CycleGAN (Chu ym., 2017), ovat mahdollistaneet MRI-kuvien konvertoinnin eri kuvantamismenetelmien välillä, mikä voi auttaa lääkäreitä saamaan tarkempia diagnostisia tietoja. Samoin SAR-satelliittikuvien laadun parantaminen tekoälyn avulla mahdollistaa entistä tarkemman maanpinnan analyysin, mikä on kriittistä esimerkiksi luonnonkatastrofien hallinnassa. (Sengar ym., 2024)

Toinen keskeinen sovellusalue on luonnollisen kielen käsittely (engl. Natural Language Processing, NLP), jossa generatiivinen tekoäly tarjoaa tehokkaita työkaluja tekstintuotantoon, asiakaspalvelun automatisointiin ja kielimallien kehittämiseen. Transformerimallit, kuten GPT ja BERT ovat tuoneet merkittäviä edistysaskelia konekääntämisessä, kysymysten ymmärtämisessä ja asiakirjojen analysoinnissa. Näitä malleja käytetään muun muassa monikielisten asiakaspalvelujärjestelmien kehittämiseen ja oikeudellisten asiakirjojen automaattiseen tiivistämiseen. Lisäksi generatiiviset kieli-

mallit voivat luoda tarkkoja tekstiivitelmiä ja automatisoituja raportteja, mikä säästää organisaatioilta aikaa ja resursseja. (Sengar ym., 2024). Viimeaikaiset vertailututkimukset ovat osoittaneet, että NLP-sovelluksiin kehitetyt generatiiviset tekoälytyökalut, kuten OpenAI:n ChatGPT, Google Bard, Microsoft Bing Assistant (nyk. Copilot) ja HuggingChat, tarjoavat tehokkaita ratkaisuja tekstin luomiseen, muokkaukseen ja analysointiin. Näiden työkalujen kyky ymmärtää ja tuottaa luonnollista kieltä on kehittynyt huomattavasti ja ne tarjoavat käyttäjilleen monipuolisia sovelluksia asiakaspalvelussa, hakukoneintegraatiossa ja sisällöntuotannossa. Vaikka generatiiviset kielimallit ovat parantaneet asiakaskokemusta ja tuottavuutta, ne herättävät myös haasteita liittyen tietoturvaan, yksityisyyteen ja eettisiin kysymyksiin. Esimerkiksi NLP-pohjaiset AI-mallit voivat tahattomasti tuottaa harhaanjohtavaa tietoa, mikä vaatii niiden huolellista valvontaa ja säätelyä. Lisäksi kielimallit saattavat välittää ja toistaa vinoumia, jotka ovat peräisin niiden koulutusdatasta, mikä voi vaikuttaa negatiivisesti päätöksentekoon ja käyttäjäkokemukseen. (Iorliam & Ingio, 2024). Pankkisektorilla generatiivinen tekoäly voi tuoda helpotusta dokumenttien käsittelyyn automatisoimalla monimutkaisia prosesseja, kuten lainahakemusten käsittelyä, petosten havaitsemista ja sääntelyvaatimusten noudattamista. Tekoälypohjainen älykäs dokumenttien käsittely yhdistää koneoppimisen, luonnollisen kielen käsittelyn ja robotiikkaan perustuvan prosessiautomaation (RPA) vähentäen tarkastusaikoja, virheitä ja tehostaen sääntelyn seurantaan. Tutkimusten mukaan pankit, jotka hyödyntävät AI-pohjaista dokumenttiautomaatiota, voivat käsitellä lainahakemuksia 70 % nopeammin, voivat parantaa petosten havaitsemista 50 % ja alentaa sääntelykustannuksia 40 %. (Ramesh Pingili, 2025).

Tietoturvan ja mm. petosten torjunnan osa-alueilla generatiivinen tekoäly tarjoaa kehittyneitä menetelmiä epätavallisten käyttäytymismallien tunnistamiseen ja reaaliaikaisen kyberturvallisuuden parantamiseen. Erityisesti rahoitusalailla, kuten myös terveydenhuollon aloilla synteettisen datan generointi mahdollistaa asiakasdatan anonymisoinnin ja turvallisen analysoinnin ilman arkaluontoisten tietojen paljastamista. Pankkialalla tämä generatiivisen tekoälyn mahdollistama synteettisen datan luonti voi tarjota merkittäviä etuja erityisesti tietosuojan, petosten tunnistamisen ja riskienhallinnan osalta. Synteettinen data viittaa keinotekoisesti tuotettuun dataan, joka säilyttää alkuperäisen aineiston tilastolliset ominaisuudet, mutta ei sisällä todellisia asiakastietoja. Tämä on erityisen tärkeää pankkisektorilla, jossa sääntely ja tietosuojavaatimukset (esim. GDPR ja PCI DSS v4.0) rajoittavat asiakkaiden henkilökohtaisten tietojen käyttöä analytiikka- ja kehitystarkoituksiin. (Karst ym., 2024b). Lisäksi tekoälymalleja voidaan käyttää maksutapahtumien reaaliaikaiseen analysointiin, jolloin petosyritykset voidaan havaita nopeasti ja estää ennen niiden toteutumista (Desai, Mallya, ym., 2024). Samalla tavoin generatiivisia malleja voidaan hyödyntää haittaohjelmien ja kyberhyökkäysten tunnistamisessa, jolloin niiden avulla voidaan analysoida suuria tietomassoja ja havaita poikkeamia normaaleista toimintamalleista (Sengar ym., 2024).

Ohjelmistokehityksen alalla generatiivinen tekoäly tukee automaattista koodin kirjoittamista, virheenkorjausta ja ohjelmistodokumentaation tuottamista. Esimerkiksi GitHub Copilot (Moradi Dakhel ym., 2023) ja muut koodiavustajat hyödyntävät generatiivisia malleja suosittelemaan ohjelmointikoodia reaaliajassa, mikä vähentää kehittäjien työkuormaa ja nopeuttaa ohjelmistojen tuotantoprosessia.

Lisäksi tekoäly voi auttaa debuggaamaan ja optimoimaan olemassa olevaa koodia, mikä voi parantaa ohjelmistojen suorituskykyä ja turvallisuutta. Tämä mahdollistaa tehokkaamman ohjelmistokehityksen ja lisää tuottavuutta monilla teknologia-aloilla. (Sengar ym., 2024). Tutkimuksessaan Idrisov ja Schlippe, (2024) analysoivat seitsemän eri generatiivisen tekoälysovelluksen kykyä tuottaa ohjelmakoodia eri ohjelmointikielillä (Java, Python ja C++). Analyysi osoitti, että esimerkiksi GitHub Copilot (GPT-3.0) tuotti oikean ratkaisun n. 50 % tapauksista, kun taas Bing AI (GPT-4.0) onnistui n. 39 % ja ChatGPT (GPT-3.5) n. 22 % tapauksista. Lisäksi havaittiin, että vaikka sovellusten tuottamat koodit olivat usein virheellisiä, monissa tapauksissa pienillä manuaalisilla muutoksilla niistä saatiin toimivia ratkaisuja, mikä nopeuttaa ohjelmistokehitystä jopa 71,3 % verrattuna käsin tehtyyn koodaukseen. (Idrisov & Schlippe, 2024).

Tekoälyn sovellukset ulottuvat myös lääkekehitykseen ja molekyyliuunnitteluun, missä generatiiviset mallit voivat ennustaa uusien lääkemolekyylien rakenteita ja simuloida niiden vaikutuksia ennen laboratoriokokeita. Tämä voi nopeuttaa lääkekehitysprosessia ja vähentää kokeellisten tutkimusten kustannuksia. Esimerkiksi AlphaFold-malli (Jumper ym., 2021) on mullistanut proteiinien laskennallisen rakenteen ennustamisen, mikä on tärkeää uusien hoitomuotojen kehittämisessä. Näiden sovellusten avulla generatiivinen tekoäly voi merkittävästi edistää terveydenhuollon tutkimusta ja lääketieteellistä innovointia. (Sengar ym., 2024).

2.1.3 Generatiivisen tekoälyn erityispiirteet

Generatiivinen tekoäly eroaa perinteisestä tekoälystä erityisesti siinä, että se pystyy luomaan uutta dataa sen sijaan, että se vain analysoisi olemassa olevaa tietoa. Perinteiset tekoälymallit, kuten luokittelijat ja ennustavat mallit, keskittyvät datan käsittelyyn ja päätöksenteon tukemiseen, kun taas generatiiviset mallit, kuten generatiiviset vastakkaisverkot ja transformerimallit pystyvät tuottamaan täysin uutta sisältöä, kuten tekstiä, kuvia ja ääntä. (Kaswan, Dhatlerwal, Malik, ym., 2023). Vaikka generatiiviset mallit eivät ole tietoisia luojia, niiden toiminta muistuttaa ihmisen luovaa prosessia. Ne kykenevät tuottamaan uudenlaista sisältöä, jota ei ole suoraan kopioitu niiden koulutusdatasta. Esimerkiksi generatiiviset kielimallit voivat kehittää uusia tarinoita, joita ei ole aiemmin kirjoitettu. Tämä nostaa esiin kysymyksen siitä, voidaanko tekoälyä pitää aidosti luovana toimijana vai onko sen "luovuus" vain monimutkaista tilastollista mallintamista. (Rathod, 2024). Vaikka generatiiviset mallit ovat kehittyneitä, ne perivät ja mahdollisesti jopa voimistavat koulutusaineistonsa harhoja. Esimerkiksi kuvageneraattorit ja kielimallit ovat saaneet kritiikkiä sukupuoleen ja etnisyyteen liittyvien stereotyyppien toistamisesta. (Sadeghiani, 2024). Generatiivisen tekoälyn käyttö ja kouluttaminen vaatii huomattavan määrän energiaa. Yhden ChatGPT-kyselyn energiankulutuksen on arvioitu olevan noin kymmenkertainen verrattuna yhteen Google-hakuun. SITRAn mukaan tämä johtuu suurten kielimallien monimutkaisuudesta ja laskentatehon tarpeesta. Lisäksi tekoälymallien koulutus ja käyttö

voivat kuluttaa huomattavia määriä vettä datakeskusten jäähdytykseen, mikä lisää ympäristökuormitusta. (SITRA, 2024).

2.2 Generatiivisen tekoälyn haasteet ja riskit

Generatiivinen tekoäly voi siis tarjota merkittäviä mahdollisuuksia eri toimialoilla, kuten pankkisektorilla ja teollisuudessa. Finanssialalla sen sovellusalueita voivat olla esimerkiksi asiakaspalvelun automatisointi, petostentorjunta ja riskienhallinta. (Moharrak & Mogaji, 2024a). Luovilla aloilla se voi edistää sisällöntuotantoa ja ihmisten sekä tekoälyn välistä yhteistyötä (Sun ym., 2024). Kuitenkin näiden teknologioiden käyttöönottoon liittyy monia haasteita, jotka voidaan jakaa muutamaaan pääkategoriaan: dataan liittyvät rajoitteet, tekniset rajoitteet, eettiset ja yhteiskunnalliset riskit sekä regulaatio ja lainsäädäntö (Rathod, 2024). Teknisistä haasteista keskeisin on mallien hallittavuus ja luotettavuus. Suurten kielimallien ja generatiivisten kuvamallien kohdalla on havaittu ongelmia ennustettavuuden ja tarkkuuden suhteen, mikä voi johtaa virheellisiin tai hallusinoituneisiin vastauksiin. (Manduchi ym., 2024). Erityisesti pankkisektorilla tämä voi olla kriittistä, sillä tekoälyn tekemät virheelliset ennusteet voivat aiheuttaa merkittäviä taloudellisia tappioita ja vahingoittaa asiakassuhteita. Eettisellä tasolla generatiivinen tekoäly voi vahvistaa syrjiviä käytäntöjä, koska se perustuu historialliseen koulutusaineistoon, jossa voi olla rakenteellisia vinoumia. Esimerkiksi pankkien käyttämät tekoälymallit voivat tehdä ennakkoluuloisia päätöksiä lainanmyynnissä, jos ne on koulutettu datalla, joka heijastaa aiempia syrjiviä käytäntöjä. (Moharrak & Mogaji, 2024a).

Näiden lisäksi generatiiviseen tekoälyyn liittyvät haasteet voidaan tarkentaa useisiin muihin kriittisiin kategorioihin. Datan laatu ja vinoumat ovat keskeisiä ongelmia, sillä generatiiviset mallit ovat riippuvaisia koulutusaineistostaan. Jos data on liian yksipuolista tai se sisältää vinoumia, mallit voivat tahattomasti vahvistaa stereotypioita ja tuottaa epätarkkoja tai syrjiviä tuloksia. Laskentaresurssien suuri tarve on toinen merkittävä haaste, sillä pitkälle kehittyneet mallit ja sovellukset vaativat suuria määriä laskentatehoa ja datan käsittelykapasiteettia, mikä voi rajoittaa niiden käyttöä pienemmissä organisaatioissa. Lisäksi mallien tulkittavuus ja hallinta voi olla ongelmallista, koska monimutkaisten mallien päätöksentekoprosessit ovat usein vaikeasti selitettäviä. Tämä voi hankaloittaa vastuullista käyttöä ja luottamuksen rakentamista tekoälyyn, erityisesti pankki- ja finanssialalla, jossa sääntelyviranomaisten on voitava valvoa päätösten perustelua. (Moharrak & Mogaji, 2024a; Rathod, 2024).

Tekoälyyn liittyy myös turvallisuusriskejä, sillä sitä voidaan hyödyntää haitallisiin tarkoituksiin, kuten väärennettyjen asiakirjojen, petollisten kuvien ja videoiden tai huijausviestien luomiseen. Tämä lisää tietoturvaohkia ja vaatii vahvoja todennusmekanismeja väärinkäytösten estämiseksi. Edellä mainittujen lisäksi lainsäädäntö ja regulaatio asettavat lisähaasteita, sillä tekoälyn oikeudelliset ja eettiset rajat ovat vielä kehittymässä. Tekijänoikeuskiistat, vastuun kohdentaminen ja tietosuojakysymykset vaativat tarkempia sääntelymalleja, jotta generatiivinen tekoäly ja sen

sovellukset voidaan integroida turvallisesti eri toimialoille. Näiden haasteiden vuoksi generatiivisen tekoälyn kehityksessä tarvitaan monialaista yhteistyötä, jossa yhdistyvät teknologinen innovaatio, eettinen harkinta ja lainsäädännöllinen valvonta. (Rathod, 2024).

Taulukko 1 Haasteet generatiivisen tekoälyn käytössä, mukailten (Rathod, 2024)

#	Haaste tai riski	Kuvaus
1	Datan laatu ja vinoumat	Generatiiviset mallit ovat riippuvaisia koulutusaineistonsa laadusta. Jos data sisältää ennakkoluuloja tai on puutteellista, mallit voivat tuottaa virheellisiä, harhaanjohtavia tai syrjiviä tuloksia.
2	Eettiset huolenaiheet	Tekoälyllä voidaan luoda ja levittää manipuloitua sisältöä, kuten deepfake-videoita, mikä herättää kysymyksiä yksityisyydestä, suostumuksesta ja väärinkäytöksistä.
3	Laskentaresurssien tarve	GenAI:n kouluttaminen ja käyttö vaativat suuria määriä laskentatehoa ja dataa, mikä voi estää pienempiä organisaatioita hyödyntämästä teknologiaa.
4	Mallien tulkittavuus ja hallittavuus	Generatiivisten mallien päätöksentekoprosessi on usein vaikeasti ymmärrettävä. Tämä hankaloittaa vastuullista käyttöä ja vaikeuttaa mallien toimintalogiikan selittämistä käyttäjille ja sääntelyviranomaisille.
5	Mode collapse -ilmiö	Erytesiti generatiivisissa vastakkaisverkkomalleissa voi esiintyä ongelma, jossa malli tuottaa vain rajallisia ja toistuvia lopputuloksia, eikä hyödynnä koko koulutusaineiston monimuotoisuutta.
6	Yleistettävyyys ja ”robustisuus”	Generatiivisten mallien on vaikea yleistää hyvin tuntemattomiin aineistoihin tai käsitellä uusia syöteolosuhteita. Tämä voi johtaa epärealistisiin, vääristyneisiin tai huonolaatuisiin tuloksiin.
7	Turvallisuusriskit	GenAI:ta voidaan hyödyntää petoksiin, väärän tiedon levittämiseen tai sosiaalisten manipulointihyökkäysten (engl. social engineering) toteuttamiseen. Näiden uhkien torjuminen edellyttää vahvoja tunnistus- ja suojausmekanismeja.
8	Lainsäädännölliset ja sääntelyhaasteet	Tekoälyyn liittyvä lainsäädäntö on vielä kehittymässä. Tekijänoikeuskysymykset, oikeudellinen vastuu ja tietosuoja aiheuttavat haasteita, jotka vaativat poliittisilta päättäjiltä ja yrityksiltä selkeitä sääntelylinjauksia.

Pankkisektorilla generatiivisen tekoälyn käyttöönottoon voi liittyä erityisiä haasteita, jotka voivat vaarantaa sekä finanssialan toiminnan luotettavuuden että asiakasturvallisuuden. Kyberturvallisuusriskit ovat yksi merkittävimmistä uhkista, sillä generatiivista tekoälyä voidaan hyödyntää petollisiin tarkoituksiin, kuten realististen phishing-sähköpostien, väärennetyjen taloudellisten tietojen tai jopa synteettisten identiteettien luomiseen. Perinteiset tietoturvamekanismit eivät välttämättä pysty vastaamaan tekoälyllä ohjattujen petosten kasvavaan sofistikoituneisuuteen, mikä lisää riskiä rahoituslaitoksille. (Deloitte, 2023; Stanoevska, 2024).

2.3 Pankkisektori yleisesti ja pankkien toiminnan erityispiirteet

Tässä luvussa pankkitoiminta jaetaan osa-alueisiin hyödyntäen kansainvälisesti vakiintuneita pankkialan viitekehyksiä: APQC:n Banking Process Classification -viitekehystä sekä BIAN:n Service Landscape -rakennetta, jota pääsi selaamaan BIAN-portaalin kautta. Näiden viitekehysten mukaisesti pankkien ydintoiminnot voidaan jäsentää esimerkiksi asiakaspalveluun, maksuliikenteeseen, luotonantoon, varainhallintaan, riskienhallintaan ja operatiiviseen toimintaan. Tämän rakenteen käyttö mahdollistaa generatiivisen tekoälyn käyttökohteiden, haasteiden ja mahdollisuuksien tarkastelun systemaattisesti pankkisektorin eri toimintojen näkökulmasta. (APQC, 2014; BIAN, 2025) Luvun jäsenys pohjautuu näihin viitekehyksiin sekä aiemman kirjallisuuden esiin nostamiin pankkitoiminnan osa-alueisiin. Pankkisektori on keskeinen osa taloudellista järjestelmää, sillä se vastaa rahoituksen välityksestä eri toimijoiden välillä ja ylläpitää luottamusta rahamarkkinoilla. Pankkien perustehtävät, kuten talletusten vastaanottaminen, lainananto ja maksuliikenteen hallinta, muodostavat rahoitusjärjestelmän ytimen. Pankit toimivat myös välittäjinä rahoitusmarkkinoilla, yhdistäen säästäjät ja lainantarvitsijat joko suoraan pääomamarkkinoiden kautta tai epäsuorasti pankkijärjestelmän kautta. Epäsuorassa rahoituksessa pankit hankkivat varoja tallettajilta ja myöntävät niitä eteenpäin luottoina, kun taas suorassa rahoituksessa yritykset ja muut toimijat voivat hankkia rahoitusta suoraan esimerkiksi velkakirjojen tai osakkeiden liikkeellelaskun kautta (Lindholm ym., 2016).

Pankkitoiminta voidaan jakaa eri segmentteihin, joista keskeisiä ovat liikepankit, investointipankit ja keskuspankit. Liikepankit tarjoavat perinteisiä palveluita, kuten talletuksia, lainoja ja maksuliikennettä, kun taas investointipankit keskittyvät arvopaperikauppaan, yritysjärjestelyihin ja muihin rahoitusmarkkinatoimintoihin. Keskuspankki puolestaan vastaa rahan tarjonnan säätelystä ja finanssijärjestelmän vakauden ylläpidosta. Keskuspankilla on yksinoikeus rahapoliittisten päätösten tekoon, kuten korkotasojen asettamiseen ja rahamäärän hallintaan. (Stosic-Mihajlovic & Jovic, 2017). Pankkien toiminta on vahvasti säänneltyä ja esimerkiksi Basel III -sopimus asettaa vaatimuksia niiden vakavaraisuudelle ja riskienhallinnalle, jotta ne kestävät taloudellisia häiriöitä (Hirvonen & Walta, 2019; Valkonen, 2022).

Pankkisektorin toimintaympäristö on muuttunut voimakkaasti digitalisaation ja fintech-yritysten nousun myötä. Uudet toimijat ovat tuoneet markkinoille innovatiivisia rahoitusratkaisuja, kuten vertaislainauksen ja joukkorahoituksen, joissa perinteinen pankki ei välttämättä ole mukana lainan välittäjänä (Valkonen, 2022; Finanssivalvonta, 2018). Tämä kehitys on lisännyt kilpailua ja pakottanut pankit kehittämään palveluitaan vastaamaan muuttuvia asiakastarpeita. Pankkisektorin erityispiirteisiin kuuluvat siis sekä tiukka sääntely että jatkuva teknologinen murros, jotka muokkaavat alan tulevaisuutta. (Lindfors, 2019; Stosic-Mihajlovic & Jovic, 2017).

Kuten mainittua, pankkisektori on äärimmäisen säädelty toimiala. Pankkisektorin sääntely on viime vuosina kokenut merkittäviä muutoksia, joita on kuvattu jopa "sääntelyaallosiksi". Tämä kehitys ei kuitenkaan ole uusi ilmiö; esimerkiksi 1930-luvun suuren laman jälkeen sääntelyä kiristettiin huomattavasti. Sääntelyn tavoitteena on perinteisesti ollut suojella pankkisektoria kriiseiltä, tarjota turvaa

sijoittajille ja kuluttajille sekä ylläpitää makrotaloudellista tasapainoa. (Mäkelä, 2018). Pankkien sääntely on keskeinen osa rahoitusjärjestelmän vakauden ylläpitämistä ja se vaikuttaa suoraan pankkien toimintaan sekä niiden vaikutuksiin reaalityöelouteen. Sääntelyn tavoitteet voidaan jakaa mikro- ja makrotason sääntelyyn. Mikrotasolla keskitytään yksittäisten pankkien vakavaraisuuden ja toiminnan varmistamiseen, kun taas makrotason regulaatio pyrkii turvaamaan koko pankkisektorin kestävyuden ja taloudellisen vakauden. (Jakovljević ym., 2015). Teknologian nopea kehitys on tuonut uusia haasteita pankkisääntelylle, erityisesti tekoälyn ja FinTech-palveluiden kasvavan roolin myötä. Rahman ym. (2023) korostavat, että tekoälyn käyttöönotto pankkisektorilla on kohdannut sääntelyllisiä esteitä, koska monissa maissa ei ole vielä annettu selkeitä ohjeita tekoälyn soveltamisesta pankkipalveluihin. Tämä on johtanut siihen, että pankit eivät ole proaktiivisesti ottaneet käyttöön tekoälypohjaisia järjestelmiä, koska niiden sääntelyyn liittyvä epävarmuus voi lisätä juridisia ja taloudellisia riskejä. (Rahman ym., 2023).

2.3.1 Asiakaskalvelu ja asiakkuuksien hallinta

Asiakaspalvelu ja asiakkuuksienhallinta (engl. Customer Relationship Management, CRM) ovat keskeisiä toimintoja palvelualoilla, mutta pankkisektorilla niihin kohdistuu erityisiä vaatimuksia ja odotuksia. Asiakaspalvelulla tarkoitetaan kaikkia niitä vuorovaikutustilanteita ja järjestelmiä, joiden kautta asiakas saa tarvitsemansa palvelun tai tuen. Asiakkuuksienhallinta puolestaan viittaa strategiaan lähestymistapaan, jossa asiakassuhteita hallitaan systemaattisesti tavoitteena asiakastyytyväisyyden lisääminen, asiakasuskollisuuden vahvistaminen ja asiakasarvon maksimointi koko asiakassuhteen elinkaaren ajalta. (Laketa ym., 2015)

Pankkisektorilla asiakaspalvelu eroaa muista toimialoista muun muassa korkean sääntelytason, monimutkaisten tuotteiden ja pitkien asiakassuhteiden vuoksi. Pankkipalvelut ovat usein henkilökohtaisia ja edellyttävät asiakkaan luottamusta, mikä tekee palvelun laadusta ratkaisevan tärkeää. Laadukas palvelu näkyy erityisesti verkkoasiakaspalvelussa, jossa esimerkiksi oikea-aikaiset ja virheettömät tapahtumat sekä henkilökohtaiset vastaukset sähköposteihin ovat kriittisiä tekijöitä asiakastyytyväisyyden kannalta. (Rahi ym., 2020)

Useat tutkimukset osoittavat, että palvelun laatu vaikuttaa suoraan asiakkaiden käyttäytymiseen, mukaan lukien aikomukseen ottaa verkkopankkipalvelut käyttöön. Mitattaessa pankkipalvelujen asiakaspalvelun laatua, sen ulottuvuuksista erityisesti pätevyys, luotettavuus, vastaavuus ja empatia ovat korostuneet. (Hajiyan ym., 2015) Pankkialalla asiakaspalvelun laatua ei voi tarkastella irrallaan CRM:stä, sillä tutkimukset osoittavat selkeän yhteyden CRM:n käyttöönoton ja parantuneen palvelun laadun sekä asiakasuskollisuuden välillä. (Hajiyan ym., 2015; Laketa ym., 2015)

CRM-järjestelmät mahdollistavat asiakassegmentoinnin asiakkaan käyttäytymisen, arvojen ja tarpeiden mukaan. Esimerkiksi CLV-mallit (Customer Lifetime Value) arvioivat asiakkaan pitkän aika-

välin tuottoarvoa pankille, kattaen koko tuoteportfolion ja ostokäyttäytymisen. Yksilöllisiin mittareihin perustuva segmentointi on erityisen tärkeää pankkisektorilla, jossa asiakassuhteet ovat pitkäaikaisia ja asiakkaiden arvonmuodostus monisyistä. (Estrella-Ramón ym., 2017)

Pankkialalla on myös huomioitava asiakaspalvelun kaksiuolotteisuus: high-touch ja high-tech -palvelut. High-touch -palvelut tarkoittavat henkilökohtaisia kontakteja ja asiakaspalvelijan osaamista, kun taas high-tech -palvelut nojaavat automaatioon ja digitaalisuuteen, kuten verkkopankkiin tai mobiilipalveluihin. Nämä ulottuvuudet eivät ole toisiaan poissulkevia, vaan molemmat on integroitava asiakaslähtöisesti palveluprosessiin. (Aliyu & Tasmin, 2012)

Verkkopankkipalveluiden kehittyessä myös asiakaspalvelun merkitys siirtyy yhä enemmän digitaalisiin kanaviin. Tutkimukset korostavat, että verkkosivuston suunnittelu ja käytettävyys sekä palvelun luotettavuus ovat ratkaisevia tekijöitä asiakastyytyväisyyden ja verkkopalvelujen käyttöönoton kannalta. Tässä kontekstissa brändikuvan merkitys nousee myös esiin: verkkopalveluiden kautta välittyvä laatu rakentaa pankin imagoa ja vaikuttaa asiakkaiden luottamukseen ja päätöksiin. (Rahi ym., 2020)

Pankkisektorilla asiakaspalvelu ja asiakkuuksienhallinta muodostavat strategisen ytimen, jossa korostuvat asiakastiedon hyödyntäminen, pitkäaikaisten suhteiden hallinta, palvelun laadun mittaaminen ja kanavien integraatio. CRM:n onnistuminen vaatii teknologisten, organisatoristen ja viestinnällisten osa-alueiden yhtenäistä ja asiakaslähtöistä toteutusta. (Laketa ym., 2015) Tämä korostaa, ettei kyse ole vain järjestelmistä tai kohtaamisista, vaan syvällisestä kyvystä ymmärtää asiakasta ja luoda lisäarvoa pitkäjänteisesti.

2.3.2 Maksut ja sitoumukset

Maksupalvelut ja sitoumusten hallinta ovat keskeisessä asemassa pankkisektorilla, muodostaen perustan päivittäiselle rahaliikenteelle ja kaupankäynnille. Sähköisten maksujen ja digitalisaation myötä maksujärjestelmien tehokkuus, turvallisuus ja nopeus ovat nousseet yhä tärkeämmiksi. Hazar ja Babuşcu (2023) huomauttavat, että fintech-yritysten kasvu ja digitaalisten teknologioiden, kuten tekoälyn ja koneoppimisen hyödyntäminen, ovat merkittävästi muuttaneet maksamisen ekosysteemiä. He korostavat erityisesti mobiilimaksamisen yleistymistä, mikä on vähentänyt pankkikonttorien roolia ja tuonut maksupalvelut lähemmäksi kuluttajien arkea. (Babuşcu & Hazar, 2023) Tämä muutos on ollut mahdollista osittain siksi, että PSD2-direktiivi velvoittaa pankkeja avaamaan asiakkaiden tietoja kolmansien osapuolten käytettäväksi rajapintojen (API) kautta, mikä on lisännyt kilpailua ja innovaatioita, mutta samalla tuonut mukanaan uusia turvallisuusriskejä. (Gounari ym., 2024)

Brandl & Dieterich (2023) huomioivat kuitenkin, että globaaleissa maksujärjestelmissä edelleen korostuu suurten pankkien hallitseva asema infrastruktuurin tarjoajina, vaikka teknologia-alan yritykset ovatkin alkaneet haastaa tätä asemaa. Perritt (1996) esittää, että sähköisten maksujärjestelmien

infrastruktuurin sääntely ja teknologinen kehitys ovat luoneet uudenlaisia vaatimuksia turvallisuudelle ja yhteentoimivuudelle, mikä on lisännyt tarvetta selkeille oikeudellisille ja teknologisille puitteille maksupalveluiden toteuttamisessa.

Maksupalveluiden ja sitoumusten hallinnan kehityksessä pankkisektorin digitalisaatio, sääntelyympäristön muutokset kuten PSD2, sekä fintech-toimijoiden mukaantulo ovat merkittävästi vaikuttaneet sekä maksamisen tapoihin että riskienhallintaan. Näiden muutosten seurauksena asiakkaiden odotukset maksupalveluiden nopeudesta, helppokäyttöisyydestä ja turvallisuudesta ovat kasvaneet huomattavasti. (Hedman & Henningson, 2012)

2.3.3 *Lainaaminen, sijoittaminen ja varainhallinta*

Pankkien keskeisinä tehtävinä pidetään usein luotonantoa, sijoitustoimintaa ja varainhallintaa. Nämä toiminnot muodostavat rahoituslaitosten ydinpalvelut ja ne erottavat pankkitoiminnan monella tapaa muista liiketoiminta-aloista. Lainaamisen ytimessä on säästöjen välitys investointikohteiksi, jolloin pankit yhdistävät taloudellisia ylijäämäyksiköitä ja alijäämäyksiköitä (Allen & Santomero, 1999). Luotonanto ei ainoastaan rahoita yksityistä kulutusta ja yritystoimintaa, vaan toimii myös rahapolitiikan välittymismekanismina, mikä korostaa pankkien roolia makrotaloudessa (Greenwood & Scharfstein, 2013).

Sijoitustoiminnassa pankit toimivat joko omalla taseellaan tai asiakkaiden varoja hallinnoiden. Pankkien sijoitustoimintaan liittyy erityisiä vakavaraisuus- ja likviditeettisääntelyjä, jotka erottavat ne selvästi muista rahoitusmarkkinoiden toimijoista, kuten hedge-rahastoista (Walter, 1999). Esimerkiksi pankkien omaisuuden hallinnassa käytettävät varainhoitotuotteet, kuten erilaiset korkoinstrumentit ja yhdistelmärahastot tarjoavat asiakkaille pääoman suojaa, mutta samalla ne vaativat pankilta korkeaa riskienhallintaosaamista ja sääntelymukaisuutta (Wang ym., 2022).

Varainhallinta on noussut entistä tärkeämmäksi segmentiksi pankkien liiketoiminnassa, erityisesti vauraiden yksityisasiakkaiden ja instituutioiden palvelualueena. Varainhallinta yhdistää sijoitustuotteiden tarjoamisen, verosuunnittelun ja perinnönsuunnittelun kaltaiset palvelut kokonaisvaltaiseksi asiakasstrategiaksi (Maude, 2010). Tämä liiketoiminta poikkeaa selkeästi muista toimialoista siinä, että se vaatii erittäin henkilökohtaista asiakassuhdetta ja luottamusta, joita tukevat pankkien pitkä historia ja sääntelyvalvonta (Drigă ym., 2009).

Toisin kuin monilla muilla aloilla, pankkien tarjoamat palvelut kytkeytyvät suoraan koko talousjärjestelmän vakauteen. Esimerkiksi varainhallintatuotteet voivat alentaa pankin varainhankinnan kustannuksia ja siten edistää edullisempaa luotonantoa (Wang ym., 2022). Tämänkaltaisia kerrannaisvaikutuksia ei synny vaikkapa vähittäiskaupan tai teollisuuden alalla, mikä tekee pankkitoiminnasta erityislaatuisen yhteiskunnallisen instituution.

2.3.4 Riskienhallinta ja sääntely

Riskienhallinta ja sääntelyn noudattaminen (engl. compliance) ovat pankkitoiminnan kulmakiviä, joilla pyritään varmistamaan järjestelmän vakaus, luotettavuus ja pitkäjänteinen toiminta. Toisin kuin monilla muilla toimialoilla, pankkien liiketoimintamalli altistuu ainutlaatuisille riskeille, kuten luottoriskille, likviditeettiriskille ja järjestelmäriskille joiden hallinta edellyttää tiukkaa sääntelykehystä ja hallintajärjestelmiä. (Bessis, 2011)

Pankkien riskienhallinta eroaa muista toimialoista siinä, että se on sekä sisäisen hallinnan että ulkoisen sääntelyn ohjaamaa. Kansainväliset standardit, kuten Basel III -säännöstö määrittävät pääoma-vaatimukset ja stressitestausten menettelyt, joiden avulla pankkien on osoitettava kestävyytensä taloudellisissa häiriötilanteissa. (Doshi, 2023) Lisäksi sääntelyyn liittyvä compliance-toiminta on pankkialalla erityisen laajaa ja sisältää jatkuvaa raportointia, asiakkaan tuntemisvelvollisuuksia (engl. Know Your Customer, KYC), sekä rahanpesun ja terrorismin rahoituksen estämistä koskevia vaatimuksia (Oeni ym., 2021).

Toisin kuin esimerkiksi valmistavassa teollisuudessa tai teknologiasektorilla, pankkien sääntely ei rajoitu vain turvallisuusstandardeihin tai kilpailuoikeudellisiin kysymyksiin, vaan ulottuu syvälle operatiiviseen toimintaan ja asiakassuhteisiin. Tämä tekee pankkien compliance-järjestelmistä merkittävästi moniulotteisempia ja riskiperusteisempia kuin monilla muilla toimialoilla. (Svatá & Fleischmann, 2011)

Strateginen riskienhallinta pankkisektorilla ei tarkoita pelkästään sääntöjen noudattamista, vaan riskien ennakoimista ja hallittua hyväksymistä liiketoiminnan kehittämiseksi. Esimerkiksi teknologisten riskien, kuten kyberturvallisuuden huomioiminen on nykyisin kriittistä ja pankit investoivat kehittyneisiin seurantajärjestelmiin ja tekoälypohjaisiin valvontaratkaisuihin. (Adeniran ym., 2024) Compliance-toiminta onkin siirtynyt reaktiivisesta toiminnasta kohti proaktiivista riskienhallintaa, jossa pyritään estämään rikkomukset ennalta eikä vain raportoimaan niitä jälkikäteen (Dill, 2019).

Yhteiskunnallisen roolinsa vuoksi pankkien on toimittava korkeiden läpinäkyvyyden ja vastuullisuuden vaatimusten mukaisesti. Tästä syystä niiden riskienhallintarakenteet ovat myös laajemmin vaikuttavia esimerkkejä muille kriittisille toimialoille. (Terblanché, 2013)

2.3.5 Operatiivinen toiminta

Pankkien operatiivinen toiminta muodostaa perustan niiden kyvyille tarjota luotettavia ja tehokkaita rahoituspalveluita yksityishenkilöille, yrityksille ja yhteiskunnalle laajemmin. Tähän sisältyvät mm. asiakastilien hallinta, maksuliikenteen käsittely, luottoprosessit, sijoitustuotteiden hallinta, varainhankinta, sisäinen valvonta sekä tukitoiminnot, kuten henkilöstöhallinto ja kirjanpito. (Berger & Udell, 2002; Llewellyn, 1999)

Ydintoiminnot ovat tyypillisesti jaoteltu vähittäis-, yritys- ja investointipankkitoimintaan. Jokaisella osa-alueella on oma operatiivinen kokonaisuutensa, johon kuuluvat asiakaspalveluprosessit, luotonannon hallintajärjestelmät, riskien arviointi ja asiakirjakäsittely. Esimerkiksi vähittäispankkitoiminnassa arjen operatiivisiin tehtäviin kuuluu mm. tilien avaaminen, maksukorttien hallinta ja asiakaskontaktien hoito. Yrityspuolella korostuvat projektirahoitus, yritysluottojen käsittely sekä kassanhallintapalvelut. (Lamarque, 2000)

Pankkien organisaatorakenne tukee tätä toimintaa yleensä funktionaalisesti: eri yksiköt (luotonanto, compliance, asiakaspalvelu, IT, riskienhallinta) toimivat tiiviissä vuorovaikutuksessa selkeästi määritellyin vastuineen. Lisäksi pankkien operatiivinen ympäristö on erittäin säädelty, mikä edellyttää jatkuvaa raportointia ja tarkkaa sisäistä kontrollia. (Bessis, 2011)

Pankkitoiminta eroaa operatiivisesti monista muista toimialoista erityisesti toiminnan katkeamattomuuden vaatimusten vuoksi. Esimerkiksi kriittiset järjestelmät on varmistettava 24/7-toimintakykyisiksi, sillä maksuliikenteen, pörssitoiminnan tai korttien käytön keskeytyminen vaikuttaa laajalti muihin toimijoihin ja kansalaisiin (Biresaw & Sibindi, 2025). Tämä poikkeaa esim. teollisuusyrityksistä, joissa lyhyet tuotantokatkot ovat helpommin hallittavissa eivätkä samalla tavalla vaikuta koko talousjärjestelmään.

Pankkien operatiivinen tehokkuus ei perustu yksinomaan teknologiaan, vaan myös henkilöstön osaamiseen, prosessien standardointiin, sääntelyn noudattamiseen ja asiakasluottamuksen ylläpitämiseen. Näiden yhdistelmä muodostaa rakenteellisen perustan koko pankkijärjestelmän vakaudelle ja luotettavuudelle. (Bessis, 2011; Llewellyn, 1999)

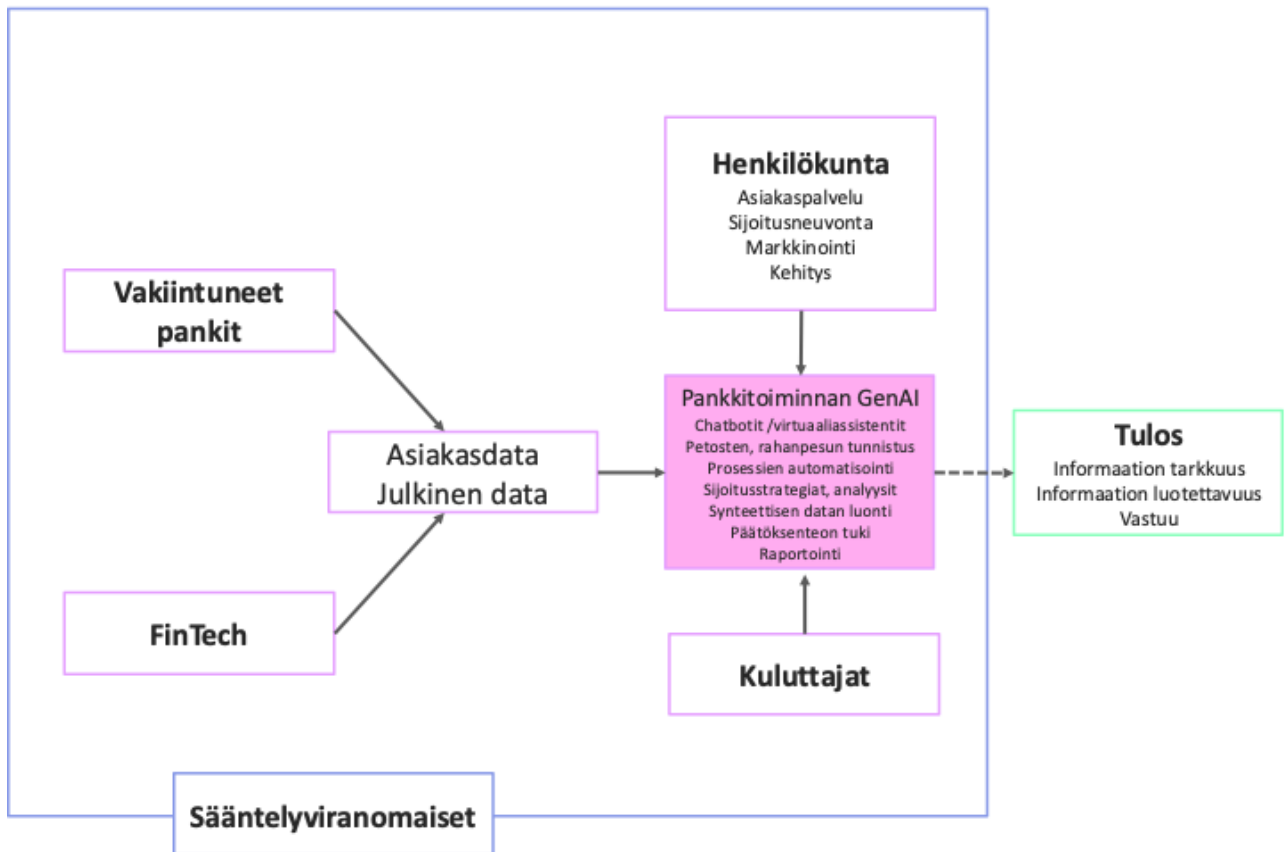
2.4 Generatiivisen tekoälyn erityispiirteet pankkisektorilla

Generatiivinen tekoäly on nopeasti muokkaamassa pankkisektoria ja sen käyttöönottoon liittyy monia erityispiirteitä. Sen merkittävimmät vaikutukset pankkitoiminnassa voivat liittyä asiakaskokemukseen, riskienhallintaan, vaatimustenmukaisuuteen sekä operatiiviseen tehokkuuteen. Generatiivisen tekoälyn avulla pankit voivat automatisoida asiakasvuorovaikutuksia, optimoida päätöksentekoprosesseja ja kehittää innovatiivisia palveluja. Esimerkiksi Kaya (2019) osoittaa, että tekoälyllä voidaan tehostaa luotonantoprosesseja ja parantaa petostentorjuntaa, mutta samalla sen käyttö tuo esiin merkittäviä sääntelyhaasteita, jotka voivat vaikuttaa pankkien toiminnan vakauteen ja läpinäkyvyyteen. (Mucsková, 2024).

Yksi merkittävimmistä haasteista on tietosuoja ja kyberturvallisuus, jotka ovat keskeisiä huolenaiheita tekoälypohjaisten pankkipalveluiden kohdalla. Han ja Yang (2018) osoittavat, että tekoälyjärjestelmien laajamittainen käyttöönotto voi lisätä tietojen väärinkäytön ja hakkeroinnin riskiä. Esimerkiksi pankkien tekoälypohjaiset asiakaspalveluratkaisut ja analytiikkatyökalut voivat kerätä asiakkaiden tietoja ilman heidän tietämystään, mikä herättää kysymyksiä läpinäkyvyydestä ja suostumuksesta. (Rahman ym., 2023). Myös luottamus tekoälyyn voi olla yksi merkittävimmistä tekijöistä sen

laajamittaisessa käyttöönotossa pankkialalla. Belanche ym. (2019) osoittavat, että vaikka pankit ovat kiinnostuneita FinTech-ratkaisuista, asiakkaat eivät välttämättä ole valmiita siirtymään täysin tekoälypohjaisiin palveluihin. Asiakkaiden hyväksyntä edellyttää teknologian luotettavuutta ja ennustettavuutta. Tämä asettaa sääntelyviranomaisille haasteen, sillä niiden on tasapainotettava innovaatiota tukevan sääntely-ympäristön ja kuluttajansuojan välillä. (Jo Bitner, 2001; Rahman ym., 2023).

Sääntelyn näkökulmasta generatiivisen tekoälyn käyttöönotto pankkisektorilla edellyttää tasapainoa innovaation edistämisen ja riskienhallinnan välillä. Tekoälyn sääntelyyn finanssialalla tarvitaan ennakoiva lähestymistapa, joka estää yliregulaation ja samalla varmistaa järjestelmien eettisyyden ja vastuullisuuden. (Mucsková, 2024; Truby ym., 2020). Näiden seikkojen vuoksi sääntelyviranomaisen on kehitettävä selkeitä linjauksia tekoälyn käytöstä pankkisektorilla. Tekoälyyn liittyvän sääntelyn on katettava muun muassa tietosuojavaatimukset, riskienhallintaprotokollat ja päätöksenteon läpinäkyvyyden varmistaminen, jotta voidaan ylläpitää sekä rahoitusjärjestelmän vakautta että kuluttajien luottamusta digitaalisiin pankkipalveluihin. (Rahman ym., 2023).



Kuvio 4 Käsitteellinen kehys generatiiviselle tekoälylle pankkialalla (mukaillen (Ooi ym., 2025))

3 TUTKIMUSMENETELMÄ

Joka vuosi julkaistaan lukuisia tutkimuksia generatiivisen tekoälyn soveltamisesta eri toimialoilla, mukaan lukien pankkisektori. Vuoden 2023 jälkeen tutkimusta on tullut nopealla tahdilla, mikä tekee ajankohtaisen tiedon seuraamisesta haastavaa. Kuten on jo esitelty, pankkisektorilla generatiivinen tekoäly voi tarjota merkittäviä mahdollisuuksia esimerkiksi asiakaspalvelun, riskienhallinnan ja sääntelyvaatimusten noudattamisen tehostamisessa, mutta aiemman tutkimuksen hajanaisuus vaikeuttaa kokonaiskuvan muodostamista. Tästä syystä tämän tutkimuksen tavoitteena on toteuttaa systemaattinen kirjallisuuskatsaus, joka kokoaa yhteen olemassa olevan tiedon ja tunnistaa keskeiset suuntaukset, mahdollisuudet ja haasteet. Systemaattiset kirjallisuuskatsaukset eroavat perinteisistä kirjallisuuskatsauksista siinä, että ne pyrkivät tunnistamaan kaikki aiheeseen liittyvät tutkimukset järjestelmällisesti ja minimoimaan valinta-, julkaisu- ja tiedonkeruuvirheet. Tässä tutkimuksessa noudatetaan PRISMA-ohjeistoa, joka auttaa varmistamaan kirjallisuuskatsauksen kattavuuden ja luotettavuuden.

3.1 Systemaattinen kirjallisuuskatsaus metodologiana

Systemaattinen kirjallisuuskatsaus (engl. Systematic Literature Review, SLR) on tieteellinen, toistettava ja läpinäkyvä menetelmä, jonka avulla voidaan koota ja arvioida olemassa olevaa tutkimustietoa valitusta aiheesta (Tranfield ym., 2003). Tämä lähestymistapa on saanut kasvavaa suosiota erityisesti nopeasti kehittyvillä aloilla, kuten generatiivisen tekoälyn ja pankkisektorin tutkimuksessa, sillä se tarjoaa kattavan ja puolueettoman yhteenvedon aiemmasta tutkimuksesta, auttaa tunnistamaan tutkimusaukkoja ja suuntaamaan tulevaa tutkimusta (Moher ym., 2008; Paul & Criado, 2020).

Järjestelmällinen kartoitus tarjoaa jäsenneilyn kehyksen generatiivisen tekoälyn nopeasti kehittyvän alan olemassa olevan tutkimuksen perusteelliselle arvioinnille, trendien tunnistamiselle ja mahdollisten puutteiden havaitsemiselle. Siinä keskitytään pikemminkin aiheen laajuuteen kuin sen syvyyteen, mikä on ratkaisevan tärkeää kehittyvillä ja nopeatempoisilla aloilla. Tämä prosessi auttaa luomaan selkeät määritelmät ja rajat alalle, vähentämään monitulkintaisuutta ja edistämään johdonmukaista keskustelua. (García-Peñalvo & Vázquez-Ingelmo, 2023).

Prosessi rakentuu yksinkertaistettuna kolmesta keskeisestä vaiheesta: suunnittelusta, toteutuksesta ja tulosten raportoinnista. Systemaattinen kirjallisuuskatsaus perustuu tarkasti määriteltyyn tutkimusprosessiin, jossa haetaan, järjestetään ja analysoidaan olemassa olevaa kirjallisuutta. Tämä varmistaa tutkimusprosessin toistettavuuden ja vähentää valikoitumiseen, julkaisuihin ja tiedonkeruuseen liittyviä virheitä. (Jebarajakirthy ym., 2021). Systemaattinen kirjallisuuskatsaus voi keskittyä eri näkökulmiin, kuten teoriaan, metodologiaan tai tiettyyn sovellusalueeseen (Palmatier ym., 2018; Paul & Barari, 2022).

Osana systemaattista kirjallisuuskatsausta mukaan otettiin myös niin sanottua harmaata kirjallisuutta (engl. grey literature), kuten alan raportteja, konsulttiyhtiöiden katsauksia ja viranomaistahojen

julkaisuja. Harmaan kirjallisuuden huomioiminen on perusteltua erityisesti nopeasti kehittyvillä ja uudehkoilla tutkimusalueilla, joissa tieteellinen kirjallisuus ei kata vielä kaikkia ilmiön osa-alueita (Paez, 2017). Useat systemaattisen kirjallisuuskatsauksen ohjeistukset korostavat harmaan kirjallisuuden tuovan lisäarvoa tutkimukseen, koska näin voidaan tunnistaa tuoreita ilmiöitä, käytännön kokemuksia ja ajankohtaisia kehityssuuntia, joita vertaisarvioidussa tutkimuksessa ei vielä ole kattavasti käsitelty (Adams et ym., 2017; Paez, 2017). Harmaan kirjallisuuden mukaan ottamisella pyrittiin varmistamaan, että tutkimuksessa huomioidaan mahdollisimman laaja-alaisesti generatiivisen tekoälyn kehitykseen ja sovelluksiin liittyvät näkökulmat pankkisektorilla.

3.2 PRISMA-ohjeisto ja sen soveltaminen

Tutkimukseen sovelletaan systemaattisen kirjallisuuskatsauksen menetelmää PRISMA-ohjeistuksen (engl. Preferred Reporting Items for Systematic Reviews and Meta-Analyses) mukaisesti. PRISMA tarjoaa standardoidun lähestymistavan systemaattisten katsausten toteuttamiseen ja raportointiin, mikä varmistaa tutkimusprosessin läpinäkyvyyden, kattavuuden ja toistettavuuden. PRISMA-ohjeiston päätavoitteena on edistää systemaattisten katsausten selkeää ja kattavaa raportointia hyödyntämällä tutkittuun tietoon perustuvaa vähimmäissuosituksen joukkoa. (Sarkis-Onofre ym., 2021)

Page ym. (2021) määrittelee PRISMA 2020 -ohjeiston järjestelmällisen katsauksen raportointiin tarkoitettuksi viitekehykseksi, joka on ensisijaisesti kehitetty terveysalan interventiodien arviointiin, mutta soveltuu myös muiden alojen tutkimuskatsauksiin. PRISMA soveltuu erilaisten katsaustyyppien raportointiin riippumatta siitä, käytetäänkö synteesimenetelmiä ja se kattaa niin alkuperäiset kuin päivitettävät tai jatkuvat systemaattiset katsaukset. Ohjeistus ei arvioi tutkimusten metodologista laatua, vaan sen ensisijainen tarkoitus on varmistaa raportoinnin kattavuus. PRISMA 2020 -tarkistuslista kattaa keskeiset raportoinnin osa-alueet, kuten otsikon, tiivistelmän, johdannon, menetelmät, tulokset ja keskustelun.

3.3 Aineistonkeruu

Systemaattisen kirjallisuuskatsauksen aineistonkeruu edellyttää tarkkaan määriteltyä ja läpinäkyvää hakuprosessia, jotta tutkimukseen sisällytetään kaikki relevantti ja laadukas kirjallisuus. PRISMA 2020 -ohjeisto korostaa aineistonkeruun raportoinnin tärkeyttä ja antaa suosituksia siitä, kuinka hakuprosessi tulee dokumentoida. Aineistonkeruu sisältää useita vaiheita, kuten tietokantojen valinnan, hakustrategian suunnittelun, hakutermien määrittelyn sekä sisällyttämis- ja poissulkukriteerien asettamisen. (Page ym., 2021). Ohjeiston mukaan tutkimuksissa tulisi raportoida käytetty hakustrategia

kokonaisuudessaan, mukaan lukien kaikki hakutermit, suodattimet ja rajoitukset, jotta tutkimusprosessi on mahdollisimman toistettava ja avoin (Sarkis-Onofre ym., 2021).

3.3.1 *Hakustrategia ja tietokannat*

Systemaattista kirjallisuuskatsausta varten tutkimuksessa käytettiin viittä eri tieteellistä tietokantaa: UTU Volter, Google Scholar, Scopus, Web of Science ja IEEE Xplore. Näiden lisäksi hakua täydennettiin harmaalla kirjallisuudella, kuten tunnettujen konsulttiyritysten raporteilla ja kansainvälisten organisaatioiden julkaisuilla. Tavoitteena on varmistaa, että tutkimuskysymyksiin löydetään mahdollisimman kattava ja laadukas aineisto.

UTU Volter -kirjastotietokantaa käytettiin sekä englannin- että suomenkielisten julkaisujen löytämiseen. Tämä tarjoaa mahdollisuuden huomioida myös kansalliset näkökulmat generatiivisen tekoälyn käyttöönottoon pankkisektorilla. Hakutermit on rakennettu huolellisesti kattamaan sekä teknologiset että pankkisektorikohtaiset termit. Englanninkielinen hakutermi haettaessa UTU Volterista oli ("generative AI" OR "GPT models" OR "large language models") AND ("banking sector" OR "financial services") AND ("applications" OR "opportunities"). Suomenkieliset hakutermit varmistavat, että myös kotimainen aineisto tulee huomioitua.

Google Scholar on hyödyllinen työkalu yleiskatsauksen muodostamisessa. Sen hakukone tukee vain rajoitettua boolean-logiikkaa, minkä vuoksi hakutermit on yksinkertaistettava. Scholarissa käytettiin hakulauseketta "Generative AI in banking" OR "large language models in financial services". Scholarin laaja kattavuus mahdollistaa tutkimusaiheeseen liittyvien artikkeleiden löytämisen eri tieteenaloilta, vaikka hakujen tarkkuus onkin laveampi verrattuna muihin tietokantoihin. Volterin tavoin myös Scholarista haettiin aineistoa myös Suomen kielellä. Lopuissa tietokannoista käytetään hakuihin pelkästään Englantia.

Scopus tarjoaa mahdollisuuden kohdentaa hakuja tarkasti esimerkiksi tiivistelmiin ja otsikoihin, mikä auttaa löytämään relevanttia aineistoa. Scopusissa hyödynnettiin edistyneitä boolean-hakuja, kuten "TITLE-ABS-KEY ((“generative AI” OR “large language models”) AND (“banking” OR “financial services”) AND (“applications” OR “opportunities”))". Tämä lähestymistapa rajasi hakutulokset artikkeleihin, jotka käsittelevät generatiivisen tekoälyn mahdollisuuksia nimenomaan pankkisektorilla. Scopusin avulla voidaan myös analysoida tutkimusten avainsanoja ja tiivistelmiä tarkasti.

Web of Science -tietokannassa käytettiin monipuolista hakulauseketta, joka hyödyntävää myöskin boolean-logiikkaa ja kattaa paljon synonyymejä. Hakulauseke TS=("generative AI" AND "banking") OR TS=("large language models" AND "banking") OR TS=("GPT models" AND "banking") OR TS=("transformer models" AND "financial services") OR TS=("artificial intelligence" AND "banking sector") OR TS=("AI" AND "finance industry") OR TS=("generative AI" AND "financial services") OR TS=("large language models" AND "finance") AND LA=("English") AND DT=("Arti-

cle" OR "Review" OR "Proceedings Paper" OR "Data Paper" OR "Abstract of Published Item") mahdollistaa pankkisektoriin liittyvän aineiston löytymisen eri näkökulmista. Web of Science tarjoaa myös tehokkaat työkalut hakutulosten lajitteluun ja analysointiin.

IEEE Xplore on erityisen hyödyllinen teknologisiin ja tieteellisiin artikkeleihin keskittyvässä tutkimuksessa ja onkin käytetyistä tietokannoista eniten teknologiaorientoitunut. IEEE Xplore korostaa teknologian näkökulmaa, mikä on keskeistä tutkimuskysymyksissä. Generatiivisen tekoälyn sovelluksia käsittelevien artikkeleiden löytämiseksi käytetään esimerkiksi hakulauseketta "Full Text & Metadata: "generative AI" AND "banking" OR "large language models" AND "financial services"".

Harmaan kirjallisuuden osalta hyödynnettiin raportteja tunnetuilta konsulttiyrityksiltä, kuten McKinseyltä, Deloittelta ja Accenturelta, sekä kansainvälisten organisaatioiden, kuten OECD:n ja World Economic Forumin, julkaisuja. Näiden lisäksi tarkastellaan teknologia- ja finanssijulkaisuja, kuten *Financial Timesia*, *MIT Technology Review'ta* ja *Suomen Pankin* julkaisuja. Näistä lähteistä saadaan täydentävää näkökulmaa ja ajankohtaista tietoa generatiivisen tekoälyn sovelluksista pankkisektorilla.

Taulukko 2 Hakutermit

Tietokanta	Hakutermi tai hakutermien syntaksi
<i>Utu Volter</i>	("generative AI" OR "GPT models" OR "large language models") AND ("banking sector" OR "financial services") AND ("applications" OR "opportunities")
<i>Google Scholar</i>	("generatiivinen tekoäly" OR "kielimallit") AND ("pankeissa" OR "pankit" OR "pankkisektori" OR "rahoituspalvelut" OR "finanssisektori") AND ("käyttökohteet" OR "mahdollisuudet" OR "ongelmat") "Generative AI in banking" OR "large language models in financial services"
<i>Scopus</i>	"Generatiivinen tekoäly" OR "Gen AI" AND "pankki" OR "pankkisektori" TITLE-ABS-KEY (("generative AI" OR "large language models" OR "transformer models" OR "GPT models") AND ("banking" OR "financial services" OR ") AND ("applications" OR "opportunities"))
<i>Web of Science</i>	TS=("generative AI" AND "banking") OR TS=("large language models" AND "banking") OR TS=("GPT models" AND "banking") OR TS=("transformer models" AND "financial services") OR TS=("artificial intelligence" AND "banking sector") OR TS=("AI" AND "finance industry") OR TS=("generative AI" AND "financial services") OR TS=("large language models" AND "finance") AND LA=("English") AND DT=("Article" OR "Review" OR "Proceedings Paper" OR "Data Paper" OR "Abstract of Published Item")
<i>IEEE Xplore</i>	("Full Text & Metadata": "generative AI" AND "banking" OR "large language models" AND "banking" OR "GPT models" AND "banking" OR "transformer models" AND "financial services" OR "artificial intelligence" AND "banking sector" OR "AI" AND "finance industry" OR "generative AI" AND "financial services" OR "large language models" AND "finance")

3.3.2 Sisällyttämis- ja poissulkukriteerit

Tässä kappaleessa määritellään katsauksen sisällyttämis- ja poissulkukriteerit, joita noudattamalla on varmistettu tutkimuksen relevanssi ja luotettavuus. Sisällyttämiskriteereiksi on asetettu, että mukaan otettavat tutkimukset käsittelevät generatiivisen tekoälyn käyttöä tai mahdollisuuksia pankkisektorilla. Tarkasteltavat aiheet voivat liittyä esimerkiksi riskienhallintaan, asiakaspalveluun tai algoritmiin kaupankäyntiin, mutta keskiössä tulee olla generatiivisen tekoälyn soveltaminen näillä osa-alueilla. Aineistoon hyväksytään vain tieteelliset julkaisut tai tunnetuista ja uskottavista lähteistä peräisin oleva harmaa kirjallisuus. Lisäksi tutkimusten tulee olla julkaistu aikaisintaan tammikuussa 2023 ja

olla joko suomen- tai englanninkielisiä, jotta ne ovat ajankohtaisia ja ymmärrettäviä tutkimuskontekstin kannalta.

Poissulkukriteerit määrittävät, mitkä tutkimukset jätetään tarkastelun ulkopuolelle. Ensisijaisesti pois suljetaan tutkimukset, jotka eivät käsittele generatiivista tekoälyä tai pankkisektoria, eivätkä näin ollen vastaa tutkimuskysymyksiin. Myös tutkimukset, jotka käsittelevät ainoastaan perinteistä tekoälyä ilman generatiivisen tekoälyn näkökulmaa, suljetaan pois. Lisäksi mielipidekirjoitukset, epäluotettavat lähteet ja julkaisut, jotka eivät ole uskottavia tai joilla ei ole tunnistettavissa olevaa tieteellistä perustaa, jätetään aineiston ulkopuolelle. Duplikaatit poistetaan analyysistä ja kaikki muut kuin englannin- tai suomenkieliset tutkimukset rajataan pois, jotta varmistetaan aineiston kieliasun yhdenmukaisuus ja tutkimuksen helppo tulkittavuus.

Taulukko 3 kelpoisuuskriteerit

<i>Sisällyttämiskriteerit</i>	<i>Poissulkukriteerit</i>
#1 Julkaisupäivä aikaisintaan tammikuussa 2023	#1 Julkaistu ennen tammikuuta 2023
#2 Aiheena generatiivinen tekoäly ja pankkisektori	#2 Aiheena vain perinteinen tekoäly, eikä generatiivinen tekoäly
#3 Akateeminen dokumentti tai uskottavan lähteen harmaa kirjallisuus	#3 Mielipidekirjoitukset ja muut epäluotettavat lähteet
#4 Kielenä Englanti tai Suomi	#4 Duplikaatit
	#5 Kielenä muu kuin Englanti tai Suomi

3.3.3 *Aineiston rajaaminen ja PRISMA-virtauskaavio*

Tutkimuksen aineistonkeruu perustui systemaattiseen hakuprosessiin, jonka tavoitteena oli varmistaa kattava ja laadukas pohja generatiivisen tekoälyn sovellusten tarkastelulle pankkisektorilla. Tämän vuoksi aineiston haku toteutettiin useista eri tietokannoista ja täydentävistä lähteistä, jotta tutkimukseen saatiin mahdollisimman monipuolinen ja ajankohtainen näkökulma. Systemaattinen haku varmistaa, että tutkimukseen sisältyvät artikkelit ovat vertaisarvioituja tai muuten luotettavia sekä vastaavat ennalta asetettuihin sisällyttämiskriteereihin.

Hakuprosessissa hyödynnettiin viittä merkittävää tietokantaa: IEEE Xplore, Google Scholar, Scopus, Web of Science ja UTU Volter. Nämä tietokannat valittiin niiden laajan kattavuuden ja relevanssin perusteella, sillä ne sisältävät runsaasti tekoälyn ja pankkisektorin tutkimukseen liittyviä julkaisuja. Hakustrategia muodostettiin käyttämällä sekä laajoja että tarkennettuja hakutermejä, jotta aineistosta voitiin löytää sekä yleisiä katsauksia että spesifimpiä tutkimuksia. Lisäksi tutkimukseen sisällytettiin harmaan kirjallisuuden lähteitä, kuten McKinsey, Deloitte, Accenture ja Suomen Pankki,

joiden raportit tarjoavat ajankohtaista ja käytännönläheistä tietoa generatiivisen tekoälyn sovelluksista finanssialalla.

Hakutulosten määrä vaihteli tietokannoittain. IEEE Xplore -hausta löytyi yhteensä 345. Google Scholarista haettiin yhteensä 209 tulosta, joista 57 artikkelia oli suomenkielisiä. Scopus-haun tuloksena saatiin 19 artikkelia, kun taas Web of Science tuotti yhteensä 242 tulosta. UTU Volter -hausta löydettiin 41 dokumenttia englanniksi, mutta suomenkielisiä julkaisuja ei ollut saatavilla. Lisäksi harmaan kirjallisuuden osalta valittiin 10 raporttia, jotka tarjosivat käytännön näkökulmaa generatiivisen tekoälyn roolista pankkisektorilla.

Hakujen perusteella löydetystä artikkeleista valittiin tutkimukseen sisällytettävä aineisto systemaattisesti PRISMA-protokollan mukaisesti. Aineiston valintaprosessi eteni seuraavien seulontavaiheiden kautta: laaja haku ja duplikaattien poistaminen, otsikkojen ja tiivistelmien tarkastelu sekä koko tekstin perusteella tehtävä arviointi. Näiden vaiheiden tarkoituksena oli varmistaa, että tutkimukseen sisällytettiin vain relevantit ja laadukkaat julkaisut, jotka vastasivat tutkimuskysymyksiin.

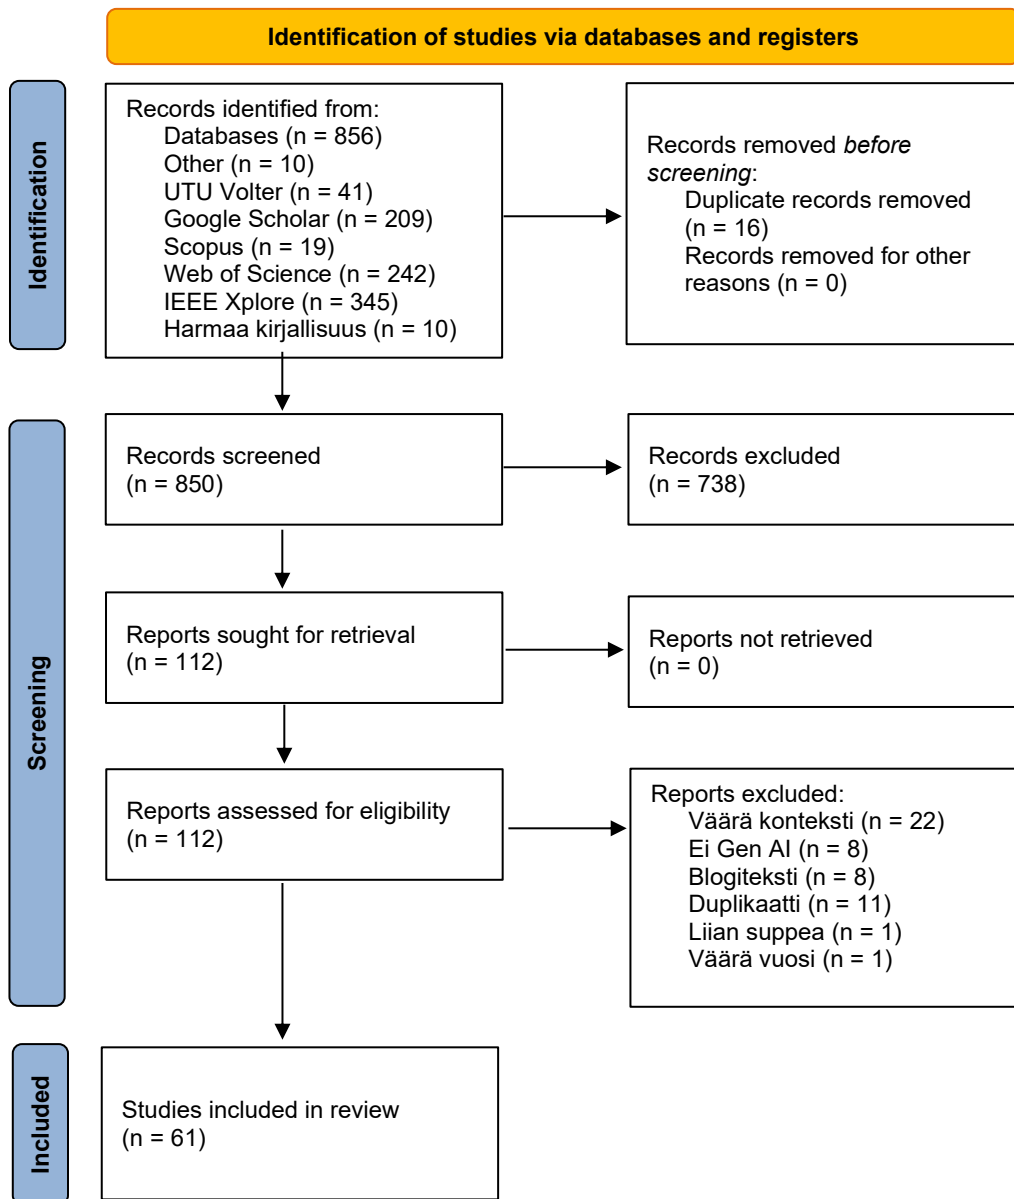
Kaiken kaikkiaan alkuperäisten hakujen tuloksena löydettiin 866 dokumenttia. Jäljelle jääneestä aineistosta poistettiin 16 duplikaattia, mikä pienensi seulottavien artikkelien määrän 850 dokumenttiin. Koska hakujen aikana samoja artikkeleita esiintyi useammassa tietokannassa, ne karsittiin Excelin avulla, jota käytettiin artikkelien hallintaan. Duplikaattien poistamisen jälkeen siirryttiin seuraavaan vaiheeseen.

Toisessa vaiheessa tarkasteltiin jäljelle jääneiden artikkelien otsikot ja tiivistelmät, painottaen otsikkotason filterointia. Tässä vaiheessa sovellettiin aiemmin määriteltyjä sisällyttämiskriteereitä, kuten generatiiviseen tekoälyyn keskittyminen, pankkisektorin konteksti sekä julkaisujen ajankohtaisuus ja vertaisarviointi. Poissulkukriteereinä toimivat muun muassa tutkimukset, jotka käsittelevät tekoälyä yleisellä tasolla ilman pankkisektorikohtaista näkökulmaa tai jotka eivät tarjonneet konkreettisia käyttökohteita tai mahdollisuuksia. Näin seulottiin pois artikkelit, jotka eivät vastanneet tutkimuksen keskeisiä tavoitteita. Tässä vaiheessa hyödynnettiin avainsanahakua ("banking" ja "generative AI"), minkä perusteella aineistosta poistettiin 738 artikkelia, koska ne eivät täyttäneet sisällyttämiskriteereitä. Lopulta vaiheesta meni eteenpäin 112 artikkelia, jotka etenivät tarkempaan analyysiin.

Kolmannessa vaiheessa analysoitiin valikoidut artikkelit niiden varsinaisen tekstin perusteella. Tämä vaihe auttoi varmistamaan, että tutkimukseen jääneet julkaisut todella tarjosivat vastauksia tutkimuskysymyksiin ja täyttivät sisällölliset ja laadulliset vaatimukset. Koko tekstin perusteella jätettiin pois tutkimukset, jotka eivät tarjonneet tarpeeksi syvällistä analyysia aiheesta, eivät tuoneet lisäarvoa tutkimukseen tai olivat vääränkielisiä. Tässä vaiheessa poistettiin 51 artikkelia ja lopulliseen aineistoon eteni 65 dokumenttia.

Valintaprosessin jokainen vaihe dokumentoitiin PRISMA-virtauskaavioon (kuvio 4), joka esittää aineiston seulonnan ja valintaprosessin visuaalisessa muodossa. Kaavioon sisältyvät alkuperäisten hakutulosten määrä, duplikaattien määrä, otsikon ja tiivistelmän perusteella poissuljetut artikkelit,

koko tekstin perusteella poissuljetut artikkelit sekä lopullinen tutkimukseen sisältyvien artikkelien määrä.




Kuvio 5 PRISMA-virtauskaavio

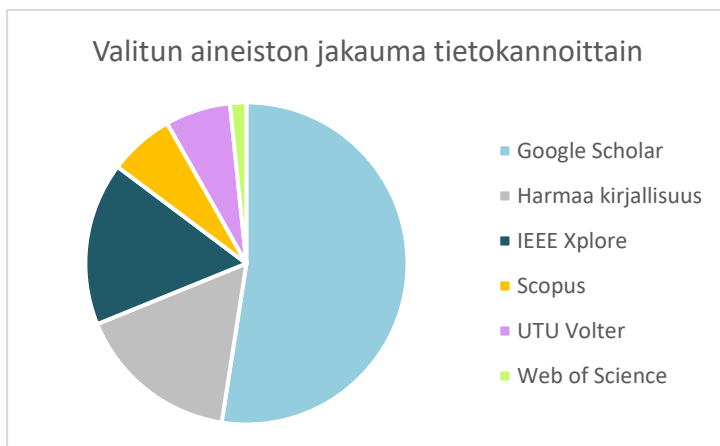
3.4 Aineiston analyysimenetelmät

Tutkimuksen lopullinen aineisto muodostuu valituista artikkeleista, joiden perusteella tiedonkeruu ja analyysi suoritettiin. Tiedonkeruu toteutettiin systemaattisesti, jotta tutkimuskysymyksiin voitiin vastata mahdollisimman kattavasti ja perusteellisesti.

Ensimmäisessä vaiheessa kerättiin jokaisesta artikkelista kuvailevat tiedot. Näihin kuuluivat julkaisuvuosi, julkaisukanava sekä tutkimusmenetelmät ja muut olennaiset tiedot. Lisäksi kartoitettaviin tietoihin sisältyivät artikkelien päätavoitteet, keskeiset löydökset ja esille tuodut ongelmat. Tässä vaiheessa pyrittiin muodostamaan yleiskuva generatiivisen tekoälyn käyttökohteista ja mahdollisuuksista pankkisektorilla sekä hahmottamaan alan yleisiä suuntauksia ja tutkimuksen nykytilaa.



Kuvio 6 Valitun aineiston julkaisujakauma vuosittain



Kuvio 7 Valitun aineiston jakauma tietokannoittain

Toisessa vaiheessa tarkasteltiin tarkemmin artikkeleissa esitettyjä sovelluskohteita ja mahdollisuuksia. Näiden tietojen avulla pyrittiin tunnistamaan generatiivisen tekoälyn keskeiset käyttöalueet pankkisektorilla, kuten asiakaspalvelussa, petosten havaitsemisessa ja liiketoimintaprosessien optimoinnissa. Samalla analysoitiin, miten mahdollisuuksia hyödynnettiin ja mitä rajoitteita tai haasteita niiden toteuttamiseen liittyi. Näin voitiin kartoittaa paitsi nykytilanne myös tulevaisuuden potentiaaliset kehityskohteet.

Kolmannessa vaiheessa keskityttiin yksityiskohtaisemmin generatiivisen tekoälyn vaikutusten arviointiin pankkisektorilla. Tämä sisälsi tarkastelun siitä, miten tekoäly vaikutti sidosryhmiin, kuten pankkien asiakkaisiin, työntekijöihin, sääntelyviranomaisiin ja pankkien liiketoimintaan yleisesti. Artikkeleista kerättiin tietoja siitä, miten tekoäly vaikutti esimerkiksi asiakaskokemukseen, operatiiviseen tehokkuuteen ja riskienhallintaan. Lisäksi analysoitiin, mitkä olivat tärkeimmät sidosryhmät ja miten niiden roolit ja vastuut muodostuivat tekoälyn käyttöönotossa.

Viimeisessä vaiheessa koottiin yhteen analyysin tulokset ja ryhmiteltiin ne eri teemoihin ja kategorioihin. Tavoitteena oli jäsentää löydökset siten, että ne tarjoavat selkeän kuvan siitä, missä pankkisektorin generatiivisen tekoälyn tutkimus tällä hetkellä menee ja mitkä ovat sen keskeisimmät käyttöalueet, mahdollisuudet ja haasteet. Näin tutkimus muodosti kattavan ja jäsennellyn näkemyksen aiheesta, johon liittyviä havaintoja voidaan hyödyntää myös käytännön sovelluksissa ja jatkotutkimuksessa. Aineisto kokonaisuudessaan on koottu liitteeseen 1.

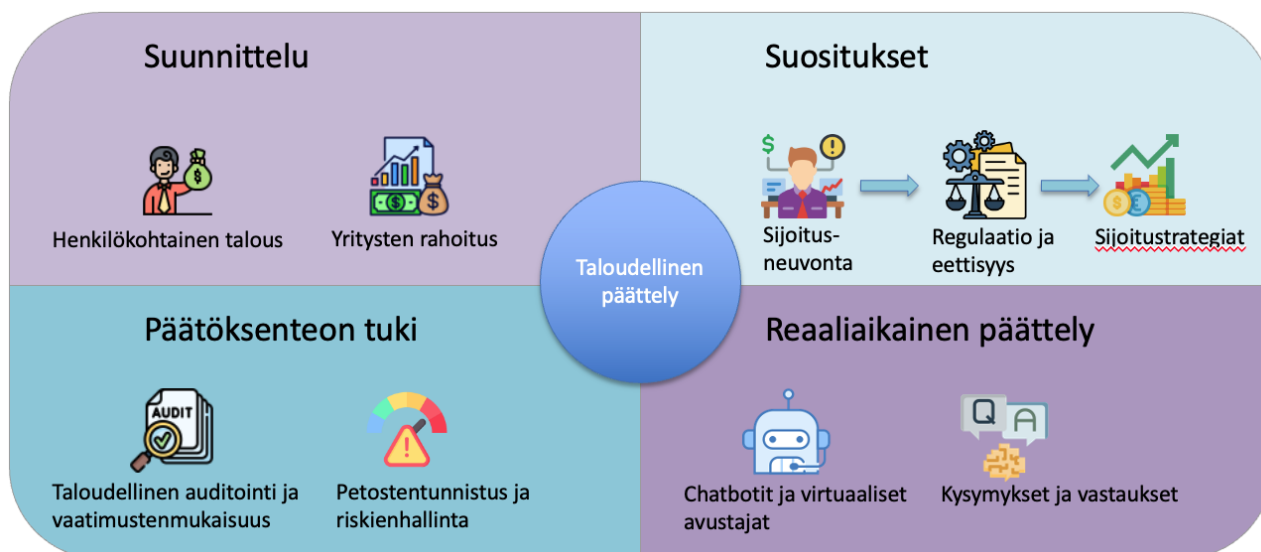
4 KIRJALLISUUSKATSAUKSEN TULOKSET

4.1 Generatiivisen tekoälyn käyttökohteet finanssialalla

Generatiivinen tekoäly tarjoaa merkittäviä mahdollisuuksia finanssialalle, erityisesti asiakaspalvelun, riskienhallinnan ja operatiivisen tehokkuuden parantamisessa. Useat tutkimukset ovat osoittaneet, että se voi mullistaa perinteiset pankkipalvelut tuottamalla personoituja asiakaskokemuksia, vähentämällä petoksia ja optimoimalla prosesseja (038).

Generatiivinen tekoäly on noussut merkittäväksi työkaluksi finanssialalla, tarjoten uusia mahdollisuuksia asiakaspalvelun tehostamiseen, riskienhallintaan ja operatiivisen tehokkuuden lisäämiseen. Useat tutkimukset ovat osoittaneet, että uusi teknologia voi muuttaa tapaa, jolla pankit ja muut rahoituslaitokset toimivat, automatisoiden monimutkaisia prosesseja ja parantaen asiakaskokemusta (038).

Finanssialan digitalisaation edetessä generatiiviset mallit, kuten suuret kielimallit (LLM), ovat alkaneet vaikuttaa keskeisiin osa-alueisiin, kuten asiakaspalvelun automatisointiin ja rahoituspäätösten tukemiseen. McKinseyn raportti (049) korostaa, että tekoäly tarjoaa pankeille kilpailuetua erityisesti operatiivisessa tehokkuudessa ja asiakaskokemuksen kehittämisessä.




Kuvio 8 Havaintokuva erilaisista taloudellisista päättelytehtävistä (mukaillen 016)


Aineistosta tehty analyysi osoittaa, että generatiivisen tekoälyn käyttö finanssialalla keskittyy erityisesti viiteen pääteemaan: sääntely ja lainsäädäntö, riskienhallinta, asiakaspalvelu, operatiivinen toiminta sekä sijoitukset ja portfolionhallinta. Nämä kaikki jakautuvat pienempiin sisäisiin osa-alueisiin, jotka avataan myöhemmin. Kuviossa 7 esitetään näiden pääteemojen esiintyvyys aineistossa. Riskienhallinnan ja asiakaspalvelun teemat ovat erityisen korostuneita, mikä kertoo siitä, että pankit näkevät tekoälyn merkittävänä apuna riskienhallinnan ja asiakaskokemuksen parantamisessa. Kuvion 8 perusteella voidaan myös havaita, että monissa dokumenteissa mainitut aiheet liittyvät sääntelyyn

ja riskienhallintaan, kun taas eettisyys ja petosten ehkäisy ovat vähemmän käsiteltyjä aiheita. Tämä voi viitata siihen, että vaikka eettiset kysymykset ovat tärkeitä, käytännön sovellukset ja sääntelyyn liittyvät haasteet ovat vielä keskeisempiä tekoälyn käyttöönotossa finanssialalla.

Taulukossa 5 vertaillaan perinteisten pankkipalveluiden ja generatiiviseen tekoölyyn pohjautuvien ratkaisujen eroja. Perinteisille pankkipalveluille on tyypillistä manuaalisuus, hitaus ja suuret operatiiviset kustannukset, kun taas generatiivinen tekoöly usein tarjoaa nopeampia, automatisoituja ja personoituja ratkaisuja.



Kuvio 9 Aineistoon valittujen artikkelien teemojen esiintyvyys



Kuvio 10 Aineiston yleisimpien teemojen suhteellinen kattavuus

Taulukko 4 Perinteiset ja generatiiviseen tekoölyyn pohjautuvat pankkipalvelut

<i>Ominaisuus</i>	<i>Perinteiset pankkipalvelut</i>	<i>Gen AI -pohjaiset ratkaisut</i>
<i>Asiakaspalvelu</i>	Hidasta, manuaalinen käsittely, vasteajat voivat olla tunteja tai päiviä.	Nopeaa, chatbotit ja automatisoidut järjestelmät voivat vastata sekunneissa.
<i>Sijoituspalvelut</i>	Perinteinen sijoitusneuvonta perustuu manuaaliseen analyysiin ja vakioituihin ratkaisuihin.	Tekoöly voi analysoida suuria datamääriä, luoda yksilöllisiä sijoitussuosituksia ja tuottaa reaaliaikaisia markkina-analyysijä.
<i>Riskienhallinta</i>	Manuaalinen prosessi, vaatii paljon henkilöstöresursseja.	Automatisoitu, tekoölymallit analysoivat suuria tietomääriä nopeasti.
<i>Petostentunnistus</i>	Voi jäädä jälkeen. Perinteiset keinot eivät aina tunnista uusia huijausmenetelmiä.	Tekoöly tunnistaa epäilyttävää käyttäytymistä reaaliajassa.
<i>Operatiivinen toiminta</i>	Korkeat kustannukset, paljon manuaalista työtä ja resurssien käyttöä.	Matalammat kustannukset, prosessien automatisointi vähentää henkilöstö- ja infrastruktuurikuluja.
<i>Säätelyyn mukautuminen</i>	Hidasta. Säätelymuutoksiin mukautuminen vie pitkään.	Nopeaa. Tekoöly pystyy mukautumaan uusiin säätelyvaatimukseen välittömästi. (Tekoöly tuo uusia säätelytarpeita).

4.1.1 Asiakaspalvelun parantaminen

Generatiivinen tekoäly tarjoaa merkittäviä mahdollisuuksia asiakaspalvelun automatisointiin ja laadun parantamiseen pankkisektorilla. Se vähentää manuaalista työkuormaa, nopeuttaa vastaamista asiakaskyselyihin ja mahdollistaa kustannustehokkaamman palvelutuotannon. Erityisesti suurten kielimallien, kuten ChatGPT:n, avulla voidaan kehittää yhä personoidumpia ja käyttäjälähtöisempiä asiakaspalveluratkaisuja, jotka mukautuvat asiakkaan yksilöllisiin tarpeisiin. Lisäksi tekoälyn hyödyntäminen vuorovaikutteisessa asiakaspalvelussa voi parantaa merkittävästi asiakastyytyvää ja tarjota saumattoman monikanavaisen palvelukokemuksen.

McKinseyn mukaan yksi pankkialan keskeisimmistä generatiivisen tekoälyn sovellusalueista on asiakaspalvelu, erityisesti asiakasrajapinnan automatisointi ja kehittäminen (047). GenAI-tekniikoiden avulla manuaaliset ja aikaa vievät prosessit voidaan muuntaa dynaamisemmiksi asiakaskohtaisiksi, joissa esimerkiksi virtuaaliassistentit tukevat asiakaspalvelijoita tarjoamalla kontekstisidonnaisia suosituksia keskusteluhistorian perusteella. GPT-pohjaisia järjestelmiä hyödynnetään myös markkinointiviestinnän personoinnissa ja asiakkaan kontekstiin mukautuvien vastausten tuottamisessa, mikä mahdollistaa hyperpersonoidun palvelun skaalautumisen laajalle asiakaskunnalle (047).

Useat pankit ovat ottaneet käyttöön generatiivista tekoälyä erityisesti chatbot-sovelluksissa sekä asiakasviestinnän automatisoinnissa (048). Yleinen toimintamalli perustuu keskitettyyn GenAI-tiimiin, joka vastaa ratkaisujen kehittämisestä ja jalkauttamisesta koko organisaation käyttöön. Tämä mahdollistaa nopean siirtymän pilottivaiheista tuotantokäyttöön ja edesauttaa sovellusten skaalautuvuutta. Lopputuloksena pankit voivat tarjota reaaliaikaista, yksilöllistä palvelua samalla, kun manuaalinen työ ja resurssitarve vähenevät (048). ChatGPT:tä on hyödynnetty erityisesti asiakaspalveluchattibottien rakentamiseen. Nämä botit pystyvät vastaamaan asiakaskysymyksiin, ehdottamaan tuotteita ja käsittelemään tapahtumia itsenäisesti. ChatGPT tarjoaa näin keskeisen asiakaspalvelumuodon finanssialan toimijoille ja sen käyttö nähdään luontevana osana luonnollisen kielen käsittelyn (NLP) ratkaisuja. Erityisesti asiakastyytyvyyden paraneminen nousee esiin näiden sovellusten keskeisenä hyötynä (007).

Useiden tutkimusten mukaan asiakaspalvelu on yksi keskeisimmistä alueista, joilla generatiivinen tekoäly voi tuoda konkreettista lisäarvoa finanssialalle. ChatGPT:n kaltaiset suuret kielimallit mahdollistavat asiakaskohtaamisten personoinnin ja automatisoinnin tavalla, joka parantaa palvelun saatavuutta, johdonmukaisuutta ja tehokkuutta. GenAI-tekniikan avulla chatbotit kykenevät vastaamaan asiakkaiden kysymyksiin tarkasti ja luonnollisesti, mikä samalla keventää asiakaspalveluhenkilöstön työtaakkaa (038). Reaaliaikainen analytiikka ja ennakoivat ratkaisut puolestaan mahdollistavat nopeamman ja osuvamman reagoinnin asiakkaiden tarpeisiin.

Teknologian sovellusalueet ulottuvat yksilöllisistä asiakasneuvojista automatisoituihin sijoitusstrategioihin. GPT-pohjaiset mallit voivat esimerkiksi tuottaa asiakkaan riskiprofiiliin perustuvia sijoitussuosituksia, jotka pohjautuvat laajaan markkina- ja asiakastietoon. Tällaiset järjestelmät eivät ainoastaan jäljittele asiantuntijan toimintaa, vaan voivat toimia aidosti päätöksentekoa tukevana, skaalautuvina järjestelminä, jotka vahvistavat pankkien kilpailukykyä digitalisoituvassa toimintaympäristössä (002).

LLM-teknologiaa hyödynnetään pankkien asiakashallinnassa laajasti, kuten kohdennetussa markkinoinnissa, asiakassegmentoinnissa ja sentimenttianalyyseissä. Asiakaspalvelun näkökulmasta suurten kielimallien avulla on kehitetty virtuaalisia asiakasavustajia, jotka ymmärtävät luonnollista kieltä ja tukevat asiakkaita esimerkiksi tilitietoihin, maksuihin ja säästösuunnitelmiin liittyvissä asioissa. Bank of American "Erica" on esimerkki 24/7-palvelusta, joka parantaa asiakastyytyvää ja pankin operatiivista tehokkuutta (008). GenAI-ratkaisut tarjoavat nopean vasteajan ja kykenevät hoitamaan yksinkertaisia tehtäviä itsenäisesti, minkä lisäksi ne voidaan integroida asiakkuudenhallintajärjestelmiin asiakasyymmärryksen syventämiseksi (009).

Useissa tutkimuksissa korostetaan personoinnin merkitystä asiakaspalvelussa (012). Älykkäät chatbotit ja virtuaaliavustajat kykenevät tarjoamaan tarkkaa, kontekstisidonnaista ja reaaliaikaista tietoa, joka mukautuu käyttäjän yksilöllisiin tarpeisiin. Osa järjestelmistä toimii myös offline-tilassa ja tunnistaa tunnetiloja, mikä lisää vuorovaikutuksen luonnollisuutta ja asiakkaan kokemaa empaattisuutta (014, 015). Tällaiset ominaisuudet ovat erityisen arvokkaita pankkisektorilla, jossa luottamuksella on keskeinen rooli.

Generatiivisen tekoälyn avulla pankit voivat entistä tarkemmin ennakoida asiakaskäyttäytymistä ja räätälöidä palveluja proaktiivisesti. Tämä lisää asiakastyytyvää ja sitoutuneisuutta sekä tukee ristiinmyyntiä, kuitenkin niin, että tietosuoja ja läpinäkyvyys säilyvät keskeisinä ehtona asiakkaan luottamuksen ylläpitämiseksi (029). On kuitenkin huomattava, että esimerkiksi pohjoismaisissa pankeissa teknologian käyttöönottoa hidastavat edelleen tietosuojahuolenaiheet ja eettiset pohdinnat, minkä vuoksi GenAI:n hyödyntäminen asiakasrajapinnassa on toistaiseksi ollut rajallista (016).

GenAI-chatbotit parantavat asiakaskokemusta tarjoamalla 24/7 saatavilla olevaa tukea, automatisoimalla KYC-prosesseja, suorittamalla todentamistehtäviä ja ehdottamalla henkilökohtaisia ratkaisuja analysoimalla asiakkaan taloustietoja (017, 018, 019). Tällaiset ratkaisut tukevat asiakassuhteen syventämistä ja mahdollistavat entistä kontekstisensitiivisempää palvelua. Morgan Stanleyn ja JPMorganin kaltaiset toimijat ovat ottaneet käyttöön OpenAI-teknologiaa muun muassa asiakastuen ja sijoitusneuvonnan tukemiseen (027, 033).

Keskustelupohjaiset asiakaspalveluratkaisut, jotka hyödyntävät suuria kielimalleja kuten GPT ja BERT, voidaan integroida pankkien digitaalisiin kanaviin tarjoten oppivaa ja mukautuvaa palvelua eri asiakasryhmille (030, 031). Kehittyneissä ratkaisuissa hyödynnetään Retrieval-Augmented Generation (RAG) -menetelmää, joka mahdollistaa faktapohjaisen ja kontekstittietoisin vastaamisen käyttäjän kysymyksiin (034, 057). Tämä tekninen toteutus parantaa erityisesti toistuvien ja yksityiskohtaisten kysymysten käsittelyä ilman laadun heikkenemistä.

GenAI voi lisäksi tukea esteettömyyttä esimerkiksi text-to-audio- ja text-to-video-mallien avulla (038), automatisoida puheluiden tiivistämistä ja asiakasviestintää (040, 055) sekä tukea tehtäväkeskeisten chatbotien kehittämistä, jotka ylittävät perinteisten sääntöpohjaisten järjestelmien rajat (036, 042). IMF ja Accenture korostavat, että teknologian inhimillinen ulottuvuus, kuten asiakkaan tarpeisiin vastaaminen empaattisesti ja läpinäkyvästi on keskeinen osa onnistunutta asiakaspalvelun digitalisaatiota (043, 044, 053).

4.1.2 Riskienhallinta ja petostentunnistus

Riskienhallinnan ja petostentunnistuksen tehostaminen on yksi keskeisimmistä generatiivisen tekoälyn sovelluskohteista finanssialalla. Tekoälypohjaiset järjestelmät kykenevät analysoimaan suuria tietomääriä ja havaitsemaan epäilyttävää toimintaa reaaliajassa, mikä auttaa vähentämään petoksia ja talousrikoksia (054). Lisäksi generatiiviset mallit mahdollistavat skenaarioanalyysien laatimisen, joiden avulla pankit voivat varautua paremmin tulevaisuuden riskeihin.

Generatiivisen tekoälyn käyttö riskienhallinnassa liittyy paitsi tekniseen valvontaan myös sääntelyyn ja operatiivisiin prosesseihin. Esimerkiksi asiakirjojen automaattinen käsittely voi vähentää virheitä ja nopeuttaa päätöksentekoa, samalla kun sääntelyvaatimusten noudattaminen paranee (054). McKinseyn mukaan generatiiviset mallit voivat tukea petosten havaitsemista analysoimalla suuria tietomassoja ja tunnistamalla epätyypillisiä käyttäytymismalleja reaaliaikaisesti (054).

GenAI-teknologioiden käyttöönotto tuo kuitenkin mukanaan myös uusia riskejä. Artikkelit nostavat esiin huolenaiheita, kuten hallusinaatiot, selitettävyyden puutteen ja regulaatioepävarmuudet, jotka edellyttävät uusia hallintaratkaisuja. Näitä ovat mm. LLM-mallien lämpötilaparametrien säätö, toksisuusfiltrit ja asiantuntijapalautejärjestelmät mallien validointiin (047). Samassa yhteydessä tuodaan esiin Citigroupin tapaus, jossa generatiivista mallia hyödynnettiin 1089-sivuisen sääntelyaineiston analysointiin uusien pääomasääntöjen vaikutusten arvioimiseksi (047). Capital One puolestaan käyttää AML-sovelluksia, joissa yhdistetään suuria transaktiotietomassoja epätyypillisten petoskuvioiden tunnistamiseksi (047).

Riskienhallinnan rakenteellinen toteutus voi nojautua keskitettyyn toimintamalliin, jossa GenAI:n käyttöönotto on integroitu sääntelykehikkoon, audit trail -rakenteisiin, tietosuojarajoihin ja immateriaalioikeuksien hallintaan. Kehitysprosessissa mallien kehittäjät ja riskiasiantuntijat työskentelevät tiiviissä yhteistyössä jo varhaisessa vaiheessa, mikä tukee sääntelymukaisuutta (048). Tätä lähestymistapaa on sovellettu esimerkiksi luottoriskien arviointiin ja compliance-alueiden hallintaan (053).

Useat artikkelit tuovat esiin generatiivisten mallien mahdollisuudet havaita petoksia reaaliajassa maksutapahtumista sekä tukea rahanpesun estämistä ja KYC-prosesseja (002, 009, 011). Swedbankin esimerkki GAN-verkkojen käytöstä rahanpesun estämisessä osoittaa, että generatiiviset menetelmät

voivat havaita poikkeavuuksia, joita perinteiset sääntöpohjaiset järjestelmät eivät tavoita (002). Vastaavasti GPT- ja BERT-pohjaisia malleja on hyödynnetty sääntelydokumenttien analyysissä ja talousraportoinnissa (014, 015).

Synteettinen data on noussut keskeiseksi työkaluksi riskienhallinnassa ja petostentorjunnassa. Esimerkiksi GPT-4:n avulla tuotettu data on parantanut mallien ennustetarkkuutta ja lyhentänyt käsitteilyaikaa, mikä tehostaa käyttöönottoprosesseja (004, 005). Samalla synteettisen datan luonnissa on huomioitava yksityisyys- ja tietosuojakysymykset sekä datan samankaltaisuus oikean aineiston kanssa (005).

Luottoriskien arviointiin liittyvissä sovelluksissa hyödynnetään historiallista asiakas- ja transaktiodataa sekä skenaariosimulointeja (029, 020, 023). GenAI-malleilla voidaan muodostaa kokonaiskuva asiakkaan taloudellisesta asemasta, simuloida markkinashokkeja ja tunnistaa haavoittuvuuksia ennen päätöksentekoa (017, 027). Tällaiset menetelmät tukevat myös EU:n sääntelyvaatimusten, kuten GDPR:n ja AI Actin, täyttämistä (029, 016).

Petostentorjunnassa generatiiviset mallit kykenevät tunnistamaan uusia huijausmenetelmiä ja vähentämään väärin hälytysten määrää (018, 019, 020). GAN- ja VAE-malleilla tuotettu synteettinen data auttaa tasapainottamaan epätasaisia aineistoja ja parantaa mallien kykyä havaita harvinaisia petoksia (024, 026). Näitä malleja on sovellettu myös asiakirjojen poikkeavuuksien havaitsemiseen (032), graafipohjaisiin transaktioverkkoihin (035) sekä sähköpostiviestinnän analysointiin (033, 055).

Jatkuva oppiminen, anomaly detection -algoritmit ja hybridiratkaisut, jotka yhdistävät sääntöjä ja oppivia järjestelmiä, muodostavat yhä tehokkaampia työkaluja riskien ja petosten hallintaan. Esimerkiksi sekventiaaliset mallit ovat osoittautuneet toimiviksi petostapausten reaaliaikaisessa analyysissä (028, 030, 031).

Lopuksi useat lähteet korostavat, että GenAI ei ainoastaan tuo tehokkuutta, vaan mahdollistaa myös strategisempaa ja ennakoivampaa riskienhallintaa. Multiagenttijärjestelmät (049), NLP-pohjainen sentimenttianalyysi (051) ja big data -analytiikka (020, 034) täydentävät GenAI-ekosysteemiä, tuoden skaalautuvuutta ja älykkäämpää päätöksentukea finanssialan käyttöön.

4.1.3 Operatiivisen tehokkuuden lisääminen

Generatiivinen tekoäly tarjoaa merkittäviä mahdollisuuksia pankkien operatiivisten prosessien tehostamiseen. Finanssialalla sen käyttö näkyy erityisesti päivittäisen toimintaan, sääntelyyn, riskienhallintaan ja legacy-järjestelmien modernisointiin liittyvien tehtävien automatisoinnissa. Näiden sovellusten avulla pankit voivat parantaa suorituskykyään, nopeuttaa prosesseja, vähentää virheitä ja kohdentaa resurssejaan aiempaa tehokkaammin. Operatiivisen tehokkuuden kasvua tukevat niin rutiinitehtävien automatisointi, sisällöntuotannon ja analyysien generointi kuin myös datasta saatavien ennakoivien näkökulmien hyödyntäminen päätöksenteossa.

Yksi keskeinen alue operatiivisessa tehostamisessa on sisäisten prosessien automatisointi. Esimerkiksi Goldman Sachs hyödyntää GenAI-malleja testien automatisoidussa generoinnissa ja sääntelytekstien tiivistämisessä, mikä on vähentänyt manuaalista työtaakkaa merkittävästi. Yksittäisen sijoitusyhteenvedon laatimisaika on artikkelin mukaan lyhentynyt yhdeksästä tunnista 30 minuuttiin. Artikkeliki korostaa integroidun GenAI-arkkitehtuurin merkitystä, jossa komponentteja kuten kontekstinhallinta, prompt-kirjastot, MLOps-alustat ja riskienhallintamoottorit voidaan hallita keskitetysti (047). Skaalautuvuus ja standardointi nousevat keskiöön myös toimintamallien suunnittelussa: keskitettyjen mallien käyttäjistä jopa 70 % on päässyt MVP-tasoiisiin sovelluksiin, kun hajautetuissa malleissa vastaava osuus on vain 30 % (048).

Operatiivisten mallien uudistaminen näkyy laajasti pankkien GenAI-hankkeissa. Accenture arvioi suuria tuottavuusparannuksia esimerkiksi koodin uudelleenkirjoittamisessa, asiakirjahallinnassa ja asiakaskontaktien tiivistämisessä. AI-agenttijärjestelmät toimivat virtuaalisina työntekijöinä eri toiminnoissa ja strateginen priorisointi tukee GenAI-ratkaisujen tehokasta skaalausta (053). Lisäksi generatiivisia malleja sovelletaan asiakassegmentointiin, henkilökohtaisten suositusten tekoon, henkilöstön koulutukseen ja monimutkaisten asiakaskysymysten hallintaan (002).

GenAI:n käyttöönotto näkyy myös talous- ja hallintoprosessien tasolla. Mallien avulla voidaan automatisoida luottokelpoisuuden arviointia, kirjanpidon toistuvia tehtäviä ja tilinpäätösten laadintaa, mikä vähentää virheriskiä ja kustannuksia. Näissä sovelluksissa hyödynnetään synteettisellä datalla koulutettuja LLM-malleja, jotka kykenevät kontekstuaaliseen tulkintaan ja tunnesävyjen ymmärtämiseen (009). Lisäksi, koska GenAI mahdollistaa asiakirjojen jäsentämisen ja sisällön tiivistämisen, jolloin dokumentaation käsittely ja säilytys voidaan osittain automatisoida.

Laajassa mittakaavassa LLM-mallit ovat parantaneet pankkien kykyä hallita IT-infrastruktuuria, tunnistaa markkinamahdollisuuksia ja kehittää personoituja palveluita. Ne tukevat automaattista asiakirjatuotantoa, koodin generointia ja datan analyysia (008). Esimerkiksi GPT-4-assistentti on nopeuttanut Morgan Stanleyn sijoitusessitteiden tuotantoa ja Guangfa Bank on parantanut kehitystyön tarkkuutta suurten mallien avulla. JPMorganin COIN-järjestelmä puolestaan käyttää generatiivista tekoälyä oikeudellisten asiakirjojen analysointiin, vapauttaen resursseja strategisempiin tehtäviin (011).

Edistyneemmät LLM- ja transformer-pohjaiset ratkaisut, kuten RAG ja LED, mahdollistavat pitkien tekstien tiivistämisen, tietojen poiminnan ja kyselypohjaisen tiedonhaun. Esimerkiksi GPTQuant ja FinChain-BERT mahdollistavat reaaliaikaisen monikielisen asiakaspalvelun, mukaan lukien tunnetilojen ja käyttäytymismallien tunnistuksen (014, 015). Nämä järjestelmät tukevat myös prosessien automatisointia, kuten tilien täsmäytyksiä ja compliance-valvontaa (030, 023).

Front-office- ja asiakasrajapinnan toiminnoissa GenAI nopeuttaa sisällöntuotantoa ja vähentää manuaalista käsittelyä. GRU-pohjaiset järjestelmät tarjoavat skaalautuvia ratkaisuja, joiden avulla voidaan tuottaa asiakaskohtaisia suosituksia ja automatisoida esimerkiksi maksupäätöksiä (039, 031). Lisäksi PixelCNN++ ja muut kuvapohjaiset mallit tehostavat dokumenttien luokittelua ja validointia esimerkiksi asiakirjojen OOD-tunnistuksessa (032).

Pankkien käytännön esimerkeissä GenAI on otettu käyttöön mm. asiakasviestinnässä (Wells Fargo), sisäisessä kehitystyössä (Goldman Sachs), rekrytoinnin optimoinnissa (BBVA) ja sijoitusneuvonnassa (HSBC) (040). Lisäksi GenAI:n hyödyntäminen dokumenttien tiivistämisessä, sopimusten luonnostelussa ja kokousmuistioiden automaatiassa mahdollistaa tuottavuuden kasvun jopa 35 % (046, 051).

Kustannustehokkuus korostuu erityisesti pienille ja keskisuurille pankeille. Esimerkiksi GPT-4:n 3-shot-luokittelu maksaa jopa 20-kertaisesti enemmän kuin Claude 2 + RAG -ratkaisu samalla tarkkuudella (042). Myös luottoanalyttikoiden tuottavuutta voidaan kasvattaa jopa 60 %, kun AI copilot tukee päätöksentekoa ja laatii alustavat arvioinnit (049). GenAI:n yhdistäminen perinteisiin prosessi-automatiaoalustoihin mahdollistaa työnkulkujen orkestroinnin ihmisten, AI:n ja muiden järjestelmien välillä (050).

Generatiivisen tekoälyn soveltaminen operatiivisen tehokkuuden parantamiseen on laajaa, monitasoista ja vaikuttaa koko pankkiorganisaation toimintaan. Se ei ainoastaan vähennä manuaalista kuormaa, vaan tukee strategista kyvykkyyttä ja kilpailukykyä digitalisoituvassa ympäristössä.

4.1.4 Sijoitukset, lainat ja luotonhallinta

Generatiivinen tekoäly tarjoaa pankkisektorille merkittäviä mahdollisuuksia myös lainojen, sijoitusten ja luotonhallinnan tehostamiseen. Lainaprosesseissa suuret kielimallit mahdollistavat dynaamisen luottoriskien hallinnan analysoimalla reaaliaikaista dataa ja ennakoimalla mahdollisia riskejä. Ne voivat automatisoida lainahakemusten käsittelyä, analysoida hakijoiden taloudellisia tietoja ja tuottaa nopeita, tarkkoja päätöksiä. Lisäksi LLM-teknologia tukee yksilöllisten lainatuotteiden suosittelua asiakkaan käyttäytymisen ja taloudellisen tilanteen perusteella. Esimerkiksi Credit Suisse on hyödyntänyt generatiivista tekoälyä asuntolainaprosessien tehostamisessa, mikä on lyhentänyt käsittelyaikoja ja parantanut riskien arviointia. Vastaavasti useat kiinalaiset pankit ovat raportoineet parantuneesta hyväksymistehokkuudesta ja alemmista luottotappioriskeistä (008).

Varainhoidossa ja sijoituspalveluissa LLM-mallit mahdollistavat yhä personoidumman ja dataohjatun asiakaspalvelun, erityisesti korkean varallisuustason asiakkaiden ja institutionaalisten sijoittajien osalta. LLM:t analysoivat asiakkaan taloudellista tilannetta, sijoitustavoitteita ja markkinadataa, tuottaen räätälöityä neuvontaa ja optimoiden sijoitussalkkujen hajautusta. Mallit tukevat myös markkinaskenaarioiden simulointia ja riskianalyysyjä, joiden avulla sijoittajat voivat tunnistaa riskejä ja reagoida ennakoivasti. Lisäksi älyneuvontajärjestelmät mahdollistavat sijoitussalkkujen automaattisen, reaaliaikaisen hallinnan. Esimerkiksi Goldman Sachs hyödyntää tekoälyä asiakasriskien ja -tavoitteiden analysointiin, Barclays tarjoaa personoitua sijoitusneuvontaa varakkaalle asiakaskunnalle ja Citibank raportoi tekoälypohjaisesta salkunhallinnasta seuranneista tuotto-parannuksista (008).

Tekoälyä hyödynnetään myös älykkäissä sijoitusaloissa ja roboneuvoissa. Näissä järjestelmissä analysoidaan markkinadataa, uutisvirtaa ja historiallisia trendejä, joiden pohjalta voidaan laatia kaupankäyntistrategioita, arvioida riskejä ja tehdä sijoituspäätöksiä. Vaikka järjestelmien ei aina nimenomaisesti ilmoiteta olevan GenAI-pohjaisia, niiden toiminnallisuus vastaa generatiivisen tekoälyn tarjoamia ratkaisuja modernissa varainhoidossa (011).

Useat tutkimukset osoittavat, että LLM-mallit voivat parantaa sijoitusstrategioiden tehokkuutta ja tukea kaupankäynnin päätöksentekoa. Mallit kykenevät tuottamaan sijoitussuosituksia uutisten ja poliittisten ilmoitusten perusteella sekä analysoimaan yritysten raportteja ja sääntelydokumenteja, mikä tukee osakestrategioiden rakentamista ja optimointia (014). Lisäksi älykkäät kaupankäyntiagentit voivat simuloida markkinakäyttäytymistä ja reagoida reaaliaikaiseen dataan, tarjoten sijoittajille dynaamista tukea päätöksentekoon. GPTQuantin kaltaiset työkalut mahdollistavat salkun uudelleentasapainottamisen ja faktorianalyysin toteuttamisen Python-koodin avulla (015).

Generatiiviset mallit, kuten FinGPT ja BloombergGPT, voivat tulkita markkinadataa syvällisemmin kuin perinteiset menetelmät. Ne tunnistavat kielen vivahteita, analysoivat markkinasentimenttiä ja tuottavat näkemyksiä, jotka tukevat sekä salkun optimointia että sijoitusstrategioiden personointia (029). Tällaiset teknologiat ovat jo käytössä useissa pankeissa: JPMorganin IndexGPT ja Finance GPT tukevat sijoituskohteiden valintaa ja neuvontaa ja BloombergGPT soveltuu rahoitusalan NLP-tehtäviin, kuten sentimenttianalyysiin ja kysymys-vastausjärjestelmiin (019, 040).

Edistyneimmissä ratkaisuissa hyödynnetään GAN- ja VAE-malleja esimerkiksi korkojen mallintamiseen tai vaihtoehtoisten skenaarioiden simuloimiseen. Näiden avulla voidaan parantaa sijoitus tuotteiden hinnoittelua ja tukea päätöksentekoa epävarmoissa markkinaympäristöissä (020, 030). Transformeri- ja RNN-arkkitehtuurien pohjalta rakennetut sijoitusagentit kykenevät käsittelemään ajallista dataa, tekemään strategiapäivityksiä ja mallintamaan markkinasentimenttiä NLP:n avulla (023).

LLM-teknologia tukee myös dokumenttipohjaista sisällöntuotantoa sijoituspalveluissa. GenAI-malleilla voidaan automaattisesti luoda sijoitusmuistioita, due diligence -raportteja ja esityksiä (031, 033). BloombergGPT:n suorituskyky on ylittänyt asiantuntijoiden keskiarvot kvantitatiivisessa analyysissä (034) ja Intuit Assist -ratkaisut tukevat henkilökohtaista taloussuunnittelua Credit Karman kautta.

Vaikka moni sovelluksista on vielä kehitysvaiheessa, niiden potentiaali sijoituspalveluiden tehostamisessa on huomattava. Tekoälyllä voidaan parantaa päätöksenteon nopeutta, simuloida vaihtoehtoisia skenaarioita ja automatisoida salkunhoitoa eri sääntelyalueiden erityistarpeet huomioiden (036, 054). Osa ratkaisuista, kuten AI copilot -toiminnot ja "digital twin" -simulaatiot, tukevat myös compliance-prosesseja ja investointipankkitoimintaa (053, 056, 055).

4.1.5 Muut käyttökohteet

Vaikka asiakaspalvelu, riskienhallinta ja operatiivinen toiminta muodostavat keskeisimmät generatiivisen tekoälyn sovellusalueet finanssialalla, kirjallisuuskatsauksessa tunnistettiin myös muita merkittäviä käyttökohteita. Näitä ovat erityisesti sijoitusstrategioiden kehittäminen, maksujärjestelmien optimointi, sisäisten prosessien tukeminen sekä strateginen suunnittelu.

Sijoitus- ja markkina-analyysi on yksi merkittävimmistä kehittyvistä sovellusalueista. Generatiivista tekoälyä hyödynnetään markkinatrendien analysoinnissa, sijoitusstrategioiden kehittämisessä ja taloudellisten muutosten ennakoinnissa. Tällaiset ratkaisut tukevat pankkien strategista suunnittelua ja markkinariskien hallintaa (054). [004 Joshi, 2025] mukaan generatiiviset mallit ovat lisänneet markkinaennusteiden tarkkuutta yli 25 % ja synteettisen markkinadatan avulla on voitu parantaa kaupankäyntistrategioiden takautuvaa testausta ja luotettavuutta. Yleisten kielimallien, kuten GPT-4:n, kehittyminen on mahdollistanut niiden hyödyntämisen monipuolisesti myös talousanalyysissä, sääntelyn tulkinnassa, budjetoinnissa, ilmatoriskien arvioinnissa ja robo-neuvonnassa, joissa ne ovat simulaatioissa saavuttaneet jopa markkinoita paremmin tuottavia tuloksia (005).

Maksuliikenteessä generatiivinen tekoäly tarjoaa ratkaisuja maksuprosessien automatisointiin, turvallisuuden parantamiseen ja asiakaskokemuksen optimointiin. LLM-mallit mahdollistavat suurten transaktiodatojen reaaliaikaisen analyysin, maksureittien optimoinnin ja virheiden vähentämisen. Ne tukevat myös luonnollisen kielen avulla toimivia älymaksupalveluja, jotka voivat auttaa esimerkiksi laskujen maksamisessa ja budjetin hallinnassa. Erityisesti kansainvälisissä maksutapahtumissa LLM:t voivat automatisoida sääntelyn tarkastuksia ja tehostaa valuutanvaihtoa. MasterCard on raportoinut 20 %:n kasvua petosten havaitsemisessa ja 200 %:n laskua väärin hälytysten määrässä generatiivisen tekoälyn ansiosta (008).

Maksujärjestelmien kehittämisessä hyödynnetään lisäksi syviä neuroverkkoja (DNN) maksukäytännön mallintamiseen sekä GAN-malleja synteettisen maksudatan tuottamiseen tilanteissa, joissa todellisen datan käyttö on tietosuojasyyistä rajoitettua. Näin voidaan parantaa petostentorjunta-algoritmien koulutusta erityisesti epätasapainoisissa aineistoissa. Samalla NLP-teknologia tukee asiakastukea muun muassa puhelulokien analysoinnissa ja raporttien automatisoinnissa. Edge-AI-tekniikat ja rajapintapohjaiset integraatiot mahdollistavat GenAI-toimintojen hyödyntämisen suoraan mobiili- ja verkkopankkisovelluksissa, mikä tukee maksujärjestelmien operatiivista tehokkuutta, tietoturvaa ja sääntelyn noudattamista (022).

Sisäisissä prosesseissa ja tukitoiminnoissa generatiivista tekoälyä hyödynnetään muun muassa dokumenttien luokittelussa ja sisäisen viestinnän tehostamisessa. Vaikka näitä sovelluksia ei käsitellä erillisinä kategorioina, ne muodostavat tärkeän osan pankkien tehokkuuden ja riskienhallinnan kokonaiskehystä (046). Lisäksi GenAI tukee ohjelmistokehitystä esimerkiksi teknisen velan purkamisessa, mahdollistamalla legacy-järjestelmien modernisoinnin ilman täydellistä uudelleenkirjoitusta (047).

Myynnin ja hallinnon tukena GenAI:n käyttö laajenee multiagent-järjestelmien kautta. Näiden avulla voidaan analysoida asiakaskohtaisia, tarjota myyntihenkilöstölle tapauskohtaisia suosituksia ja automatisoida sopimusten tai tarjousten laadintaa. Ratkaisut ovat uudelleenkäytettäviä ja skaalautuvia, mikä nopeuttaa käyttöönottoa ja vähentää kokonaiskustannuksia (049).

Strategisessa päätöksenteossa GenAI:ta sovelletaan esimerkiksi seuraavan parhaan toimenpiteen (next best action) -suositusten muodostamiseen yhdistämällä asiakas- ja markkinadataa. Tämä mahdollistaa räätälöityjen tarjousten laatimisen ja uusien liiketoimintamallien kehittämisen (050). Samalla generatiivinen tekoäly tukee automaattisten kauppastrategioiden rakentamista ja sentimentianalyysiä (051).

Dokumentointiin ja ohjelmistokehitykseen liittyvissä tehtävissä GenAI voi tehostaa asiantuntijoiden työtä merkittävästi. Esimerkiksi Goldman Sachs käyttää kielimalleja ohjelmakoodin kirjoittamiseen ja testien luomiseen. Westpac on ottanut käyttöön toimialakohtaisesti koulutetun Kai-GPT:n, jonka tavoitteena on vähentää hallusinaatoriskiä ja parantaa tulosten tarkkuutta. Näin LLM-mallien arvo korostuu räätälöityjen pankkikohtaisessa soveltamisessa (055).

4.1.6 Teknologioista

(005) Yleisten kielimallien (kuten GPT-4) nopea kehitys on käynnistänyt uuden innovaation aikakauden finanssialalla. LLM-malleja on testattu laajasti erilaisissa rahoituksen ja kirjanpidon tehtävissä, mukaan lukien talousanalyysi, sääntelyn tulkinta, budjetointi, riskienhallinta ja ilmatoriskien analysointi. Ne ovat osoittautuneet erityisen hyödyllisiksi taloudellisen tekstin analysoinnissa sekä sijoitusneuvonnassa, missä ne ovat toimineet robo-neuvojien kaltaisina järjestelminä jopa onnistuen tuottamaan markkinoita paremmin tuottavia salkkuja simulaatioissa (005). Näiden sovellusten käyttäntöön vieminen edellyttää kuitenkin integraatiota olemassa oleviin pankkijärjestelmiin, kuten asiakkuudenhallintajärjestelmiin, riskienhallinta-alustoihin ja eri tiedonhallintakerroksiin. Siksi LLM- ja muiden GenAI-teknologioiden käyttöönotto linkittyy yhä useammin osaksi laajempia MLOps-kokonaisuuksia, joissa mallien koulutus, käyttöönotto ja seuranta tapahtuvat hallitusti (007)

Taulukko 5 Mahdollisuuksia suurten kielimallien käyttöön pankkisektorilla (mukaiillen 008)

Liiketoiminta- alue ja käyttö- kohde	LLM-pohjai- nen automaa- tio	Da- tanalyysi & pää- töksen- teko	Asiakasko- kemuksen parantami- nen	Riskien- hallinta & eh- käisy	Innovaatiot & teknologiake- hitys
<i>Asiakashankinta ja asiakassuhteide n hallinta</i>	Älykäs asiakas- palvelujärjes- telmä	Asiakas- tyytyväi- syyden analyysi	Asiakasseg- mentointi ja elinkaaren hal- linta	Henkilö- kohtaiset suosituk- set	Älykäs vuoro- vaikutusalusta

<i>Tilinhallinta ja asiakaspalvelu</i>	Automaattinen tiliseuranta	Tilitapah-tuma-analyysi	Virtuaaliassistentti	Henkilökohtainen asiakaspalvelu	Reaaliaikainen tiliseuranta
<i>Maksut ja selvitykset</i>	Maksuprosessin automaatio	Rajat ylittävän maksuliikenteen tuki	Maksukäyttämisen analyysi	Maksuvirtojen ennustaminen	Älykäs maksu-neuvoja
<i>Luotonhallinta</i>	Automaattinen lainapäätös	Luotonhallinnan prosessi-analyysi	Luottoriskin analyysi	Lainaris-kien ennustaminen	Dynaaminen luottoriskien hallinta
<i>Sijoittaminen ja varainhoito</i>	Sijoitusraportoinnin automaatio	Markkinatrendien analyysi	Älykäs varojen allokointi	Älykäs sijoitusneuvonta	Markkinaskenaarioiden ja riskien simulointi
<i>Riskienhallinta ja sääntely</i>	Automaattiset vaatimustenmuokausuustarkastukset	Riskiraportointi	Rahanpesun estämisen analyysi	Riskiteki-jöiden mallinnus ja analyysi	Prosessien optimointi vaatimustenmukaisuudessa
<i>Fintech ja liiketoiminnan tuki</i>	Operatiivisten prosessien automaatio	IT-tuen automatisointi	Järjestelmän suorituskyvyn seuranta ja analyysi	Datan käsittelyn optimointi	Tietoturva-avallonta

(007) Artikkelin mukaan ChatGPT voi tukea sijoitusten hallintaa analysoimalla taloudellista dataa ja tarjoamalla neuvoja sekä yrityksille että sijoittajille parempien sijoituspäätösten tekemiseksi. Mallia voidaan hyödyntää sijoitusten hallintaan keskittyvien avustusrakenteiden kehittämisessä ja sen kyvykkyyksiin kuuluu myös omaisuuden- ja salkunhallintaan liittyvien toimintojen tukeminen. Näin ollen generatiivinen tekoäly voi toimia apuvälineenä sekä strategisessa päätöksenteossa että sijoitus-toiminnan tehostamisessa (007).

Rahoitusalan erityistarpeisiin kehitetyt kielimallit (finance-specific LLMs) ovat nousseet keskeiseen asemaan monimutkaisten taloudellisten tehtävien suorittamisessa. Mallit kuten BloombergGPT, FinGPT ja FinMA on koulutettu yksinomaan rahoitusdatalla, mikä tekee niistä huomattavasti tarkempia ja tehokkaampia kuin yleiskäyttöiset LLM:t. Lisäksi multimodaaliset mallit, kuten FinVis-GPT, yhdistävät tekstin, numeerisen ja visuaalisen datan, mahdollistaen kattavamman taloudellisen analyysin. Näiden mallien suorituskykyä arvioidaan jatkuvasti erityisillä rahoitusalan benchmarkeilla (esim. FinEval, FinLMEval), jotka tukevat mallien kehitystä ja käytännön soveltamista sääntely-yhteensopivuuden näkökulmasta (005, 014).

Kirjallisuudessa generatiivisista malleista erityisesti GAN-mallit vakiinnuttaneet asemansa taloudellisen datan synteettisessä generoinnissa. Niitä on hyödynnetty esimerkiksi osakekurssien ennustamiseen (esim. LSTM-GAN), ajallisten aikasarjojen mallintamiseen (FIN-GAN) sekä sijoitusstrategi-

oiden kalibrointiin (cGAN). Lisäksi TimeGAN on osoittautunut tehokkaaksi säilyttämään moniosakeaineistojen korrelaatorakenteen. VAE-malleja on käytetty esim. PayVAE-mallissa, joka oppii maksutapahtumien ajallisen ja relationaalisen rakenteen. Uudemmat diffuusiomallit, kuten FTS-Diffusion, on kehitetty mallintamaan finanssiaikasarjojen epäsäännöllisiä ja skaalainvariantteja ilmiöitä. Näiden mallien avulla voidaan tuottaa realistista, tietosuojan säilyttävää dataa, joka tukee taloudellisten mallien kehittämistä ja testaamista ilman arkaluontoisen datan paljastamista. Tällainen synteettinen data vähentää myös regulaation aiheuttamaa pullonkaulaa reaali maailman datan käytössä (005).

(014) Agenttipohjaiset LLM-mallit tarjoavat uuden suunnan, jossa generatiivista tekoälyä voidaan hyödyntää markkinakäyttäytymisen ja taloudellisten vuorovaikutussuhteiden simulointiin. Näiden avulla voidaan tukea strategista suunnittelua ja riskienhallintaa finanssiekosysteemin tasolla (014). Lisäksi FinBERTin ja BloombergGPT:n kaltaisten erikoistuneiden mallien kehitys osoittaa suuntaa, jossa generatiiviset järjestelmät rakennetaan entistä kohdennetummiksi, ottaen huomioon finanssialan korkeat vaatimukset tarkkuuden, läpinäkyvyyden ja sääntely-yhteensopivuuden osalta (014).

4.2 Haasteet ja riskit

Generatiivisen tekoälyn käyttöönottoon finanssialalla liittyy merkittäviä riskejä ja haasteita, jotka voivat hidastaa tai jopa estää teknologian laajamittaista hyödyntämistä. Näitä voidaan tarkastella neljän keskeisen teeman kautta: ymmärtämiseen liittyvät haasteet, tietoturvariskit, infrastruktuuriin ja dataan liittyvät esteet sekä teknologian toimintavarmuuteen liittyvät ongelmat.

Tekoälyjärjestelmien toimintaperiaatteiden puutteellinen ymmärrys voi johtaa väärinkäyttöihin ja liialliseen luottamukseen mallien tuottamaan sisältöön. Kempainen (2024) nostaa esiin riskin siitä, että käyttäjät, mukaan lukien pankkien henkilöstö eivät aina ymmärrä generatiivisten mallien rajoitteita. Tämä saattaa johtaa siihen, että tekoälyratkaisuja käytetään päätöksenteossa ilman riittävää arviointia, mikä puolestaan kasvattaa virhepäätösten ja asiakasreklamaatioiden riskiä (061).

Toiseksi, tietoturvaan ja väärinkäyttöihin liittyvät riskit muodostavat keskeisen huolenaiheen. Generatiiviset mallit voivat mahdollistaa tietovuotoja tai vahingollisten viestien, kuten phishing-hyökkäysten, automatisointia (061). Esimerkiksi asiakaspalveluchatbotit voivat ilman asianmukaista suunnittelua antaa virheellisiä neuvoja tai paljastaa arkaluontoista tietoa. Samalla riski syrjivistä päätöksistä kasvaa, mikäli malleja koulutetaan epätasapainoisella tai vinoutuneella aineistolla. Tällöin vaarana on esimerkiksi epäoikeudenmukaiset luottopäätökset tai asiakkaiden eriarvoinen kohtelu.

Kolmanneksi, infrastruktuuriin ja dataan liittyvät tekniset esteet muodostavat merkittävän käyttöönoton hidasteen. Vaikka pankit vastaisivat sääntelyvaatimuksiin, GenAI-teknologioiden täysimittainen hyödyntäminen edellyttää kehittyneitä tietojärjestelmiä ja yhteensopivia malleja, joita ei ole välttämättä saatavilla kaikilla toimijoilla (002). Etenkin yhteistyöpohjaiset ratkaisut, kuten eri toimijoiden yhteinen mallikehitys, nostavat esiin kilpailuoikeudellisia, tietosuojallisia ja eettisiä kysymyksiä. Lisäksi laadukkaan koulutusdatan saatavuus ei ole tasapuolista: suuret, vakiintuneet pankit voivat

hyödyntää historiallista asiakasdataansa, kun taas pienemmät toimijat joutuvat turvautumaan heikompiin, avoimiin aineistoihin (002).

Lisäksi, teknologian toimintavarmuus ja tulosten luotettavuus ovat erityisen kriittisiä pankkialalla, jossa virheet voivat johtaa merkittäviin oikeudellisiin ongelmiin ja mainehaittoihin. Generatiiviset mallit saattavat tuottaa harhaanjohtavaa tai virheellistä tietoa, joka voi vaikuttaa asiakkaiden päätöksentekoon erityisesti haavoittuvien asiakasryhmien kohdalla. Esimerkiksi lainapäätöksiin liittyvä automatisoitu neuvonta saattaa herättää kysymyksiä vastuunjaosta: kantaako virheestä vastuun pankki vai asiakas? (002)

Lisähaasteena nousevat myös mallien tekniset rajoitteet ja resurssivaatimukset. LLM-pohjaisia moniagenttijärjestelmiä on kehitetty sijoituskäyttöön, kuten rahasto- ja osakekauppaan, mutta niiden suorituskyky vaihtelee merkittävästi kielestä ja datasta riippuen. Esimerkiksi suorituskyky heikkenee matalan resurssin kielillä, mikä rajoittaa teknologian tasa-arvoista käyttöä (005). Lisäksi korkea GPU-muistin tarve asettaa haasteita erityisesti pienemmille toimijoille ja on herättänyt kiinnostusta tehokkaampien esikoulutusmenetelmien kehittämiseen (005).

Haasteiden hallintaan ehdotetaan kirjallisuudessa useita toimenpiteitä. Kempainen (2024) korostaa algoritmien jatkuvaa päivittämistä, koulutusdatan laadun varmistamista ja organisaation sisäistä koulutusta. Riskienhallinnan tulee olla koko pankkiorganisaation yhteinen tehtävä. Ei ainoastaan teknisen henkilöstön vastuulla. Lisäksi GenAI-sovellusten vaikutuksia suositellaan seurattavaksi järjestelmällisesti, osana pankin yleistä hallintamallia ja vastuullisuuskehystä (061). Kempainen esittää tutkielmassaan tekoälyn riskien jakaantumisen pankkialalla seuraavasti:



Kuva 3. Vastauksissa esiin tulleet riskit

Kuvio 11 Tekoölyyn liittyvien riskien jakautuminen Finanssialan ammattilaisten näkökulmasta (N=4, 061)

4.2.1 Sääntelyn ja tietosuojan kysymykset

Generatiivisen tekoälyn käyttöönotto finanssialalla tuo mukanaan monisyisiä sääntely- ja tietosuoja-haasteita, jotka edellyttävät sekä teknologisia että hallinnollisia ratkaisuja. Pankkien tulee toimia lukuisten kansallisten ja kansainvälisten sääntelykehysten rajoissa ja samaan aikaan varmistaa vastuullinen, läpinäkyvä ja eettinen tekoälyn hyödyntäminen. Kirjallisuudessa korostuu, että sääntely ei ole ainoastaan compliance-kysymys, vaan edellytys teknologian tuotantokäytölle.

Ensinnäkin sääntelyyn liittyvät hallintorakenteet ja tekniset kontrollit nousevat keskeiseen rooliin GenAI:n käyttöönotossa. McKinsey painottaa mallien selitettävyyttä, hallusinaatoriskin torjuntaa, IP-oikeuksien kunnioittamista ja audit trail -ratkaisujen hyödyntämistä (047). Myös mallihallinnan rakenteet ja valvontamekanismit (esim. riskikehykset ja komiteat) ovat tärkeitä, jotta sääntelyn mukaisuus varmistetaan jo operatiivisen mallisuunnittelun tasolla (048). Accenture nostaa vastuullisen tekoälyn (engl. Responsible Artificial Intelligence, RAI) strategiseksi kysymykseksi, joka kytkeytyy paitsi sääntelyyn, myös brändipääomaan ja luottamukseen. RAI-kehysten avulla voidaan hallita muun muassa hallusinaatioita, IP-riskejä ja ESG-vaikutuksia (053).

Lisäksi sääntelyyn liittyy käytötapaakohtaisia kysymyksiä, kuten sijoitusneuvontaa koskevien lakien soveltaminen robo-neuvojen toimintaan (005), tekoälyn oikeudellinen vastuu (007) ja LLM-mallien käsittelemän säännellyn datan, kuten asiakas- ja luottotietojen, suojaaminen (008, 009). Artikkelit nostavat esiin riskin siitä, että tekoälyjärjestelmät käsittelevät tietoja tavalla, joka ei ole täysin yhteensopiva GDPR:n ja rahoitusalan erityissääntelyn kanssa. Tämä koskee erityisesti avoimia, julkisia malleja, joiden käyttöä pankit ovat rajoittaneet tietovuotoriskien vuoksi (033). Ratkaisuina esitetään mm. salaus, anonymisointi, käyttöoikeuksien rajoittaminen ja valvonta (008), sekä suljettujen mallien käyttö ja versionhallittu audit trail (033).

Sääntelyn kehitysvaihe ja institutionaalinen epäselvyys vaikeuttavat laajamittaista käyttöönottoa. EU:n AI Act, GDPR, DORA ja muut säädökset muodostavat sääntelykehiksen, mutta niiden soveltaminen generatiiviseen tekoälyyn on vielä monelta osin jäsentymätöntä (016, 029). Artikkelit korostavat tarvetta selkeille sääntelylinjauksille, jotka yhdistävät teknologisen innovoinnin ja kuluttajansuojan (014, 015). Erityisesti korkean riskin käyttötapauksissa, kuten luottokelpoisuuden arvioinnissa ja sijoitusneuvonnassa, tarvitaan läpinäkyvyyttä, selitettäviä päätöksiä (viittaa engl. Explainable AI, XAI) ja tarkkaa dokumentointia (030, 031).

Esiin nousee myös tekoälyn rooli sääntelyn tukemisessa ja valvonnassa. LLM-malleja ja RAG-menetelmiä voidaan hyödyntää esimerkiksi sääntelyteksteihin vastaamisessa, auditointidokumenttien automatisoinnissa tai sisäisten tarkastusprosessien tukena (014, 023). Artikkelit nostavat esiin myös sääntelyviranomaisten kiinnostuksen GenAI:n hyödyntämiseen omassa valvontatyössään, mikä viittaa sääntelyn digitalisoitumiseen (013). Kehitys kulkee suuntaan, jossa generatiivinen tekoäly voi toimia sekä sääntelyhaasteiden aiheuttajana että niiden ratkaisemisen työkaluna.

Viidenneksi esille nousevat eettiset ja institutionaaliset riskit, kuten vastuunjako, syrjintä, deepfaket, energiankulutus ja mallien vinoumat. Artikkelit painottavat, että GenAI:n käyttö päätöksenteossa, kuten luottopäätöksissä, ei saa tapahtua ilman ihmiskontrollia ja selitettävyyttä (015, 027, 056). Kansainväliset viitekehykset, kuten NIST AI RMF ja AI-EOU, sekä käytännöt kuten sääntelyhiekkalaatikat, tukevat eettisesti kestävästä käyttöönottoa (055, 056). Samalla korostetaan tarvetta seurata kolmansien osapuolien riskejä, erityisesti silloin kun pankit eivät kehitä malleja itse (055).

Teknologiset ratkaisut, kuten synteettisen datan luonti (045), parametritehokas hienosäätö (engl. parameter-efficient fine-tuning) (034) ja selitettävät AI-menetelmät (030), tarjoavat keinoja sääntelyvaatimusten täyttämiseen teknisesti tehokkaasti. Kuitenkin sääntelyviranomaisten hyväksyntä edellyttää, että järjestelmien hallittavuus, läpinäkyvyys ja jäljitettävyyden on rakennettu osaksi koko AI-governance-arkkitehtuuria (049, 050, 054).

4.2.2 *Eettiset haasteet*

Generatiivisen tekoälyn käyttöönotto pankkialalla edellyttää huolellista eettistä ja yhteiskunnallista arviointia. Vaikka teknologia tarjoaa huomattavia mahdollisuuksia esimerkiksi asiakasviestinnän ja analytiikan kehittämisessä, siihen liittyy myös keskeisiä riskejä liittyen tietosuojongelmiin, vastuukysymykset ja väärinkäytösten mahdollisuus. Tutkimuksissa on korostettu tarvetta sektorikohtaisille eettisille ohjeistuksille, turvallisen datan käytölle sekä suljettuihin ympäristöihin perustuville teknisille ratkaisuilla, jotka tukevat läpinäkyvää ja vastuullista tekoälyn hyödyntämistä (005).

Yksi keskeisimmistä eettisistä haasteista liittyy algoritmisten mallien vinoumiin. LLM-mallit voivat vahvistaa koulutusdatan sisältämiä rakenteellisia vääristymiä, mikä voi johtaa epäoikeudenmukaisiin päätöksiin esimerkiksi asiakassegmentoinnissa, luotonmyöntämisessä tai riskien arvioinnissa (008). Tällaiset päätökset voivat vaarantaa yhdenvertaisen kohtelun ja johtaa juridisiin seuraamuksiin, erityisesti tilanteissa, joissa syrjintä kohdistuu sukupuolen, etnisen taustan tai sosioekonomisen aseman perusteella (019, 025, 028). Ongelmien hallinta edellyttää läpinäkyvien dokumentointikäytäntöjen käyttöönottoa, vinoumien järjestelmällistä tunnistamista ja avointa viestintää mallien päätöksentekoprosesseista niin asiakkaille kuin valvontaviranomaisille (008).

Toinen laajasti tunnistettu eettinen kysymys koskee generatiivisten mallien selitettävyyttä. Useat generatiivisen tekoälyn ratkaisut toimivat niin sanotun "musta laatikko" -logiikan (engl. black box) mukaisesti, mikä vaikeuttaa päätösten perustelemista ja auditoitavuutta (001, 005, 016, 029). Tämä läpinäkyvyyden puute voi horjuttaa asiakkaiden luottamusta, hidastaa viranomaishyväksyntää ja estää virheellisten päätösten korjaamisen ajoissa (020, 040). Erityisesti asiakaspalvelussa ja lainapäätöksenteossa päätösten ymmärrettävyys on olennainen osa eettistä vastuullisuutta (060).

Kolmas merkittävä teema liittyy tietosuojaan. Generatiiviset mallit käsittelevät usein laajoja määriä arkaluonteista tietoa, kuten asiakasprofiileja ja luottotietoja, mikä altistaa ne tietovuodoille ja väärinkäytöksille (002, 004, 008, 023). Erityisesti väärin konfiguroidut tai avoimet järjestelmät voivat

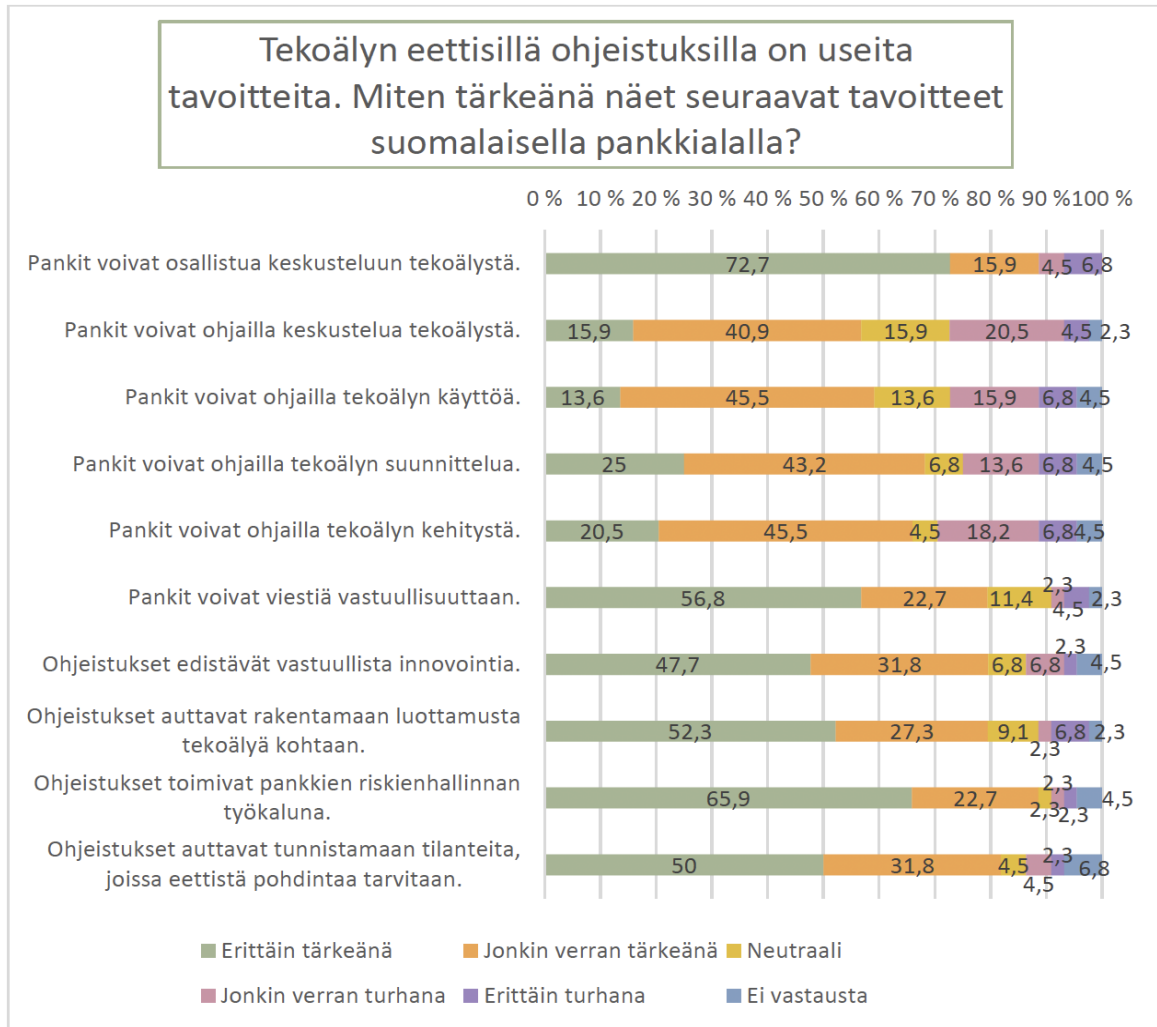
vahingossa paljastaa luottamuksellista dataa, mikä rikkoo sekä asiakkaiden luottamusta että sääntelyä, kuten GDPR:ää (009, 031). Tietosuojaan turvaaminen vaatii teknisiä toimenpiteitä, kuten tietojen anonymisointia, käyttöoikeuksien hallintaa ja valvottuja infrastruktuureja.

Eettinen vastuunjako nousee esiin erityisesti tilanteissa, joissa generatiivinen malli tuottaa virheellistä tai syrjivää tietoa. Vastuukysymys jää helposti epäselväksi: kantavatko seuraukset pankki, järjestelmän kehittäjä vai loppukäyttäjä (007, 015, 062)? Tämä häilyvyys edellyttää organisaatioilta selkeitä toimintaperiaatteita ja valvontakäytäntöjä, jotka määrittelevät vastuun jakautumisen eri toimijoiden kesken (023, 050).

Eettisiä huolia liittyy myös sääntelyn noudattamiseen. Finanssiala toimii vahvasti säännellyssä ympäristössä ja esimerkiksi GDPR, MiFII ja AI Act asettavat generatiiviselle tekoälylle korkeita vaatimuksia (001, 004, 009, 061). Monissa tutkimuksissa korostetaan, että nykyinen sääntelykehikko ei kaikilta osin vastaa GenAI:n erityispiirteisiin, mikä lisää epävarmuutta ja voi hidastaa teknologian vastuullista käyttöönottoa (005, 014, 032).

Näihin kysymyksiin on pyritty vastaamaan myös suomalaisessa kontekstissa. Pauliina Tuusan opinnäytetyö (060) esittelee viitekehyksen, jossa GenAI:n käyttöä ohjaavat viisi periaatetta: läpinäkyvyys ja selitettävyyys, oikeudenmukaisuus ja tasa-arvo, vahingon välttäminen, vastuullisuus ja yksityisyys. Työssä painotetaan erityisesti organisatorista sitoutumista jatkuvaa arviointia ja eettisiä auditointeja. Tietosuoja nähdään olennaisena ja korostetaan, ettei asiakasdataa tule käyttää koulutusmateriaalina ilman lainmukaista suojaa ja perustetta. Eettisten periaatteiden systemaattinen soveltaminen nähdään edellytyksenä GenAI:n hyväksyttävälle ja kestävästi skaalattavalle käyttöönotolle suomalaisissa pankeissa.

Aineistosta käy selväksi, että GenAI:n eettinen hyödyntäminen pankkisektorilla edellyttää selkeitä sääntöjä, läpinäkyvää teknologiaa ja jatkuvaa valvontaa. Kestävä käyttöönotto edellyttää myös, että teknologian kehittäjät, käyttäjät ja sääntelyviranomaiset toimivat yhteistyössä eettisesti hyväksyttävän ja oikeudellisesti kestävä toimintaympäristön varmistamiseksi. Kuviossa 12 (Tuusa, 2025) esitetään, että vaikka pankkien asiakkaat pitävät tärkeänä että pankit voivat osallistua tekoälyn käyttöön liittyvään keskusteluun, niille ei haluta antaa liikaa vaikutusvaltaa itse kehityksen suuntaamiseen. Tämä osoittaa tarpeen vahvemmalle yhteiselle ohjaukselle ja vuoropuhelulle.



Kuvio 12 Pankkiasiakkaiden näkemys tekoälyn eettisten ohjeistuksien tärkeydestä (061)

4.2.3 Teknologiset rajoitukset

Generatiivisen tekoälyn käyttöönotto pankkisektorilla kohtaa useita merkittäviä teknologisia haasteita, jotka liittyvät erityisesti datan laatuun, mallien suorituskykyyn, järjestelmien yhteentoimivuuteen ja mallien selitettävyyteen. Korkealaatuisen ja riittävän laajan datan saatavuus on keskeinen edellytys generatiivisten mallien kouluttamiselle. Tässä suhteessa erityisesti pienemmät ja uudemmat toimijat kärsivät datan hajanaisuudesta, puutteellisesta kattavuudesta ja rajallisesta pääsystä luotettaviin lähteisiin (002, 003). Vaikka suuremmilla pankeilla on usein pitkät historiatiedot käytettävissä,

uusilla toimijoilla on usein käytössään vain avoimia tietolähteitä, jotka eivät aina täytä mallien koulutukselle asetettuja vaatimuksia. Lisäksi pankkien välinen datayhteistyö on rajallista, mikä johtuu osin kilpailullisista ja eettisistä huolista (010).

Toinen keskeinen teknologinen haaste liittyy generatiivisten mallien integroimiseen olemassa oleviin pankkijärjestelmiin. Monet pankit hyödyntävät edelleen vanhentuneita IT-ympäristöjä, jotka eivät ole yhteensopivia nykyaikaisten tekoälyratkaisujen kanssa. Tämä aiheuttaa suuria haasteita järjestelmien teknisessä yhteensopivuudessa ja edellyttää usein kalliita ja aikaa vieviä päivityksiä, jotka voivat hidastaa teknologian käyttöönottoa (004, 005, 011). Infrastruktuuriin liittyvät puutteet vaikuttavat suoraan tekoälyn skaalautuvuuteen ja operatiiviseen hyötyyn (029).

Lisäksi ongelmana on aiemminkin mainittu "musta laatikko" -logiikka eli selitettävyyden puute. Monimutkaiset LLM-mallit, kuten GPT-pohjaiset järjestelmät, tuottavat vastauksia, joiden taustalla oleva päättelyketju ei ole helposti ymmärrettävissä. Tämä muodostaa esteen tekoälyn hyväksynnälle erityisesti korkean vaatimustason prosesseissa, kuten luottopäätöksenteossa, riskienhallinnassa ja sääntelyraportoinnissa, joissa päätösten perustelujen tulee olla jäljitettävissä ja läpinäkyviä (020, 023). Mallien selitettävyyttä parantavien tekniikoiden, kuten XAI- ja human-in-the-loop -lähestymistapojen, tarve on erityisen kriittinen pankkitoiminnassa (014).

Myös mallien laskennalliset ja operatiiviset rajoitteet muodostavat merkittävän esteen käyttöönotolle. LLM-mallit vaativat suuria määriä laskentatehoa ja energiaa, mikä tekee niiden käytöstä haasteellista erityisesti pienemmille toimijoille, joilla ei ole omia datakeskuksia tai riittäviä resursseja skaalautuvan teknologian ylläpitoon (047). Tämän vuoksi osa pankeista suosii pilvipalveluja, mutta se puolestaan nostaa esiin kysymyksiä tietosuojasta, riippuvuudesta ulkoisiin toimijoihin ja pitkän aikavälin kustannustehokkuudesta (008).

Yksi erityisen haitallinen teknologinen riski liittyy niin sanottuihin hallusinaatioihin eli tilanteisiin, joissa malli tuottaa virheellistä tai täysin keksittyä tietoa ilman vastaavuutta todellisuuteen. Tämä on kriittinen haaste finanssialalla, jossa virheelliset tiedot voivat johtaa vakaviin asiakas-, sääntely- tai investointivirheisiin (007, 016, 045). Vaikka RAG-menetelmät ja palautepohjainen mallikehitys voivat vähentää hallusinaatioiden riskiä, niiden torjuminen vaatii jatkuvaa tutkimusta ja mallien huolellista validointia (005).

Lisähaasteena on reaaliaikaisen tiedonkäsittelyn rajoitteet. Monet generatiiviset mallit eivät pysty itsenäisesti prosessoimaan tuoretta markkinadataa ilman ulkoisia integraatioita tai teknisiä tukirakenteita. Tämä rajoittaa niiden käyttöä sovelluksissa, joissa nopeus ja ajantasaisuus ovat kriittisiä, kuten kaupankäynti, sääntelymuutosten seuranta tai poikkeamanalyysi (010, 027).

teknologiset rajoitteet pankkisektorilla eivät liity ainoastaan yksittäisiin teknisiin ominaisuuksiin, vaan muodostavat laaja-alaisen haastekokonaisuuden. Näiden ongelmien ratkaiseminen vaatii merkittäviä investointeja datan hallintaan, infrastruktuurin modernisointiin, mallien selitettävyyteen ja käyttöönottoprosessien standardointiin. Lisäksi tarvitaan tiivistä yhteistyötä teknologiatoimittajien ja sääntelyviranomaisten kanssa, jotta generatiivisen tekoälyn mahdollisuudet voidaan hyödyntää turvallisesti ja tehokkaasti (001, 050, 051).

4.3 Mahdollisuudet ja tulevaisuuden näkymät

Generatiivisen tekoälyn kehitys avaa tulevaisuudessa pankkisektorilla monipuolisia ja laajavaikutteisia mahdollisuuksia, erityisesti asiakaspalvelun, päätöksenteon tuen, riskienhallinnan ja liiketoimintaprosessien automatisoinnin saralla. Yksi keskeisimmistä tulevaisuuden näkymistä liittyy GenAI:n ja big datan yhdistämiseen, jonka myötä voidaan kehittää entistä tarkempia ja reaaliaikaisempia riskienhallintamalleja. Näillä voidaan arvioida esimerkiksi luottoriskiä ja markkinariskiä aiempaa täsmällisemmin analysoimalla jatkuvasti päivittyvää, laajamittaista tietoa (003, 005). Samalla pankkien käyttämättömiä laskentaresursseja voidaan hyödyntää jatkuvaan mallien oppimiseen ja lokitietojen analysointiin, mikä lisää prosessien joustavuutta ja tehokkuutta (005).

Teknologinen kehitys tukee erityisesti suurten kielimallien (LLM) ja generatiivisten mallien integrointia pankkien data-alustoihin. Tekoälyllä voidaan automatisoida asiakaspalvelun toistuvia tehtäviä, tarjota personoituja suosituksia, tuottaa reaaliaikaisia vastauksia ja tulkita asiakaskyselyitä luonnollisen kielen ymmärryksen avulla (004, 006, 007, 019). Kehittyvä kontekstuaalinen kyvykkyys ja multimodaalisuus eli tekstin, puheen ja kuvien yhdistäminen mahdollistavat entistä älykkäämmän vuorovaikutuksen asiakasrajapinnoissa (018, 045).

Toinen merkittävä suuntaus liittyy agenttipohjaiseen tekoälyyn (Agentic AI), joka kykenee suorittamaan itsenäisiä, tavoitteisiin sidottuja tehtäviä, kuten sijoitussalkkujen jatkuvaa optimointia tai epäilyttävien transaktioiden monitorointia (019, 031). GenAI:lla on myös potentiaalia pääomamarkkina-analysissä, synteettisen koulutusdatan luomisessa ja sisäisen tiedonhallinnan tehostamisessa erityisesti tilanteissa, joissa datasiiloja on purettava organisaation sisällä (020, 025, 035). Teknologisesta näkökulmasta tulevaisuus tuo mukanaan mahdollisuuksia hajautettujen pilvialustojen (engl. multi-cloud) hyödyntämiseen, spesifien GPT-versioiden käyttöönottoon ja yrityskohtaisesti räätälöityjen mallien rakentamiseen, jotka samalla täyttävät sääntelyn, tietosuojan ja tietoturvan vaatimukset (010, 045, 046). Lisäksi tekoälyn integrointi regtech-ratkaisuihin ja ESG-tavoitteisiin mahdollistaa uudenlaista vastuullista pankkitoimintaa ja läpinäkyvämpää päätöksentekoa (056, 058).

GenAI ei ainoastaan tehosta olemassa olevia prosesseja, vaan mahdollistaa kokonaan uusia liiketoimintamalleja. Tämä voi näkyä esimerkiksi reaaliaikaisina sijoitusneuvojina, automaattisina sääntelyraportteina, riskienhallintajärjestelmissä tai skaalautuvina päätöksenteon tukialustoina, jotka muuttavat koko pankkitoiminnan arkkitehtuuria (001, 014, 054).

Kaiken kaikkiaan generatiivinen tekoäly näyttää paitsi tehokkuuden ja tuottavuuden lisääjänä, myös strategisena työkaluna pankkitoiminnan uudelleenmuotoilussa. Sen tulevaisuuden mahdollisuudet riippuvat kuitenkin pitkälti siitä, kuinka hyvin teknologiainfrastruktuurit, sääntelykehykset ja eettiset valmiudet kehittyvät teknologian rinnalla.

Shalinin ja Bagrechan (2023) tutkimuksessa selvitettiin kuluttajien näkemyksiä generatiivisen tekoälyn käyttöönoton aikataulusta pankkisektorilla. Vaikka vastaajajoukko oli rajallinen ja kerätty

mukavuusotannalla, tulokset antavat viitteitä siitä, miten teknologian omaksumista ajallisesti hahmotetaan suurkaupunkien pankkiasiakkaiden keskuudessa Intiassa. Yli puolet kyselyyn vastanneista on sitä mieltä, että generatiivisen tekoälyn ratkaisut pitäisi näkyä pankeissa mahdollisimman pian. (031)



Kuvio 13 Kuluttajien näkemys siitä, milloin generatiivinen tekoäly tulisi ottaa käyttöön pankkisektorilla (n=51) (031)

4.3.1 Strateginen hyöty pankkialalla


Generatiivinen tekoäly tarjoaa pankkisektorille useita strategisia hyötyjä, jotka liittyvät erityisesti tehokkuuden parantamiseen, palveluiden personointiin, kilpailukyvyn vahvistamiseen ja innovaatioiden mahdollistamiseen. Tärkeimpiä etuja on operatiivisten prosessien automatisointi, joka vähentää manuaalisen työn tarvetta ja parantaa tuottavuutta. Generatiivista tekoälyä hyödyntämällä voidaan automatisoida asiakaspalvelun rutiinitehtäviä ja taustajärjestelmien toimintoja, mikä johtaa merkittäviin kustannussäästöihin ja palvelun nopeutumiseen (002, 003, 004).

Tekoälyn kyky luoda asiakassegmenttejä ja analysoida käyttäytymismalleja mahdollistaa tarkemman ja vaikuttavamman asiakasviestinnän. Tämä tukee asiakastyytyväisyyden ja -uskollisuuden kasvua personoitujen palvelujen avulla (005, 006). Personointi ei rajoitu pelkästään viestintään, vaan ulottuu myös tuotteiden ja suositusten räätälöintiin, esimerkiksi automaattisesti mukautuviin säästö- tai sijoitusratkaisuihin, joita asiakkaalle voidaan tarjota reaaliaikaisesti (007, 008). Lisäksi pankit voivat hyödyntää generatiivista tekoälyä kehittääkseen alakohtaisia kielimalleja, jotka tarjoavat syvällisiä näkemyksiä strategiseen päätöksentekoon ja riskienhallintaan. Tällainen tietopohjainen johtaminen voi tukea pankin kilpailuasemaa erityisesti nopeasti muuttuvilla markkinoilla (010, 015). Tutkimukset osoittavat, että tekoäly voi parantaa luottoriskien arviointia merkittävästi ja nopeuttaa lainapäätöksiä jopa 70 % verrattuna perinteisiin menetelmiin. Samalla osa lähteistä ennustaa tekoälyn

mahdollistavan jopa 340 miljardin dollarin vuotuisen lisäarvon pankkialalle maailmanlaajuisesti vuoteen 2030 mennessä (029).

Tulevaisuuteen suuntautuen generatiivinen tekoäly toimii myös innovaation ajurina: se mahdollistaa uusien palveluiden kehittämisen, kuten reaaliaikaiset taloudelliset neuvontaratkaisut tai täysin automatisoidut digitaalisen pankkitoiminnan mallit (014, 018, 045). Tällaiset ratkaisut eivät ainoastaan vastaa asiakkaiden odotuksiin, vaan myös laajentavat pankkien toimintakenttää uusille asiakassegmenteille ja liiketoiminta-alueille. Kokonaisuutena generatiivinen tekoäly ei ainoastaan tehosta olemassa olevia prosesseja, vaan luo rakenteellista kilpailuetua pankkisektorille pitkällä aikavälillä.

Accenture (2024) arvioi pankkialan tärkeimpien kahdenkymmenen tehtävän tai roolin hyötymistä generatiivisesta tekoälystä tulevaisuudessa seuraavasti:



Kuvio 14 Kuinka pankkialan tärkeimmät 20 työtehtävää tulevat hyötymään generatiivisesta tekoälystä (Accenture (053))

4.3.2 Kilpailukyvyn parantaminen

Generatiivisen tekoälyn hyödyntäminen pankkisektorilla tarjoaa konkreettisia ja mitattavia kilpailuetuja, jotka tukevat pankkien asemaa nopeasti muuttuvassa ja digitaalisessa toimintaympäristössä. Yksi merkittävimmistä eduista on operatiivisen tehokkuuden parantuminen: tekoälyn käyttöönoton on havaittu vähentävän manuaalisten prosessien käsittelyaikaa jopa 28 % ja lisäävän kokonaistuottavuutta 35 %:lla, mikä mahdollistaa resurssien uudelleensuuntaamisen strategisiin tehtäviin (003). Tämän lisäksi generatiivinen tekoäly tukee päätöksenteon laatua ja nopeutta, erityisesti riskienhallinnassa: kehittyneiden mallien, kuten käyttö on pienentänyt virhemarginaaleja 18 % ja arviointivirheitä on saatu vähennettyä 20 % verrattuna perinteisiin riskimalleihin (003, 015).

Kilpailukyvyn vahvistumista edistää myös generatiivisen tekoälyn ja big datan välinen synergia. Ennusteiden tarkkuus on kasvanut jopa 40 %, mikä antaa pankeille etulyöntiaseman markkinatilanteiden ennakoinnissa ja asiakastarpeiden ymmärtämisessä (003, 018). Tämä mahdollistaa paitsi parempien päätösten tekemisen myös uusien markkinasegmenttien tavoittamisen aiempaa tarkemmin kohdistetuilla palveluilla (004, 006).

Taloudellisesti tekoälyn kilpailukykyhyödyt ovat merkittäviä: tekoälyä hyödyntävien yritysten on raportoitu olevan keskimäärin 15 % kannattavampia kuin kilpailijansa ja Generatiivisen tekoälyn odotetaan tuottavan pankkisektorille yli 140 miljardin dollarin vuotuisen lisäarvon vuoteen 2025 mennessä (004, 031). Lisäksi sen avulla pankit voivat tuottaa nopeammin uusia tuotteita ja palveluita, esimerkiksi reaaliaikaisia neuvontaratkaisuja ja täysin automatisoituja asiakaspalvelukanavia, jotka skaalautuvat helposti ja erottuvat kilpailijoiden tarjonnasta (007, 014, 045).

Tehokkuus, tarkkuus, innovatiivisuus ja taloudellinen lisäarvo muodostavat yhdessä strategisen kokonaisuuden, jonka avulla pankit voivat parantaa markkina-asemaansa, erottua kilpailijoistaan ja vastata entistä ketterämmin asiakasodotuksiin sekä sääntelyvaatimuksiin. Generatiivisen tekoälyn hyödyntäminen ei ole vain teknologinen päivitys, vaan se toimii kilpailukyvyn rakenteellisena vahvistajana koko pankkitoiminnan tasolla.

5 TULOSTEN POHDINTA

Tässä luvussa tarkastellaan tutkimuksen tuloksia suhteessa aiempaan kirjallisuuteen sekä arvioidaan löydösten merkitystä pankkisektorin kannalta. Lisäksi pohditaan tutkimuksen rajoitteita ja nostetaan esiin kehityskohteita generatiivisen tekoälyn hyödyntämisessä pankkialalla.

Tutkimuksen systemaattinen kirjallisuuskatsaus osoitti, että generatiivisen tekoälyn soveltaminen pankkisektorilla painottuu erityisesti asiakaspalvelun parantamiseen, riskienhallinnan ja petostentunnistuksen kehittämiseen sekä operatiivisen tehokkuuden lisäämiseen. Näitä teemoja tukee myös aiempi tutkimus ja alan raportit, joissa korostetaan tekoälyn kykyä tuoda lisäarvoa pankkien toimintaan automatisoimalla rutiiniprosesseja, tehostamalla tiedonkäsittelyä ja mahdollistamalla persoonallisia asiakaspalveluratkaisuja. Aineistoon valikoituneet tutkimukset vahvistivat, että pankit, jotka ottavat generatiivisen tekoälyn osaksi ydintoimintojaan, voivat saavuttaa merkittäviä säästöjä ja kilpailuetua.

Merkittävänä havaintona voidaan pitää sitä, että vaikka generatiivisen tekoälyn käyttöönottoon liittyy merkittäviä mahdollisuuksia, sen soveltaminen ei ole ongelmaton. Tulokset osoittavat, että erityisesti tietosuojan ja sääntelyn kysymykset, kuten GDPR:n ja muiden kansainvälisten standardien noudattaminen, muodostavat merkittävän esteen laajamittaiselle käyttöönotolle. Eettiset kysymykset, kuten algoritmien läpinäkyvyys, päätöksenteon oikeudenmukaisuus sekä syrjinnän ja vinoumien riski, ovat myös keskeisiä haasteita, joita pankkien tulee huomioida. Aineiston perusteella nämä riskit korostuvat erityisesti lainapäätösten ja muiden kriittisten prosessien automatisoinnissa.

Pankkisektorin erityispiirteenä on tiukka sääntely-ympäristö, joka ohjaa vahvasti teknologian käyttöä. Tulosten perusteella voidaan todeta, että useissa tutkimuksissa korostui tarve kehittää pankkien sisäisiä prosesseja ja osaamista niin, että uudet teknologiat voidaan ottaa käyttöön hallitusti ja vastuullisesti. Vaikka generatiivinen tekoäly voi tuoda pankkisektorille huomattavia tehokkuusparannuksia ja avata uusia liiketoimintamahdollisuuksia, teknologian hyödyntäminen vaatii johdonmukaista riskienhallintaa sekä henkilöstön koulutusta ja osaamisen kehittämistä.

Huomiota ansaitsee myös se, että aineiston analyysi toi esiin myös ristiriitaisuuksia ja epävarmuustekijöitä. Joissakin tutkimuksissa korostettiin generatiivisen tekoälyn mahdollisuuksia laaja-alaisesti, mutta toisaalta osa lähteistä suhtautui varauksellisemmin teknologian kypsytyteen ja valmiuteen käytännön sovelluksissa. Joidenkin lähteiden mukaan teknologian nopea kehitys voi johtaa tilanteeseen, jossa käytännön implementoinnin esteet, kuten tietoturva ja regulaation hitaus, hidastavat hyötyjen realisoitumista. Tämä havainto korostaa, että vaikka generatiivisen tekoälyn tutkimus on vilkasta, osa ratkaisumalleista on vasta kehitysvaiheessa ja vaatii jatkotutkimusta.

Tutkimuksen rajoitteena on se, että suuri osa aineistosta keskittyy lyhyen ja keskipitkän aikavälin vaikutuksiin, ja pitkäaikaisvaikutuksista on saatavilla vain vähän empiiristä tietoa. Lisäksi osa aineistosta perustuu harmaaseen kirjallisuuteen, mikä voi vaikuttaa tulosten yleistettävyyteen ja tieteelliseen arvioitavuuteen. Tästä huolimatta systemaattisen kirjallisuuskatsauksen avulla on voitu muodostaa kattava kokonaiskuva generatiivisen tekoälyn nykytilasta ja kehityssuunnista pankkisektorilla.

6 JOHTOPÄÄTÖKSET

Tässä luvussa esitetään tutkimuksen keskeiset johtopäätökset ja vastataan asetettuihin tutkimuskysymyksiin. Lisäksi arvioidaan työn tieteellistä kontribuutiota, esitetään käytännön suosituksia pankkisektorin toimijoille sekä tarkastellaan tutkimuksen rajoitteita. Luvun lopussa pohditaan mahdollisia jatkotutkimuksen suuntaviivoja, joita tämän tutkimuksen havainnot ja rajoitteet tuovat esiin. Luvun tavoitteena on kiteyttää tutkimuksen tärkeimmät löydökset sekä osoittaa, millä tavoin työ edistää ymmärrystä generatiivisen tekoälyn roolista ja soveltamisesta pankkitoiminnassa.

6.1 Tutkimuksen päätelmät ja kontribuutio

Tämän tutkimuksen perusteella generatiivisen tekoälyn käyttöönotto pankkisektorilla on jo lyhyellä aikavälillä mahdollistanut uusia tapoja tehostaa operatiivisia prosesseja, parantaa asiakaskokemusta ja kehittää pankkien riskienhallintaa. Keskeisimmät käyttökohteet ovat asiakaspalvelun automatisointi, petostentunnistus sekä päätöksenteon ja raportoinnin tukeminen. Tutkimusaineiston perusteella generatiivinen tekoäly voi auttaa pankkeja paitsi säästämään kustannuksia, myös kehittämään kokonaan uusia palvelumalleja ja lisäämään strategista joustavuutta.

Toisaalta tulokset osoittavat, että teknologian käyttöönottoon liittyy merkittäviä haasteita erityisesti tietosuojan, sääntelyn ja eettisten kysymysten osalta. Pankkien on panostettava osaamiseen ja prosessien kehittämiseen, jotta teknologiaa voidaan hyödyntää vastuullisesti. Tutkimus osoittaa, että generatiivisen tekoälyn menestyksekkäs käyttöönotto vaatii jatkuvaa kehitystyötä, tiivistä yhteistyötä regulaattoreiden kanssa sekä selkeiden eettisten periaatteiden määrittelyä.

Tieteellisen tutkimuksen kannalta työ tarjoaa systemaattisen yhteenvedon generatiivisen tekoälyn soveltamisen mahdollisuuksista ja haasteista pankkisektorilla. Tutkimus täydentää aiempaa kirjallisuutta kokoamalla alan ajantasaiset näkemykset ja nostamalla esiin pankkikohtaisia erityispiirteitä, kuten sääntelyn vaikutuksen teknologian käyttöönottoon. Työssä tunnistetaan myös keskeisiä epävarmuustekijöitä ja kehityskohteita, mikä tarjoaa hyvän pohjan jatkotutkimukselle.

Keskeisimmät generatiivisen tekoälyn sovelluskohteet, sidosryhmät ja niihin liittyvät vaikutukset pankkisektorilla on tiivistetty Kuvioon 4. Tämä käsitekehys havainnollistaa, miten eri toimijat, data ja teknologiset ratkaisut kytkeytyvät toisiinsa ja millaisia tuloksia GenAI:n hyödyntäminen voi tuottaa pankkitoiminnassa. Kuvio kokoaa yhteen tutkimuksessa analysoidut eri vaikutukset ja jäsentää niitä selkeästi pankkisektorin toimintaympäristössä.

6.2 Käytännön suositukset pankkisektorille

Generatiivisen tekoälyn käyttöönotto pankkisektorilla edellyttää huolellista vaiheittaista suunnittelua, jossa teknologiset, organisatoriset ja eettiset näkökohdat yhdistetään toisiaan tukevaksi kokonaisuudeksi. Vuonna 2025 teknologian kehitys on saavuttanut tason, jolla pankit voivat harkita useita käytännön sovelluksia, mutta onnistunut käyttöönotto edellyttää tarkkaa kontekstin, käyttötarkoituksen ja riskien arviointia.

Ensivaiheessa suositellaan keskityttäväksi sisäisiin käyttökohteisiin, joissa generatiivinen tekoäly voi tuoda tehokkuusetuja ilman merkittäviä tietosuojai- tai asiakasluottamukseen liittyviä riskejä. Tällaisia ovat esimerkiksi sisäisten dokumenttien tuottaminen ja tiivistäminen, raportoinnin automatisointi sekä luonnostekstien laatiminen tukiprosesseissa. Näissä tilanteissa voidaan hyödyntää laajoja kielimalleja, joita ajetaan suljetuissa ympäristöissä tai jotka toimivat tarkasti rajatun tietopohjan varassa. Tällainen lähestymistapa mahdollistaa teknologian testaamisen hallitusti ja madaltaa käyttöönoton kynnyksiä. Seuraavassa vaiheessa käyttöä voidaan laajentaa asiakaspalvelun tueksi. Chatbotit, jotka hyödyntävät luonnollisen kielen prosessointia, voivat tukea asiakaspalvelijoita esimerkiksi vastaamalla usein kysyttyihin kysymyksiin, tuottamalla alustavia viestejä tai tarjoamalla suosituksia. Tärkeää on, että näiden järjestelmien tuottama sisältö on läpinäkyvää ja että asiakkaille kerrotaan selkeästi, milloin he ovat vuorovaikutuksessa tekoälyn kanssa. Järjestelmien tulee toimia rajatulla autonomia-asteella ja niiden antama tieto tulee voida tarvittaessa jälkikäteen auditoida.

Kun teknologia ja organisaation kyvykkyys kehittyvät, voidaan siirtyä kehittyneempiin sovelluksiin, kuten riskianalyysiin, petostentorjuntaan ja asiakasprofilointiin. Näissä käyttötarkoituksissa voidaan hyödyntää järjestelmiä, jotka tuottavat suosituksia tai vaihtoehtoisia toimintamalleja analysoimalla suuria tietomääriä reaaliaikaisesti. Näiden järjestelmien tulee olla selitettävissä ja niiden perusteella tehtävät päätökset on voitava perustella liiketoiminnallisesti ja eettisesti. Mallien toimintaa on seurattava jatkuvasti ja niiden käyttöön on liityttävä selkeät vastuunjakomallit.

Aikanaan, kun sääntely, teknologinen infrastruktuuri ja organisaatiokulttuuri sen mahdollistavat, generatiivinen tekoäly voidaan integroida osaksi pankin strategisia toimintoja. Tällöin se ei ole enää erillinen kokeilu tai tukityökalu, vaan väline, joka ohjaa liiketoiminnan kehittämistä, ennakoii muutoksia ja tukee päätöksentekoa läpi organisaation. Tämän tason käyttöönotto edellyttää myös osallistumista alan yhteisiin standardointiprosesseihin, aktiivista vuoropuhelua sidosryhmien kanssa ja jatkuvaa teknologista ja eettistä arviointia. Onnistunut käyttöönotto ei ole yksinomaan tekninen tai operatiivinen kysymys, vaan vaatii laaja-alaista johtamista, viestintää ja sitoutumista. Teknologia tulee nähdä osana laajempaa toimintaympäristön muutosta, jossa asiakaskokemus, vastuullisuus ja innovaatiokyky ovat keskiössä. Pankkien kannattaa edetä vaiheittain, arvoida kypsyystasonsa realistisesti ja valita käyttökohteet, joissa teknologian hyödyt ja käyttöönoton riskit ovat tasapainossa.

Generatiivisen tekoälyn käyttöönotto pankkisektorilla edellyttää sovelluskohtaista harkintaa sekä teknologisten ratkaisujen ja toimittajien tuntemusta. Alla oleva kuva esittelee keskeiset käyttökohteet,

niihin soveltuvat teknologiat sekä esimerkkejä toimittajista, joiden ratkaisuja on hyödynnetty tai arvioitu kirjallisuudessa vuosien 2023–2025 aikana. Visualisointi tarjoaa tiiviin kokonaiskuvan siitä, millä tavoin generatiivista tekoälyä voidaan jäsentää pankkien käytännön tarpeisiin.



Kuvio 15 Generatiivisen tekoälyn käyttökohteet, teknologiat ja toimittajat pankkisektorilla. Visualisointi perustuu systemaattiseen kirjallisuuskatsaukseen ja alan keskeisiin kehityssuuntiin.

6.3 Tutkimuksen rajoitteet

Vaikka tämä tutkimus tarjoaa hyödyllisiä näkökulmia generatiivisen tekoälyn soveltamiseen finanssisektorilla, siihen liittyy myös joitain sisällöllisiä ja metodologisia rajoitteita. Ensimmäinen keskeinen rajoite liittyy aineiston ajalliseen rajaukseen: systemaattinen kirjallisuuskatsaus toteutettiin PRISMA-protokollan mukaisesti ja se kattoi vuosina 2023–2025 julkaistut tutkimukset. Tämä rajaus perustui tarpeeseen keskittyä ajankohtaiseen kirjallisuuteen tekoälyn nopean kehityksen jälkeen. Lyhyt aikaväli saattoi kuitenkin sulkea pois aiempia, yhä relevantteja tutkimuksia, tai toisaalta jättää huomiotta uusimpia käytännön ratkaisuja, joita ei ole vielä julkaistu tieteellisessä muodossa.

Toinen rajoite liittyy tarkastellun tutkimuskentän hajanaisuuteen. Generatiivinen tekoäly on monitieteinen ilmiö ja siihen liittyvä tutkimus jakautuu useille eri aloille, kuten tietojenkäsittelytieteeseen, liiketaloustieteeseen, käyttäytymistieteisiin ja oikeustieteeseen. Tämä teki kokonaiskuvan rakentamisesta haastavaa ja edellytti metodologista kompromissia lähestymistapojen ja terminologioiden välillä. Lisäksi suuri osa tarkastelluista julkaisuista oli kvalitatiivisia tai konseptuaalisia, mikä

voi sisältää tutkijoiden subjektiivisia painotuksia. Vaikka analyysi pyrki objektiivisuuteen, on mahdollista, että jotkut näkökulmat tai alueelliset erityispiirteet jäivät kattamatta.

Lisäksi koska generatiivinen tekoäly kehittyi nopeasti, voi osa tässä esiteltyistä teknologioista tai ratkaisuista vanhentua suhteellisen lyhyessä ajassa. Tämän vuoksi tutkimus on pyritty kirjoittamaan mahdollisimman aikaa kestäväksi keskittymällä yleisiin käyttötapauksiin ja teknologisiin periaatteisiin yksittäisten ohjelmistojen tai alustojen sijaan. Samalla on kuitenkin huomioitava, että käytännön sovellukset voivat vaihdella merkittävästi eri pankkien välillä johtuen muun muassa regulaation tasosta, resurssien määrästä ja organisaation kulttuurista. Kaikkiaan nämä rajoitteet eivät vähennä työn tuottamaa arvoa, mutta ne on syytä ottaa huomioon tuloksia arvioitaessa ja sovellettaessa niitä käytännön kehitystyöhön tai jatkotutkimukseen.

6.4 Ehdotukset jatkotutkimukselle

Tämän tutkimuksen pohjalta voidaan tunnistaa useita jatkotutkimuksen kohteita, jotka syventäisivät ymmärrystä generatiivisen tekoälyn hyödyntämisestä pankkisektorilla. Ensimmäkin olisi tärkeää toteuttaa empiirisiä tutkimuksia, jotka tarkastelevat GenAI-teknologioiden käytännön soveltamista yksittäisissä pankeissa tai vertailtavissa maissa. Tällaiset tapaustutkimukset voisivat paljastaa, miten teknologiaan liittyvät mahdollisuudet ja haasteet realisoituvat eri organisaatioiden konteksteissa ja miten sisäinen valmius, osaaminen ja kulttuuri vaikuttavat käyttöönoton onnistumiseen.

Jatkotutkimuksessa voisi myös syventyä asiakasnäkökulmaan. Vaikka generatiivinen tekoäly tarjoaa mahdollisuuksia asiakaspalvelun ja asiakaskokemuksen kehittämiseen, ei vielä tiedetä riittävästi siitä, miten asiakkaat suhtautuvat tekoälypohjaisiin vuorovaikutuskanaviin rahoituspalveluissa. Eriytyisen kiinnostavaa olisi selvittää, missä kulkee asiakkaan hyväksynnän ja luottamuksen raja tekoälyn tuottamissa neuvoissa, erityisesti silloin kun kyse on taloudellisesti merkittävistä päätöksistä.

Lisäksi olisi hyödyllistä tutkia GenAI-teknologioiden vaikutuksia työnkuviin, osaamisvaatimuksiin ja työorganisaatioihin finanssialalla. Tämän tutkimuksen perusteella voitaisiin päätellä, että teknologia muuttaa asiantuntijatyötä enemmän avustavaksi ja päätöksiä tukevaksi, mutta muutoksen vaikutuksista työntekijöiden rooliin, motivaatioon ja koulutustarpeisiin on vielä vain vähän tietoa.

Lisäksi voisi olla syytä tarkastella generatiivisen tekoälyn eettisiä ja oikeudellisia ulottuvuuksia pankkisektorilla. Tulevaisuuden tutkimus voisi analysoida tarkemmin esimerkiksi mallien selitettävyyttä, vastuukysymyksiä ja sääntelyn vaikutusta käytännön päätöksentekoon. Sääntelykehikon kehittyessä olisi tärkeää arvioida myös, missä määrin pankkien teknologiset ratkaisut pysyvät lainsäädännön vaatimusten tasolla vai rajoittavatko sääntelytoimet innovaatiota.

Generatiivinen tekoäly on vasta matkansa alussa pankkisektorilla. Tuleva tutkimus voisi hyödyntää pitkittäistarkasteluja ja laajempia aineistoja sen ymmärtämiseksi, miten teknologia muovaa pankkien toimintamalleja, kilpailuasemaa ja suhdetta asiakkaisiin pitkällä aikavälillä.

6.5 Lopuksi

Tutkimuksen perusteella generatiivinen tekoäly on nopeasti kehittyvä teknologia, joka tarjoaa pankkisektorille merkittäviä mahdollisuuksia, mutta myös huomattavia haasteita. Keskeistä teknologian onnistuneessa hyödyntämisessä on tasapainoinen ja vastuullinen lähestymistapa, jossa mahdollisuudet ja riskit arvioidaan kokonaisvaltaisesti. Tutkimus tarjoaa ajantasaisen ja kattavan näkemyksen alan kehityssuunnista ja luo pohjaa sekä pankkien käytännön kehitystyölle että tulevalle tieteelliselle tutkimukselle.

LÄHTEET

- , S. J. (2025). The Synergy of Generative AI and Big Data for Financial Risk: Review of Recent Developments. *International Journal For Multidisciplinary Research*, 7(1), 35488. <https://doi.org/10.36948/ijfmr.2025.v07i01.35488>
- 3 Ways Generative AI Will Transform Banking | Accenture Banking Blog*. (n.d.).
- 037_UddeniyeGedara_Herath*. (n.d.).
- 089_capturing-the-full-value-of-generative-ai-in-banking*. (n.d.).
- 090_scaling-gen-ai-in-banking-choosing-the-best-operating-model*. (n.d.).
- 091_extracting-value-from-ai-in-banking-rewiring-the-enterprise*. (n.d.).
- 093_deloitte-cn-fsi-ai-in-banking-en-240805*. (n.d.).
- 094_Generative AI in financial services _ Deloitte Global*. (n.d.).
- 097_Accenture-Age-AI-Banking-New-Reality*. (n.d.).
- 0104_eurotalous_analyysi_05092024*. (n.d.).
- Abdulsalam, T. A., & Tajudeen, R. B. (2024). Artificial Intelligence (AI) in the Banking Industry: A Review of Service Areas and Customer Service Journeys in Emerging Economies. *Business & Management Compass*, 68(3), 19–43. <https://doi.org/10.56065/9hfvrq20>
- Adams, R. J., Smart, P., & Huff, A. S. (2017). Shades of Grey: Guidelines for Working with the Grey Literature in Systematic Reviews for Management and Organizational Studies. *International Journal of Management Reviews*, 19(4), 432–454. <https://doi.org/10.1111/ijmr.12102>
- Adedoyin Tolulope Oyewole, Omotayo Bukola Adeoye, Wilhelmina Afua Addy, Chinwe Chinazo Okoye, Onyeka Chrisanctus Ofodile, & Chinonye Esther Ugochukwu. (2024). Promoting sustainability in finance with AI: A review of current practices and future potential. *World Journal of Advanced Research and Reviews*, 21(3), 590–607. <https://doi.org/10.30574/wjarr.2024.21.3.0691>
- Adeniran, I. A., Angela Omozele Abhulimen, Anwuli Nkemchor Obiki-Osafiele, Olajide Soji Osundare, Edith Ebele Agu, & Christianah Pelumi Efunniyi. (2024). Strategic risk

management in financial institutions: Ensuring robust regulatory compliance. *Finance & Accounting Research Journal*, 6(8), 1582–1596.

<https://doi.org/10.51594/farj.v6i8.1508>

Adke, V., Bakhshi, D. P., & Askari, D. M. (2024). Social Media Management Tools for Customer Service: A Review. *Journal of Marketing*, 1(1).

Aftabi, S. Z., Ahmadi, A., & Farzi, S. (2023). Fraud detection in financial statements using data mining and GAN models. *Expert Systems with Applications*, 227, 120144.

<https://doi.org/10.1016/j.eswa.2023.120144>

Ahmadirad, Z. (2024). Banking and Investment in the Future: Unveiling Opportunities and Research Necessities for Long-Term Growth. *International Journal of Applied Research in Management, Economics and Accounting*, 1(2), 34–41.

<https://doi.org/10.63053/ijmea.7>

Ahmed, F. (2022). ETHICAL ASPECTS OF ARTIFICIAL INTELLIGENCE IN BANKING. *Journal of Research in Economics and Finance Management*, 1(2), 55–63.

<https://doi.org/10.56596/jrefm.v1i2.7>

AI Index Report. (2024). *AI index report 2024*. https://aiindex.stanford.edu/wp-content/uploads/2024/04/HAI_AI-Index-Report-2024.pdf

Al Naqbi, H., Bahroun, Z., & Ahmed, V. (2024). Enhancing Work Productivity through Generative Artificial Intelligence: A Comprehensive Literature Review. *Sustainability*, 16(3), 1166. <https://doi.org/10.3390/su16031166>

Aliyu, A. A., & Tasmin, R. B. H. (2012). *The impact of information and communication technology on banks' performance and customer service delivery in the banking industry*. 2(1).

Allen, F., & Santomero, A. M. (1999). *What do Financial intermediaries do?*

Amini, M.-R., Canu, S., Fischer, A., Guns, T., Kralj Novak, P., & Tsoumakas, G. (Eds.). (2023). *Machine Learning and Knowledge Discovery in Databases: European Conference, ECML PKDD 2022, Grenoble, France, September 19–23, 2022, Proceedings, Part VI* (Vol. 13718). Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-26422-1>

- Angela Olere Omogbeme, Ada Ivy Phil-Ugochukwu, Ikechukwu Josephat Nwabufu, & Jude Onyebuchi Nwabufu. (2024). The role of artificial intelligence in enhancing financial inclusion: A review of its impact on financial services for the unbanked population in the United States. *World Journal of Advanced Research and Reviews*, 23(2), 2184–2192. <https://doi.org/10.30574/wjarr.2024.23.2.2489>
- APQC. (2014). *K04844_PCF_Banking_Vers_6.1.0_April 2023*. https://www.apqc.org/system/files/resource-file/2023-04/K04844_PCF_Banking_Vers_6.1.0_April%202023.pdf
- Babuşcu, Ş., & Hazar, A. (2023). Financial Technologies: Digital Payment Systems and Digital Banking. Today's Dynamics. *Journal of Research, Innovation and Technologies (JoRIT)*, 2(16), 162. [https://doi.org/10.57017/jorit.v2.2\(4\).04](https://doi.org/10.57017/jorit.v2.2(4).04)
- Bai, X., Zhuang, S., Xie, H., & Guo, L. (2024). *Leveraging Generative Artificial Intelligence for Financial Market Trading Data Management and Prediction*. Computer Science and Mathematics. <https://doi.org/10.20944/preprints202407.0084.v1>
- Bank, D., Koenigstein, N., & Giryas, R. (2021). *Autoencoders* (No. arXiv:2003.05991). arXiv. <https://doi.org/10.48550/arXiv.2003.05991>
- Banks look to AI for high yield on transformation*. (n.d.).
- Barde, K., & Kulkarni, P. A. (2023). Applications of Generative AI in Fintech. *The Third International Conference on Artificial Intelligence and Machine Learning Systems*, 1–5. <https://doi.org/10.1145/3639856.3639893>
- Beheshti, A. (2023a). Empowering Generative AI with Knowledge Base 4.0: Towards Linking Analytical, Cognitive, and Generative Intelligence. *2023 IEEE International Conference on Web Services (ICWS)*, 763–771. <https://doi.org/10.1109/ICWS60048.2023.00103>
- Beheshti, A. (2023b). Empowering Generative AI with Knowledge Base 4.0: Towards Linking Analytical, Cognitive, and Generative Intelligence. *2023 IEEE International Conference on Web Services (ICWS)*, 763–771. <https://doi.org/10.1109/ICWS60048.2023.00103>

- Belanche, D., Casaló, L. V., & Flavián, C. (2019). Artificial Intelligence in FinTech: Understanding robo-advisors adoption among customers. *Industrial Management & Data Systems*, *119*(7), 1411–1430. <https://doi.org/10.1108/IMDS-08-2018-0368>
- Belgodere, B., Dognin, P., Ivankay, A., Melnyk, I., Mroueh, Y., Mojsilovic, A., Navratil, J., Nitsure, A., Padhi, I., Rigotti, M., Ross, J., Schiff, Y., Vedpathak, R., & Young, R. A. (2024). Auditing and Generating Synthetic Data with Controllable Trust Trade-offs. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 1–1. <https://doi.org/10.1109/JETCAS.2024.3477976>
- Bengesi, S., El-Sayed, H., Sarker, M. K., Houkpati, Y., Irungu, J., & Oladunni, T. (2024). Advancements in Generative AI: A Comprehensive Review of GANs, GPT, Autoencoders, Diffusion Model, and Transformers. *IEEE Access*, *12*, 69812–69837. IEEE Access. <https://doi.org/10.1109/ACCESS.2024.3397775>
- Berger, A. N., & Udell, G. F. (2002). Small Business Credit Availability and Relationship Lending: The Importance of Bank Organisational Structure. *The Economic Journal*, *112*(477), F32–F53. <https://doi.org/10.1111/1468-0297.00682>
- Bessis, J. (2011). *Risk Management in Banking*.
- Bharathi Mohan, G., Prasanna Kumar, R., Vishal Krishh, P., Keerthinathan, A., Lavanya, G., Meghana, M. K. U., Sulthana, S., & Doss, S. (2024). An analysis of large language models: Their impact and potential applications. *Knowledge and Information Systems*, *66*(9), 5047–5070. <https://doi.org/10.1007/s10115-024-02120-8>
- Biresaw, T. M., & Sibindi, A. B. (2025). The Assessment of Enterprise Risk Management Practices of Ethiopian Commercial Banks. *Risks*, *13*(3), 51. <https://doi.org/10.3390/risks13030051>
- Bolón-Canedo, V., Morán-Fernández, L., Cancela, B., & Alonso-Betanzos, A. (2024). A review of green artificial intelligence: Towards a more sustainable future. *Neurocomputing*, *599*, 128096. <https://doi.org/10.1016/j.neucom.2024.128096>
- Botunac, I., Parlov, N., & Bosna, J. (2024a). Opportunities of Gen AI in the Banking Industry with regards to the AI Act, GDPR, Data Act and DORA. *2024 13th Mediterranean*

Conference on Embedded Computing (MECO), 1–6.

<https://doi.org/10.1109/MECO62516.2024.10577936>

Botunac, I., Parlov, N., & Bosna, J. (2024b). Opportunities of Gen AI in the Banking Industry with regards to the AI Act, GDPR, Data Act and DORA. *2024 13th Mediterranean Conference on Embedded Computing (MECO)*, 1–6.

<https://doi.org/10.1109/MECO62516.2024.10577936>

Bowden, J., Cummins, M., Dao, D., & Jain, K. (2024). *Explainable AI for Financial Risk Management*. University of Strathclyde. <https://doi.org/10.17868/STRATH.00089573>

Brandl, B., & Dieterich, L. (2023). The exclusive nature of global payments infrastructures: The significance of major banks and the role of tech-driven companies. *Review of International Political Economy*, *30*(2), 535–557.

<https://doi.org/10.1080/09692290.2021.2016470>

Busson, A. J. G., Gaio, R., Rocha, R. H., Evangelista, F., Rizzi, B., Carvalho, L., Miceli, R., Rabaioli, M., & Favaro, D. (2023). Saturn Platform: Foundation Model Operations and Generative AI for Financial Services. *Anais Estendidos Do XXIX Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia 2023)*, 85–88.

https://doi.org/10.5753/webmedia_estendido.2023.234354

Cao, H., Tan, C., Gao, Z., Xu, Y., Chen, G., Heng, P.-A., & Li, S. Z. (2023). *A Survey on Generative Diffusion Model* (No. arXiv:2209.02646). arXiv.

<https://doi.org/10.48550/arXiv.2209.02646>

Chatterjee, P., Das, D., & Rawat, D. B. (2024a). A Generative AI Approach for Ensuring Data Integrity Security Resilience in Fintech Systems. *2024 IEEE 24th International Symposium on Cluster, Cloud and Internet Computing Workshops (CCGridW)*, 168–173.

<https://doi.org/10.1109/CCGridW63211.2024.00027>

Chatterjee, P., Das, D., & Rawat, D. B. (2024b). A Generative AI Approach for Ensuring Data Integrity Security Resilience in Fintech Systems. *2024 IEEE 24th International Symposium on Cluster, Cloud and Internet Computing Workshops (CCGridW)*, 168–173.

<https://doi.org/10.1109/CCGridW63211.2024.00027>

- Chen, M., Mei, S., Fan, J., & Wang, M. (2024a). *An Overview of Diffusion Models: Applications, Guided Generation, Statistical Rates and Optimization* (No. arXiv:2404.07771). arXiv. <https://doi.org/10.48550/arXiv.2404.07771>
- Chen, M., Mei, S., Fan, J., & Wang, M. (2024b). Opportunities and challenges of diffusion models for generative AI. *National Science Review*, 11(12), nwae348. <https://doi.org/10.1093/nsr/nwae348>
- Chu, C., Zhmoginov, A., & Sandler, M. (2017). *CycleGAN, a Master of Steganography* (No. arXiv:1712.02950). arXiv. <https://doi.org/10.48550/arXiv.1712.02950>
- Core banking modernization: Unlocking legacy code with generative AI | Accenture Banking Blog*. (n.d.).
- Degen, H., & Ntoa, S. (Eds.). (2024). *Artificial Intelligence in HCI: 5th International Conference, AI-HCI 2024, Held as Part of the 26th HCI International Conference, HCII 2024, Washington, DC, USA, June 29–July 4, 2024, Proceedings, Part II* (Vol. 14735). Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-60611-3>
- Deloitte. (2023). *Navigating the artificial intelligence frontier*.
- Desai, A. P., Mallya, G. S., Luqman, M., Ravi, T., Kota, N., & Yadav, P. (2024). Opportunities and Challenges of Generative-AI in Finance. *2024 IEEE International Conference on Big Data (BigData)*, 4913–4920. <https://doi.org/10.1109/Big-Data62323.2024.10825658>
- Desai, A. P., Ravi, T., Luqman, M., Mallya, G., Kota, N., & Yadav, P. (2024a). Opportunities and Challenges of Generative-AI in Finance. *2024 IEEE International Conference on Big Data (BigData)*, 4913–4920. <https://doi.org/10.1109/Big-Data62323.2024.10825658>
- Desai, A. P., Ravi, T., Luqman, M., Mallya, G., Kota, N., & Yadav, P. (2024b). Opportunities and Challenges of Generative-AI in Finance. *2024 IEEE International Conference on Big Data (BigData)*, 4913–4920. <https://doi.org/10.1109/Big-Data62323.2024.10825658>
- Desiraju, K., & Khan, A. (2024). Enhancing Customer Support Services in Banking Using Generative AI. In S. K. Sharma, Y. K. Dwivedi, B. Metri, B. Lal, & A. Elbanna (Eds.),

Transfer, Diffusion and Adoption of Next-Generation Digital Technologies (Vol. 698, pp. 288–295). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-50192-0_25

Dill, A. (2019). *Bank Regulation, Risk Management, and Compliance: Theory, Practice, and Key Problem Areas* (1st ed.). Informa Law from Routledge. <https://doi.org/10.4324/9780429351167>

Dilmegani, C. (2024, January 2). *10 GAN Use Cases in 2025*. AIMultiple. <https://research.aimultiple.com/gan-use-cases/>

Dodda, S. (2024). *Exploring Variational Autoencoders and Generative Latent Time-Series Models for Synthetic Data Generation and Forecasting*. Preprints. <https://doi.org/10.36227/techrxiv.172564074.44005012/v1>

Doshi, K. (2023). *Risk and Regulatory Compliance in Banking: A Comprehensive Guide*. <https://doi.org/10.5281/ZENODO.14807434>

Doumpos, M., Zopounidis, C., Gounopoulos, D., Platanakis, E., & Zhang, W. (2023). Operational research and artificial intelligence methods in banking. *European Journal of Operational Research*, *306*(1), 1–16. <https://doi.org/10.1016/j.ejor.2022.04.027>

Drigă, I., Niță, D., & Cucu, I. (2009). *PRIVATE BANKING AND WEALTH MANAGEMENT SERVICES OFFERED BY BANKS*.

Dubey, S. S., Astvansh, V., & Kopalle, P. K. (2024). EXPRESS: Generative AI Solutions to Empower Financial Firms. *Journal of Public Policy & Marketing*, 07439156241311300. <https://doi.org/10.1177/07439156241311300>

Eckerli, F., & Osterrieder, J. (2021). *Generative Adversarial Networks in finance: An overview* (No. arXiv:2106.06364). arXiv. <https://doi.org/10.48550/arXiv.2106.06364>

Engvall, N. (n.d.). *The Influence of Institutional Factors on AI adoption in EU banking cybersecurity*:

Ernest Mfumbilwa, E., Mnong'one, C., Chao, E., & Amani, D. (2024). Invigorating continuance intention among users of AI chatbots in the banking industry: An empirical study from Tanzania. *Cogent Business & Management*, *11*(1), 2419482. <https://doi.org/10.1080/23311975.2024.2419482>

- Estrella-Ramón, A., Sánchez-Pérez, M., Swinnen, G., & VanHoof, K. (2017). A model to improve management of banking customers. *Industrial Management & Data Systems*, *117*(2), 250–266. <https://doi.org/10.1108/IMDS-03-2016-0107>
- Fan, M. (2024). LLMs in Banking: Applications, Challenges, and Approaches. *Proceedings of the International Conference on Digital Economy, Blockchain and Artificial Intelligence*, 314–321. <https://doi.org/10.1145/3700058.3700107>
- Fatouros, G., Soldatos, J., Kouroumalis, K., Makridakis, G., & Kyriazis, D. (2023). Transforming Sentiment Analysis in the Financial Domain with ChatGPT. *Machine Learning with Applications*, *14*, 100508. <https://doi.org/10.1016/j.mlwa.2023.100508>
- Five key success factors for commercial banks to scale generative AI | Accenture Banking Blog*. (n.d.).
- Four ways generative AI will transform commercial banking | Accenture Banking Blog*. (n.d.).
- Fragiadakis, G., Diou, C., Kousiouris, G., & Nikolaidou, M. (2024). *Evaluating Human-AI Collaboration: A Review and Methodological Framework* (No. arXiv:2407.19098). arXiv. <https://doi.org/10.48550/arXiv.2407.19098>
- García-Peñalvo, F., & Vázquez-Ingelmo, A. (2023). What Do We Mean by GenAI? A Systematic Mapping of The Evolution, Trends, and Techniques Involved in Generative AI. *International Journal of Interactive Multimedia and Artificial Intelligence*, *8*(4), 7. <https://doi.org/10.9781/ijimai.2023.07.006>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative Adversarial Nets. *Advances in Neural Information Processing Systems*, *27*. https://proceedings.neurips.cc/paper_files/paper/2014/hash/5ca3e9b122f61f8f06494c97b1afccf3-Abstract.html
- Gounari, M., Stergiopoulos, G., Pipiros, K., & Gritzalis, D. (2024). Harmonizing open banking in the European Union: An analysis of PSD2 compliance and interrelation with cybersecurity frameworks and standards. *International Cybersecurity Law Review*, *5*(1), 79–120. <https://doi.org/10.1365/s43439-023-00108-8>

- Greenwood, R., & Scharfstein, D. (2013). The Growth of Finance. *Journal of Economic Perspectives*, 27(2), 3–28. <https://doi.org/10.1257/jep.27.2.3>
- Hajiyani, H., Aminbeidokhti, A. A., & Hemmatian, H. (2015). The effect of customer relationship management on customer loyalty: Evidence from banking industry. *Management Science Letters*, 993–998. <https://doi.org/10.5267/j.msl.2015.9.001>
- Hamdan, A. (Ed.). (2024). *Achieving Sustainable Business Through AI, Technology Education and Computer Science: Volume 2: Teaching Technology and Business Sustainability* (Vol. 159). Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-71213-5>
- Han, S., & Yang, H. (2018). Understanding adoption of intelligent personal assistants: A parasocial relationship perspective. *Industrial Management & Data Systems*, 118(3), 618–636. <https://doi.org/10.1108/IMDS-05-2017-0214>
- Hariharan Pappil Kothandapani. (2024). Automating financial compliance with AI: A New Era in regulatory technology (RegTech). *International Journal of Science and Research Archive*, 11(1), 2646–2659. <https://doi.org/10.30574/ijrsra.2024.11.1.0040>
- Hassan, M. K., Parvin, S., & Siddiquee, J. A. (2024). ChatGPT Practices: Finance and Banking Domain. *Journal of Business, Communication & Technology*, 29–41. <https://doi.org/10.56632/bct.2024.3203>
- Hedman, J., & Henningsson, S. (2012). Competition and collaboration shaping the digital payment infrastructure. *Proceedings of the 14th Annual International Conference on Electronic Commerce*, 178–185. <https://doi.org/10.1145/2346536.2346571>
- Henry, J., Natalie, T., & Den Madsen. (2021). *Pix2Pix GAN for Image-to-Image Translation*. <https://doi.org/10.13140/RG.2.2.32286.66887>
- Hirvonen, A., & Walta, V. (2019). *Luotonanto pankkisektorin ulkopuolelta kasvussa*. Euro ja talous. <https://www.eurojatalous.fi/fi/2019/artikkelit/luotonanto-pankkisektorin-ulkopuolelta-kasvussa/>
- IBM. (2024, June 12). *What is a Variational Autoencoder?* | IBM. <https://www.ibm.com/think/topics/variational-autoencoder>
- Idrisov, B., & Schlippe, T. (2024). Program Code Generation with Generative AIs. *Algorithms*, 17(2), 62. <https://doi.org/10.3390/a17020062>

- IEA. (2024). *Data centres & networks*. IEA. <https://www.iea.org/energy-system/buildings/data-centres-and-data-transmission-networks>
- Iorliam, A., & Ingio, J. A. (2024). A Comparative Analysis of Generative Artificial Intelligence Tools for Natural Language Processing. *Journal of Computing Theories and Applications*, 1(3), 311–325. <https://doi.org/10.62411/jcta.9447>
- Jakovljević, S., Degryse, H., & Ongena, S. (2015). A Review of Empirical Research on the Design and Impact of Regulation in the Banking Sector. *Annual Review of Financial Economics*, 7(1), 423–443. <https://doi.org/10.1146/annurev-financial-111914-042024>
- Jameaba, M.-S. (2023). *Digitalization, Emerging Technologies, and Financial Stability: Challenges and Opportunities for the Indonesian Banking Sector and Beyond*. *Muyanja Ssenyonga Jameaba*. <https://doi.org/10.32388/CSTTYQ.3>
- Jebarajakirthy, C., Maseeh, H. I., Morshed, Z., Shankar, A., Arli, D., & Pentecost, R. (2021). Mobile advertising: A systematic literature review and future research agenda. *International Journal of Consumer Studies*, 45(6), 1258–1291. <https://doi.org/10.1111/ijcs.12728>
- Jere, I. (n.d.). *Tekoäly työelämän ja vihreän siirtymän muutosvoimana*.
- Jo Bitner, M. (2001). Service and technology: Opportunities and paradoxes. *Managing Service Quality: An International Journal*, 11(6), 375–379. <https://doi.org/10.1108/09604520110410584>
- Jovanović, M., & Campbell, M. (2022). Generative Artificial Intelligence: Trends and Prospects. *Computer*, 55(10), 107–112. *Computer*. <https://doi.org/10.1109/MC.2022.3192720>
- Jumper, J., Evans, R., Pritzel, A., Green, T., Figurnov, M., Ronneberger, O., Tunyasuvunakool, K., Bates, R., Žídek, A., Potapenko, A., Bridgland, A., Meyer, C., Kohl, S. A. A., Ballard, A. J., Cowie, A., Romera-Paredes, B., Nikolov, S., Jain, R., Adler, J., ... Hassabis, D. (2021). Highly accurate protein structure prediction with AlphaFold. *Nature*, 596(7873), 583–589. <https://doi.org/10.1038/s41586-021-03819-2>

- Kalia, S. (2023). Potential Impact of Generative Artificial Intelligence(AI) on the Financial Industry. *International Journal on Cybernetics & Informatics*, 12(6), 37–51.
<https://doi.org/10.5121/ijci.2023.120604>
- Kamalnath, V., Lerner, L., Moon, J., Sari, G., Sohoni, V., & Zhang, S. (2023, December 5). *Generative AI in banking and financial services | McKinsey*. <https://www.mckinsey.com/industries/financial-services/our-insights/capturing-the-full-value-of-generative-ai-in-banking>
- Karras, T., Laine, S., & Aila, T. (2019). *A Style-Based Generator Architecture for Generative Adversarial Networks*.
- Karst, F. S., Chong, S.-Y., & Antenor, A. A. (n.d.). *Generative AI for Banks: Benchmarks and Algorithms for Synthetic Financial Transaction Data*.
- Karst, F. S., Chong, S.-Y., Antenor, A. A., Lin, E., Li, M. M., & Leimeister, J. M. (2024a). *Generative AI for Banks: Benchmarks and Algorithms for Synthetic Financial Transaction Data* (No. arXiv:2412.14730). arXiv. <https://doi.org/10.48550/arXiv.2412.14730>
- Karst, F. S., Chong, S.-Y., Antenor, A. A., Lin, E., Li, M. M., & Leimeister, J. M. (2024b). *Generative AI for Banks: Benchmarks and Algorithms for Synthetic Financial Transaction Data* (No. arXiv:2412.14730). arXiv. <https://doi.org/10.48550/arXiv.2412.14730>
- Karst, F. S., Li, M. M., & Leimeister, J. M. (2025). SynDEc: A Synthetic Data Ecosystem. *Electronic Markets*, 35(1), 7. <https://doi.org/10.1007/s12525-024-00746-8>
- Kaswan, K. S., Dhatteval, J. S., Kumar, N., & Lal, S. (2023). Artificial Intelligence for Financial Services. In S. Grima, K. Sood, & E. Özen (Eds.), *Contemporary Studies of Risks in Emerging Technology, Part A* (pp. 71–92). Emerald Publishing Limited.
<https://doi.org/10.1108/978-1-80455-562-020231006>
- Kaswan, K. S., Dhatteval, J. S., Malik, K., & Baliyan, A. (2023). Generative AI: A Review on Models and Applications. *2023 International Conference on Communication, Security and Artificial Intelligence (ICCSAI)*, 699–704. <https://doi.org/10.1109/ICCSAI59793.2023.10421601>
- Kaya, O. (2019). *Artificial intelligence in banking: A lever for profitability with limited implementation to date*.

- Khan, F., Bartáková, G. P., Almadhor, A., Qayyum, A., Abeer, K., & Durrani, A. (2025). Evaluating the capacity and limitations of generative AI in financial decision making. *Computer Standards & Interfaces*, *93*, 103965. <https://doi.org/10.1016/j.csi.2024.103965>
- Kingma, D. P., Salimans, T., Jozefowicz, R., Chen, X., Sutskever, I., & Welling, M. (2016). Improved Variational Inference with Inverse Autoregressive Flow. *Advances in Neural Information Processing Systems*, *29*. https://proceedings.neurips.cc/paper_files/paper/2016/hash/ddeebdeefdb7e7e7a697e1c3e3d8ef54-Abstract.html
- Kong, Y., Nie, Y., Dong, X., Mulvey, J. M., Poor, H. V., Wen, Q., & Zohren, S. (2024). Large Language Models for Financial and Investment Management: Applications and Benchmarks. *The Journal of Portfolio Management*, *51*(2), 162–210. <https://doi.org/10.3905/jpm.2024.1.645>
- Kshetri, N. (2024a). Generative Artificial Intelligence in the Financial Services Industry. *Computer*, *57*(6), 102–108. <https://doi.org/10.1109/MC.2024.3382452>
- Kshetri, N. (2024b). Generative Artificial Intelligence in the Financial Services Industry. *Computer*, *57*(6), 102–108. <https://doi.org/10.1109/MC.2024.3382452>
- Kumar, K., Kuhar, N., & Sharma, M. (2025a). Artificial Intelligence in the Indian Banking System: A Systematic Literature Review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.5088937>
- Kumar, K., Kuhar, N., & Sharma, M. (2025b). Artificial Intelligence in the Indian Banking System: A Systematic Literature Review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.5088937>
- Laketa, M., Sanader, D., Laketa, L., & Mistic, Z. (2015). Customer relationship management: Concept and importance for banking sector. . . *Customer Relationship Management*.
- Lamarque, E. (2000). *KEY ACTIVITIES IN THE BANKING INDUSTRY ANALYSIS BY THE VALUE CHAIN*.
- Lee, D. K. C., Guan, C., Yu, Y., & Ding, Q. (2024a). A Comprehensive Review of Generative AI in Finance. *FinTech*, *3*(3), Article 3. <https://doi.org/10.3390/fintech3030025>
- Lee, D. K. C., Guan, C., Yu, Y., & Ding, Q. (2024b). A Comprehensive Review of Generative AI in Finance. *FinTech*, *3*(3), 460–478. <https://doi.org/10.3390/fintech3030025>

- Li, Z., Wu, C., Li, J., & Yuan, Q. (2025). Chatbot research in the fields of business and information systems: A systematic review and bibliometric analysis. *Aslib Journal of Information Management*. <https://doi.org/10.1108/AJIM-05-2024-0427>
- Lindfors, A. (2019). *DIGITALISAATIO JA PANKKITOIMINNAN KANNATTAVUUS SUOMESSA*.
- Lindholm, T., Kettunen, J., & Turunen, J. (2016). *Globaali kansantalous* (Vol. 1). Edita.
- Llewellyn, D. T. (1999). *The new economics of banking*. Société Universitaires Européenne de Recherches Financières.
- López-Solís, O., Luzuriaga-Jaramillo, A., Bedoya-Jara, M., Naranjo-Santamaría, J., Bonilla-Jurado, D., & Acosta-Vargas, P. (2025). Effect of Generative Artificial Intelligence on Strategic Decision-Making in Entrepreneurial Business Initiatives: A Systematic Literature Review. *Administrative Sciences*, 15(2), 66. <https://doi.org/10.3390/admsci15020066>
- Loukas, L., Stogiannidis, I., Diamantopoulos, O., Malakasiotis, P., & Vassos, S. (2023). Making LLMs Worth Every Penny: Resource-Limited Text Classification in Banking. *4th ACM International Conference on AI in Finance*, 392–400. <https://doi.org/10.1145/3604237.3626891>
- M, J., & Atham, S. B. (2025). Harnessing Artificial Intelligence and Machine Learning for Predictive Modeling and Decision Support in the Stock Market: A Research Review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.5089267>
- Mäkelä, M. (2018). *SÄÄNTELY JA RISKIENHALLINTA PANKKISEKTORILLA*.
- Manduchi, L., Pandey, K., Bamler, R., Cotterell, R., Däubener, S., Fellenz, S., Fischer, A., Gärtner, T., Kirchler, M., Kloft, M., Li, Y., Lippert, C., Melo, G. de, Nalisnick, E., Ommer, B., Ranganath, R., Rudolph, M., Ullrich, K., Broeck, G. V. den, ... Fortuin, V. (2024). *On the Challenges and Opportunities in Generative AI* (No. arXiv:2403.00025). arXiv. <https://doi.org/10.48550/arXiv.2403.00025>
- Maple, C., Szpruch, L., Epiphaniou, G., Staykova, K., Singh, S., Penwarden, W., Wen, Y., Wang, Z., Hariharan, J., & Avramovic, P. (n.d.). *The AI Revolution: Opportunities and Challenges for the Finance Sector*.

- Maude, D. J. (2010). *Global Private Banking and Wealth Management: The New Realities*. Wiley.
- Mettrick, G. (2024). The AI handbook for financial services leaders: Tips and tactics for mastering AI in banking and finance. *Journal of Securities Operations & Custody*, 16(3), 286. <https://doi.org/10.69554/SESY2749>
- Mienye, E., Jere, N., Obaido, G., Mienye, I. D., & Aruleba, K. (2024). Deep Learning in Finance: A Survey of Applications and Techniques. *AI*, 5(4), 2066–2091. <https://doi.org/10.3390/ai5040101>
- Moharrak, M., & Mogaji, E. (2024a). Generative AI in banking: Empirical insights on integration, challenges and opportunities in a regulated industry. *International Journal of Bank Marketing*. <https://doi.org/10.1108/IJBM-08-2024-0490>
- Moharrak, M., & Mogaji, E. (2024b). Generative AI in banking: Empirical insights on integration, challenges and opportunities in a regulated industry. *International Journal of Bank Marketing*. <https://doi.org/10.1108/IJBM-08-2024-0490>
- Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & the PRISMA Group. (2009). Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. *Annals of Internal Medicine*, 151(4), 264–269. <https://doi.org/10.7326/0003-4819-151-4-200908180-00135>
- Moradhasel, N., Sayadi, M. K., & Moin, M. S. (2024a). Analyzing the Challenges and Opportunities of Generative Artificial Intelligence in Iran's Banking Industry. *2024 11th International Symposium on Telecommunications (IST)*, 345–350. <https://doi.org/10.1109/IST64061.2024.10843491>
- Moradhasel, N., Sayadi, M. K., & Moin, M. S. (2024b). Analyzing the Challenges and Opportunities of Generative Artificial Intelligence in Iran's Banking Industry. *2024 11th International Symposium on Telecommunications (IST)*, 345–350. <https://doi.org/10.1109/IST64061.2024.10843491>
- Moradi Dakhel, A., Majdinasab, V., Nikanjam, A., Khomh, F., Desmarais, M. C., & Jiang, Z. M. (Jack). (2023). GitHub Copilot AI pair programmer: Asset or Liability? *Journal of Systems and Software*, 203, 111734. <https://doi.org/10.1016/j.jss.2023.111734>

- Mucsková, M. (2024). Transforming Banking with Artificial Intelligence: Applications, Challenges, and Implications. *Trends Economics and Management*, 18(42), 21–37. <https://doi.org/10.13164/trends.2024.42.21>
- Nie, Y., Kong, Y., Dong, X., Mulvey, J. M., Poor, H. V., Wen, Q., & Zohren, S. (2024). *A Survey of Large Language Models for Financial Applications: Progress, Prospects and Challenges* (No. arXiv:2406.11903). arXiv. <https://doi.org/10.48550/arXiv.2406.11903>
- [No title found]. (n.d.). *World Journal of Advanced Engineering Technology and Sciences*.
- Oeniya, L., Abbey Ngochindo Igwe, Onyeka Chrisanctus Ofodile, Chikezie Paul-Mikki Ewim, & Titilayo Deborah Olorunyomi. (2021). Optimizing risk management frameworks in banking: Strategies to enhance compliance and profitability amid regulatory challenges. *International Journal of Science and Technology Research Archive*, 1(2), 113–119. <https://doi.org/10.53771/ijstra.2021.1.2.0052>
- Oluwafemi Elias, Sunday David Esebre, Idris Abijo, Adesina Mayowa Timothy, Temitope Deborah Babayemi, Ebenezer O. Makinde, Oladiipo Ishola Oladepo, & Iyinoluwa Elizabeth Fatoki. (2024). Harnessing artificial intelligence to optimize financial technologies for achieving sustainable development goals. *World Journal of Advanced Research and Reviews*, 23(2), 616–625. <https://doi.org/10.30574/wjarr.2024.23.2.2385>
- Ooi, K.-B., Tan, G. W.-H., Al-Emran, M., Al-Sharafi, M. A., Capatina, A., Chakraborty, A., Dwivedi, Y. K., Huang, T.-L., Kar, A. K., Lee, V.-H., Loh, X.-M., Micu, A., Mikalef, P., Mogaji, E., Pandey, N., Raman, R., Rana, N. P., Sarker, P., Sharma, A., ... Wong, L.-W. (2025). The Potential of Generative Artificial Intelligence Across Disciplines: Perspectives and Future Directions. *Journal of Computer Information Systems*, 65(1), 76–107. <https://doi.org/10.1080/08874417.2023.2261010>
- Paez, A. (2017). Gray literature: An important resource in systematic reviews. *Journal of Evidence-Based Medicine*, 10(3), 233–240. <https://doi.org/10.1111/jebm.12266>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ...

- Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, n71. <https://doi.org/10.1136/bmj.n71>
- Palmatier, R. W., Houston, M. B., & Hulland, J. (2018). Review articles: Purpose, process, and structure. *Journal of the Academy of Marketing Science*, 46(1), 1–5. <https://doi.org/10.1007/s11747-017-0563-4>
- Pang, Y., Mao, J., He, L., Lin, H., & Qiang, Z. (2024). An Improved Face Image Restoration Method Based on Denoising Diffusion Probabilistic Models. *IEEE Access*, 12, 3581–3596. IEEE Access. <https://doi.org/10.1109/ACCESS.2024.3349423>
- Paramesha, M., Rane, N., & Rane, J. (2024). Artificial intelligence, machine learning, deep learning, and blockchain in financial and banking services: A comprehensive review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4855893>
- Patil, K., Pramod, D., & Kulkarni, M. (2024a). Information Quality Dimensions in Generative Conversational AI for Financial Inclusion. *2024 Sixth International Conference on Computational Intelligence and Communication Technologies (CCICT)*, 64–68. <https://doi.org/10.1109/CCICT62777.2024.00021>
- Patil, K., Pramod, D., & Kulkarni, M. (2024b). Information Quality Dimensions in Generative Conversational AI for Financial Inclusion. *2024 Sixth International Conference on Computational Intelligence and Communication Technologies (CCICT)*, 64–68. <https://doi.org/10.1109/CCICT62777.2024.00021>
- Patil, M., G, A., Sharma, A., & Patil, S. (2024). An Automated Alert System for Financial Fraud Detection with Learning Based Models. *2024 8th International Conference on Computational System and Information Technology for Sustainable Solutions (CSITSS)*, 1–6. <https://doi.org/10.1109/CSITSS64042.2024.10816781>
- Paul, J., & Barari, M. (2022). Meta-analysis and traditional systematic literature reviews—What, why, when, where, and how? *Psychology & Marketing*, 39(6), 1099–1115. <https://doi.org/10.1002/mar.21657>
- Paul, J., & Criado, A. R. (2020). The art of writing literature review: What do we know and what do we need to know? *International Business Review*, 29(4), 101717. <https://doi.org/10.1016/j.ibusrev.2020.101717>

- Perritt, H. (1996). *Legal and Technological Infrastructures for Electronic Payment Systems*.
- Qiyam, F., Jaradat, Y., & AlZu'Bi, S. (2024a). Prompt Engineering in Business Analytics for Next-Gen Digital Banking Services. *2024 2nd International Conference on Foundation and Large Language Models (FLLM)*, 432–436.
<https://doi.org/10.1109/FLLM63129.2024.10852452>
- Qiyam, F., Jaradat, Y., & AlZu'Bi, S. (2024b). Prompt Engineering in Business Analytics for Next-Gen Digital Banking Services. *2024 2nd International Conference on Foundation and Large Language Models (FLLM)*, 432–436.
<https://doi.org/10.1109/FLLM63129.2024.10852452>
- R, S., & Bagrecha, C. (2023). A Study On Generative Ai And Its Impact On Banking And Financial Services Sector: Data Privacy & Sustainable Perspective. *2023 IEEE Technology & Engineering Management Conference - Asia Pacific (TEMSCON-ASPAC)*, 1–5. <https://doi.org/10.1109/TEMSCON-ASPAC59527.2023.10531592>
- Rahi, S., Ghani, M. A., & Ngah, A. H. (2020). *Factors propelling the adoption of internet banking: The role of e-customer service, website design, brand image and customer satisfaction*.
- Rahman, M., Ming, T. H., Baigh, T. A., & Sarker, M. (2023). Adoption of artificial intelligence in banking services: An empirical analysis. *International Journal of Emerging Markets*, 18(10), 4270–4300. <https://doi.org/10.1108/IJOEM-06-2020-0724>
- Ramesh Pingili. (2025). AI-driven intelligent document processing for banking and finance. *International Journal of Management & Entrepreneurship Research*, 7(2), 98–109.
<https://doi.org/10.51594/ijmer.v7i2.1802>
- Rathod, R. (2024). Renaissance on Generative AI. *International Journal for Research in Applied Science and Engineering Technology*, 12(6), 1354–1359.
<https://doi.org/10.22214/ijraset.2024.63324>
- Reznikov, R. (2024). LEVERAGING GENERATIVE AI: STRATEGIC ADOPTION PATTERNS FOR ENTERPRISES. *MODELING THE DEVELOPMENT OF THE ECONOMIC SYSTEMS*, 1, 201–207. <https://doi.org/10.31891/mdes/2024-11-29>

- Ridzuan, N. N., Masri, M., Anshari, M., Fitriyani, N. L., & Syafrudin, M. (2024). AI in the Financial Sector: The Line between Innovation, Regulation and Ethical Responsibility. *Information*, 15(8), 432. <https://doi.org/10.3390/info15080432>
- Rifaldi, D., Famuji, T. S., Wijaya, S. A., Chotikunnan, P., Abougarair, A. J., & Ma'arif, A. (n.d.). Machine Learning 5.0 In-depth Analysis Trends in Classification. *Machine Learning*.
- Routray, S. K., Jha, M. K., Sharmila, K. P., Javali, A., Pappa, M., & Singh, M. (2024). Generative Artificial Intelligence: Principles, Potentials and Challenges. *2024 2nd International Conference on Self Sustainable Artificial Intelligence Systems (ICSSAS)*, 211–216. <https://doi.org/10.1109/ICSSAS64001.2024.10760992>
- Rupeika-Apoga, R. & Eleftherios. (2020). Ideas for a Regulatory Definition of FinTech. *International Journal of Economics and Business Administration*, VIII(Issue 2), 136–154. <https://doi.org/10.35808/ijeba/448>
- Sadeghiani, A. (2024). *Generative AI Carries Non-Democratic Biases and Stereotypes: Representation of Women, Black Individuals, Age Groups, and People with Disability in AI-Generated Images across Occupations* (No. arXiv:2409.13869). arXiv. <https://doi.org/10.48550/arXiv.2409.13869>
- Sarkis-Onofre, R., Catalá-López, F., Aromataris, E., & Lockwood, C. (2021). How to properly use the PRISMA Statement. *Systematic Reviews*, 10(1), 117, s13643-021-01671-z. <https://doi.org/10.1186/s13643-021-01671-z>
- Sattarov, T., Schreyer, M., & Borth, D. (2023). FinDiff: Diffusion Models for Financial Tabular Data Generation. *4th ACM International Conference on AI in Finance*, 64–72. <https://doi.org/10.1145/3604237.3626876>
- Schmidhuber, J. (1990). *Making the World Differentiable: On Using Self-Supervised Fully Recurrent Neural Networks for Dynamic Reinforcement Learning and Planning in Non-Stationary Environments*.
- Sengar, S. S., Hasan, A. B., Kumar, S., & Carroll, F. (2024). Generative artificial intelligence: A systematic review and applications. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-024-20016-1>
- Service Landscape. (2025). *BIAN*. <https://bian.org/deliverables/service-landscape/>

- Shabsigh, G. (2023). Generative Artificial Intelligence in Finance. *Fintech Notes*, 2023(006), 1. <https://doi.org/10.5089/9798400251092.063>
- Shalini, R., & Bagrecha, C. (2023). A Study On Generative Ai And Its Impact On Banking And Financial Services Sector: Data Privacy & Sustainable Perspective. *2023 IEEE Technology & Engineering Management Conference - Asia Pacific (TEMSCON-ASPAC)*, 1–5. <https://doi.org/10.1109/TEMSCON-ASPAC59527.2023.10531592>
- Shalini, R., & Chaya, B. (2024, May 21). *A Study On Generative Ai And Its Impact On Banking And Financial Services Sector: Data Privacy & Sustainable Perspective*. <https://ieeexplore-ieee-org.ezproxy.utu.fi/document/10531592/references#references>
- Shukla, N. K., Katikeri, R., Raja, M., Sivam, G., Yadav, S., Vaid, A., & Prabhakararao, S. (2023a). Generative AI Approach to Distributed Summarization of Financial Narratives. *2023 IEEE International Conference on Big Data (BigData)*, 2872–2876. <https://doi.org/10.1109/BigData59044.2023.10386313>
- Shukla, N. K., Katikeri, R., Raja, M., Sivam, G., Yadav, S., Vaid, A., & Prabhakararao, S. (2023b). Generative AI Approach to Distributed Summarization of Financial Narratives. *2023 IEEE International Conference on Big Data (BigData)*, 2872–2876. <https://doi.org/10.1109/BigData59044.2023.10386313>
- Simran, T., & Geetha, J. (2024a). Enhancing Graph Database Interaction through Generative AI-Driven Natural Language Interface for Financial Fraud Detection. *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1–8. <https://doi.org/10.1109/ICCCNT61001.2024.10725408>
- Simran, T., & Geetha, J. (2024b). Enhancing Graph Database Interaction through Generative AI-Driven Natural Language Interface for Financial Fraud Detection. *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1–8. <https://doi.org/10.1109/ICCCNT61001.2024.10725408>
- Singh, B. (2024). Generative Artificial Intelligence: Prospects for Banking Industry. *International Journal of Research in Engineering, Science and Management*, 7(3), Article 3.

- Singh, R., Kim, J. Y., Glassy, E. F., Dash, R. C., Brodsky, V., Seheult, J., De Baca, M. E., Gu, Q., Hoekstra, S., & Pritt, B. S. (2025). Introduction to Generative Artificial Intelligence: Contextualizing the Future. *Archives of Pathology & Laboratory Medicine*, 149(2), 112–122. <https://doi.org/10.5858/arpa.2024-0221-RA>
- SITRA. (2024, August 15). *Ratkaiseeko tekoälyasetus generatiivisen tekoälyn ympäristöhaasteet?* Sitra. <https://www.sitra.fi/blogit/ratkaiseeko-tekoalyasetus-generatiivisen-tekoalyn-ymparistohaasteet/>
- Skalski, P., Sutton, D., Burrell, S., Perez, I., & Wong, J. (2023). Towards a Foundation Purchasing Model: Pretrained Generative Autoregression on Transaction Sequences. *4th ACM International Conference on AI in Finance*, 141–149. <https://doi.org/10.1145/3604237.3626850>
- Srinivsan, S., & Krishna, R. S. B. (2024). Multimodal Information Extraction: A Systematic Review of Subtask, Modal Types and Applications Based on Deep Learning in Banking Sector. *2024 5th International Conference for Emerging Technology (INCET)*, 1–7. <https://doi.org/10.1109/INCET61516.2024.10593297>
- Stanoevska, E. (2024). GENERATIVE ARTIFICIAL INTELLIGENCE, THREAT OR CHALLENGE FOR THE MODERN BANKING SYSTEM. *International Journal*, 66.1.
- Stosic-Mihajlovic, L., & Jovic, L. (2017). The financial sector of the state: The structure of the banking system with a banking sector in Central and Eastern European countries. *Journal of Process Management. New Technologies*, 5(4), 13–29. <https://doi.org/10.5937/jouproman5-15302>
- Suchonwanich, N., Nuchitprasitchai, S., & Viriyapant, K. (2024a). Enhancing Personalized Financial Advisory Application with Generative AI and Chatbot: A Usability Study. *2024 8th International Conference on Information Technology (InCIT)*, 97–102. <https://doi.org/10.1109/InCIT63192.2024.10810647>
- Suchonwanich, N., Nuchitprasitchai, S., & Viriyapant, K. (2024b). Enhancing Personalized Financial Advisory Application with Generative AI and Chatbot: A Usability Study. *2024 8th International Conference on Information Technology (InCIT)*, 97–102. <https://doi.org/10.1109/InCIT63192.2024.10810647>

- Sumit Bhatnagar & Roshan Mahant. (2024). Unleashing the Power of AI in Financial Services: Opportunities, Challenges, and Implications. *International Journal of Advanced Research in Science, Communication and Technology*, 439–448. <https://doi.org/10.48175/IJAR SCT-19155>
- Sun, Y., Jang, E., Ma, F., & Wang, T. (2024). Generative AI in the Wild: Prospects, Challenges, and Strategies. *Proceedings of the CHI Conference on Human Factors in Computing Systems*, 1–16. <https://doi.org/10.1145/3613904.3642160>
- Svatá, V., & Fleischmann, M. (2011). IS/IT Risk Management in Banking Industry. *Acta Oeconomica Pragensia*, 19(3), 42–60. <https://doi.org/10.18267/j.aop.334>
- Tanvirahmedshuvo, Iqbal, A., Ahmed, E., Rahman, A., & Ontor, M. R. H. (2024). ENHANCING FRAUD DETECTION AND ANOMALY DETECTION IN RETAIL BANKING USING GENERATIVE AI AND MACHINE LEARNING MODELS. *The American Journal of Engineering and Technology*, 6(11), Article 11. <https://doi.org/10.37547/tajet/Volume06Issue11-09>
- Terblanché, J. (2013). *Legal risk and compliance risk in the banking industry in South Africa. The impact of generative AI in banking | Accenture Banking Blog.* (n.d).
- The time for generative AI in commercial banking is now | Accenture Banking Blog.* (n.d).
- Track Descriptions—ECIS.* (2023, September 5). <https://ecis2024.eu/track-descriptions/>
- Tranfield, D., Denyer, D., & Smart, P. (2003). Towards a Methodology for Developing Evidence-Informed Management Knowledge by Means of Systematic Review. *British Journal of Management*, 14(3), 207–222. <https://doi.org/10.1111/1467-8551.00375>
- Truby, J., Brown, R., & Dahdal, A. (2020). Banking on AI: Mandating a proactive approach to AI regulation in the financial sector. *Law and Financial Markets Review*, 14(2), 110–120. <https://doi.org/10.1080/17521440.2020.1760454>
- Tulcanaza-Prieto, A. B., Cortez-Ordoñez, A., & Lee, C. W. (2023). *Influence of Customer Perception Factors on AI-enabled Customer Experience in the Ecuadorian Banking Environment.* Business, Economics and Management. <https://doi.org/10.20944/preprints202306.1938.v1>

- Tuusa, P. (2025). *Generatiivisen tekoälyn eettiset periaatteet suomalaisella pankkisektorilla.*
- Uchenna Innocent Nnaomah, Opeyemi Abayomi Odejide, Samuel Aderemi, David Olanrewaju Olutimehin, Emmanuel Adeyemi Abaku, & Omamode Henry Orieno. (2024). AI in risk management: An analytical comparison between the U.S. and Nigerian banking sectors. *International Journal of Science and Technology Research Archive*, 6(1), 127–146. <https://doi.org/10.53771/ijstra.2024.6.1.0035>
- Udayagiri, S. B., Dhaka, A., Bhatnagar, Y., & Das, R. (2023a). Out-Of-Distribution Detection in Documents Using Generative AI for Banking Applications. *2023 Fourth International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE)*, 1–8. <https://doi.org/10.1109/ICSTCEE60504.2023.10585174>
- Udayagiri, S. B., Dhaka, A., Bhatnagar, Y., & Das, R. (2023b). Out-Of-Distribution Detection in Documents Using Generative AI for Banking Applications. *2023 Fourth International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE)*, 1–8. <https://doi.org/10.1109/ICSTCEE60504.2023.10585174>
- Unleashing a new era of productivity in investment banking through the power of generative AI.* (n.d.).
- Valkonen, T. (2022). *Pankkitoiminta ja pankkitoimintajärjestelmät – case uuden pankkitoimintajärjestelmän kehittämisen haasteet.*
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł. ukasz, & Polosukhin, I. (2017). Attention is All you Need. *Advances in Neural Information Processing Systems*, 30. https://papers.nips.cc/paper_files/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html
- Walter, I. (1999). The Global Asset Management Industry: Competitive Structure and Performance. *Financial Markets, Institutions & Instruments*, 8(1), 1–78. <https://doi.org/10.1111/1468-0416.00026>
- Wang, Z., & Ventre, C. (2024). A Financial Time Series Denoiser Based on Diffusion Models. *Proceedings of the 5th ACM International Conference on AI in Finance*, 72–80. <https://doi.org/10.1145/3677052.3698649>

- Wang, Z., Zhao, H., & Li, L. (2022). The positive side of bank wealth management products: Evidence from bank lending rate. *Journal of Financial Stability, 58*, 100950. <https://doi.org/10.1016/j.jfs.2021.100950>
- www.finanssivalvonta.fi. (2018, September 5). *Kulutusuotot ja pikavipit*. www.finanssivalvonta.fi. <https://www.finanssivalvonta.fi/kuluttajansuoja/pankkipalvelut/kulutusuotot-ja-pikavipit/>
- Xu, J. (n.d.). *AI in ESG for Financial Institutions: An Industrial Survey*.
- Zada, M., Khan, S., Mehmood, S., & Contreras-Barraza, N. (2024). Generative artificial intelligence in FinTech: Applications, environmental, social, and governance considerations, and organizational performance: The moderating role of ethical dilemmas. *Oeconomia Copernicana, 15*(4), 1303–1347. <https://doi.org/10.24136/oc.3323>
- Zeng, X., He, C., & Jiang, Y. (2023). Investigating the Advancements in Generative Models. *2023 International Conference on Artificial Intelligence and Automation Control (AIAC)*, 347–351. <https://doi.org/10.1109/AIAC61660.2023.00037>
- Zheng, X., Li, J., Lu, M., & Wang, F.-Y. (2024a). New Paradigm for Economic and Financial Research With Generative AI: Impact and Perspective. *IEEE Transactions on Computational Social Systems, 11*(3), 3457–3467. *IEEE Transactions on Computational Social Systems*. <https://doi.org/10.1109/TCSS.2023.3334306>
- Zheng, X., Li, J., Lu, M., & Wang, F.-Y. (2024b). New Paradigm for Economic and Financial Research With Generative AI: Impact and Perspective. *IEEE Transactions on Computational Social Systems, 11*(3), 3457–3467. <https://doi.org/10.1109/TCSS.2023.3334306>

LIITTEET

Liite 1. Systemaattisen kirjallisuuskatsauksen aineisto

Liite_1_Systemaattisen_kirjallisuuskatsauksen_aineisto.pdf

ID	Tietokanta	Kirjoittaja(t)	Julkaisu vuosi	Nimi	Koodattavat teemat
001	Google Scholar	Moayad Moharrak, Emmanuel Mogaji	2024	Generative AI in banking: empirical insights on integration, challenges and opportunities in a regulated industry	regulaatio,asiakaspalvelu,petostentunnistus,riskienhallinta,sijoitukset,operatiivinen toiminta
002	Google Scholar	Keng-Boon Ooi, Garry Wei-Han Tan, Mostafa Al-Emran, Mohammed A. Al-Sharafi, Alexandru Capatina, Amrita Chakraborty, Yogesh K. Dwivedi, Tzu-Ling Huang, Arpan Kumar Kar, Voon-Hsien Lee, Xiu-Ming Loh, Adrian Micu, Patrick Mikael, Emmanuel Mogaji, Neeraj Pandey, Ramakrishnan Raman, Nripendra P. Rana, Prianka Sarker, Anshuman Sharma, Ching-I Teng, Samuel Fosso Wamba, Lai-Wan Wong	2025	The Potential of Generative Artificial Intelligence Across Disciplines: Perspectives and Future Directions	operatiivinen toiminta,asiakaspalvelu,petostentunnistus
003	Google Scholar	Satyadar Joshi	2025	The Synergy of Generative AI and Big Data for Financial Risk: Review of Recent Developments	Sijoitukset, riskienhallinta, petostentunnistus, operatiivinen toiminta
004	Google Scholar	Sumit Bhatnagar, Roshan Mahant	2024	Unleashing the Power of AI in Financial Services: Opportunities, Challenges, and Implications	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
005	Google Scholar	David Kuo Chuen Lee, Chong Guan, Yinghui Yu, Quinxu Ding	2024	A Comprehensive Review of Generative AI in Finance	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
006	Google Scholar	Mallikarjuna Paramesha, Nitin Liladhar Rane, Jayesh Rane	2024	Artificial Intelligence, Machine Learning, Deep Learning, and Blockchain in Financial and Banking Services: A Comprehensive Review	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
007	Google Scholar	Khalid Hassan, Shahnaz Parvin, Jahangir Alam Siddiquee	2024	ChatGPT Practices: Finance and Banking Domain	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
008	Google Scholar	Minghong Fan	2024	LLMs in Banking: Applications Challenges and Approaches	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
009	Google Scholar	Muyanja-Ssenyonga Jameaba	2024	Digitalization, Emerging Technologies, and Financial Stability: Challenges and Opportunities for the Indonesian Banking Sector and Beyond	riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
010	Google Scholar	Humaid Al Naqbi, Zied Bahroun, Vian Ahmed	2024	Enhancing Work Productivity through Generative Artificial Intelligence: A Comprehensive Literature Review	operatiivinen toiminta,asiakaspalvelu, regulaatio
011	Google Scholar	Nurhadhinah Nadiyah Ridzuan, Masairol Masri, Muhammad Anshari, Norma Latif Fitriyani, Muhammad Syafrudin	2024	AI in the Financial Sector: The Line between Innovation, Regulation and Ethical Responsibility	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
012	Google Scholar	Ududeniye Gedara Dilusha, Wasala Nalinda	2024	UNVEILING THE FUTURE: HOW SRI LANKA'S BANKING SECTOR IS LEVERAGING AI-POWERED APPLICATIONS FOR ENHANCING CUSTOMER EXPERIENCE.	Asiakaspalvelu, operatiivinen toiminta

013	Google Scholar	Carsten Maple, Lukasz Szpruch, Gregory Epiphaniou, Kalina Staykova, Simran Singh, William Penwarden, Yisi Wen, Zijian Wang, Jagdish Hariharan, Pavle Avramovic	2023	The AI Revolution: Opportunities and Challenges for the Finance Sector	Regulaatio
014	Google Scholar	Yuqi Nie , Yaxuan Kong , Xiaowen Dong, John M. Mulvey†, H. Vincent Poor, Qingsong Wen, Stefan Zohren†	2024	A Survey of Large Language Models for Financial Applications: Progress, Prospects and Challenges	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
015	Google Scholar	Yaxuan Kong, Yuqi Nie, Xiaowen Dong, John M. Mulvey, H. Vincent Poor, Qingsong Wen, and Stefan Zohren	2024	Large Language Models for Financial and Investment Management: Applications and Benchmarks	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
016	Google Scholar	Lucas Ek, Elliot Arnarp	2024	Generative AI in Traditional Banking Institutes A Qualitative Study of its Utilisation, Value Creation, Challenges and Strategic Facilitators	Riskienhallinta, operatiivinen toiminta, regulaatio, asiakaspalvelu
017	Google Scholar	Bahadur Singh	2024	Generative Artificial Intelligence: Prospects for Banking Industry	Riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
018	Google Scholar	Vivek Dubey	2024	Generative AI – A Catalyst in Banking and Financial Industry	Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, petosten tunnistus, regulaatio
019	Google Scholar	Siva Sai, Keya Arunakar, Vinay Chamola, Amir Hussain, Pranav bisht, Sanjeev kumar	2025	Generative AI for Finance: Applications, Case Studies and Challenges	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
020	Google Scholar	Charanjit Singh	2025	Is generative AI (artificial intelligence) the next advent in the evolution of finance and navigating financial crime and regulation?	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
021	Google Scholar	Marc-Andre Zöller, Anastasiia Iurshina, Ines Röder	2024	Trustworthy Generative AI for Financial Services	Operatiivinen tehokkuus, regulaatio
022	Google Scholar	Harish Kumar Sriram, Aluri Seenu	2023	Generative AI-Driven Automation in Integrated Payment Solutions: Transforming Financial Transactions with Neural Network-Enabled Insights	riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
023	Google Scholar	Satyadar Joshi	2025	Gen AI for Market Risk and Credit Risk Learn Agentically powered Gen AI ; Gen AI Agentic Framework for Financial Risk Management !	Riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
024	Google Scholar	Venkata Rupesh, Kumar Dabbir	2025	REAL-TIME FRAUD DETECTION IN BANKING WITH GENERATIVE ARTIFICIAL INTELLIGENCE	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus
025	Google Scholar	Poornima Kapadan Othayoth, Shivi Khanna	2025	Implementation of artificial intelligence and chatbot for the enhancement of new age banking systems: a systematic review	Riskienhallinta, asiakaspalvelu
026	Google Scholar	Jai Kiran Reddy Burugulla	2025	Enhancing Credit and Charge Card Risk Assessment Through Generative AI and Big Data Analytics: A Novel Approach to Fraud Detection and Consumer Spending Patterns	riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
027	Google Scholar	Laith Haleem Al-Hchemi	2024	Evaluating Generative AI in enhancing banking services efficiency	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio

028	IEEE Xplore	Sagarika Behera, Varsha Kalagudi, Sai Manish Kumar Reddy B, Soumya Ranjan Das	2025	Generative AI-Based Financial Fraud Detecion System	Petostentunnistus, Operatiivinen tehokkuus
029	IEEE Xplore	Ive Botunac, Natalija Parlov, Jurica Bosna	2024	Opportunities of Gen AI in the Banking Industry with regards to the AI Act, GDPR, Data Act and DORA	Sijoitukset, riskienhallinta, asiakaspalvelu, regulaatio
030	IEEE Xplore	Niloorfar Moradhasel, Mohammad Kazem Sayadi, Mohamad Shahram Moin	2024	Analyzing the Challenges and Opportunities of Generative Artificial Intelligence in Iran's Banking Industry	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, petosten tunnistus, regulaatio
031	IEEE Xplore	Shalini R., Chaya Bagrecha	2023	A Study On Generative Ai And Its Impact On Banking And Financial Services Sector: Data Privacy & Sustainable Perspective	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, petosten tunnistus, regulaatio
032	IEEE Xplore	Sai Babu Udayagiri, Ayush Dhaka, Yash Bhatnagar, Rahul Das	2023	Out-Of-Distribution Detection in Documents Using Generative AI for Banking Applications	Riskienhallinta, Operatiivinen tehokkuus
033	IEEE Xplore	Nir Kshetri	2024	Generative Artificial Intelligence in the Financial Services Industry	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, petosten tunnistus, regulaatio
034	IEEE Xplore	Akshar Prabhu Desai, Tejasvi Ravi, Mohammad Luqman, Ganesh Mallya, Nithya Kota, Pranjul Yadav	2024	Opportunities and Challenges of Generative-AI in Finance	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, petosten tunnistus, regulaatio
035	IEEE Xplore	Simran T, Geetha J	2024	Enhancing Graph Database Interaction through Generative AI-Driven Natural Language Interface for Financial Fraud Detection	Petostentunnistus, Operatiivinen tehokkuus, riskienhallinta
036	IEEE Xplore	Niorn Suchonwanich, Siranee Nuchitprasitchai, Kanchana Viriyapant	2024	Enhancing Personalized Financial Advisory Application with Generative AI and Chatbot: A Usability Study	Sijoitukset, riskienhallinta, operatiivinen toiminta, asiakaspalvelu
037	IEEE Xplore	Mallanagouda Patil, Aishwarya G, Anukriti Sharma, Siya Patil	2024	An Automated Alert System for Financial Fraud Detection with Learning Based Models	Riskienhallinta, petosten tunnistus, operatiivinen toiminta
038	Scopus	Kanti Desiraju, Anupriya Khan	2024	Enhancing Customer Support Services in Banking Using Generative AI	Asiakaspalvelu, operatiivinen toiminta
039	Scopus	Piotr Skalski, David Sutton, Stuart Burrell, Iker Perez, Jason Wong	2024	Towards a Foundation Purchasing Model: Pretrained Generative Autoregression on Transaction Sequences	Petostentunnistus, Operatiivinen tehokkuus, riskienhallinta
040	Scopus	Kalpesh Barde, Parth Kulkarni	2023	Applications of Generative AI in Fintech	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, petosten tunnistus, regulaatio
041	Scopus	Rima Rouhana, May Merhej Sayegh	2024	The Use of Generative AI in the Lebanese Banking Sector in Response to the Rise of the Fintech Firms Since 2019	Riskienhallinta, operatiivinen toiminta, asiakaspalvelu, regulaatio
042	Web of Science	Lefteris Loukas, Ilias Stogiannidis, Odysseas Diamantopoulos, Prodromos Malakasiotis, Stavros Vassos	2023	Making LLMs Worth Every Penny: Resource-Limited Text Classification in Banking	Operatiivinen tehokkuus, asiakaspalvelu
043	UTU Volter	Ghiath Shabsigh, El Bachir Boukherouaa	2023	Generative Artificial Intelligence in Finance: Risk Considerations	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, petosten tunnistus, regulaatio
044	UTU Volter	Shank Shaurya Dubey, Vivek Astvansh, Praveen K. Koppalle	2024	Generative AI Solutions to Empower Financial Firms	Riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus

045	UTU Volter	Fabian Sven Karst, Sook-Yee Chong, Abigail A. Entenor, Enyu Lin, Mahei Manhai Li, Jan Marco Leimester	2024	Generative AI for Banks: Benchmarks and Algorithms for Synthetic Financial Transaction Data	Riskienhallinta, operatiivinen toiminta, petosten tunnistus, regulaatio
046	UTU Volter	Guy Mettrick	2024	The AI handbook for financial services leaders: Tips and tactics for mastering AI in banking and finance	riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
047	Harmaa kirjallisuus, McKinsey	Vishnu Kamalnath, Larry Lerner, Jared Moon, Gökhan Sari, Vik Sohoni, Shuo Zhang	2023	Capturing the full value of generative AI in banking	Riskienhallinta, operatiivinen toiminta, asiakaspalvelu, regulaatio
048	Harmaa kirjallisuus, McKinsey	Kevin Buehler, Alison Corsi, Mina Jurisic, Larry Lerner, Andrea Siani, Brian Weintraub	2024	Scaling gen AI in banking: Choosing the best operating model	Riskienhallinta, operatiivinen toiminta, asiakaspalvelu, regulaatio
049	Harmaa kirjallisuus, McKinsey	Carlo Giovine, Larry Lerner, Renny Thomas, Shwaitang Singh, Sudhakar Kakulavarapu, Violet Chung	2024	Extracting value from AI in banking: Rewiring the enterprise	riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
050	Harmaa kirjallisuus, Deloitte	Deloitte	2024	Changing the game: the impact of artificial intelligence on the banking and capital markets sector	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, petosten tunnistus, regulaatio
051	Harmaa kirjallisuus, Deloitte	Sriram Gopalakrishnan, Val Srinivas, Abhinav Chauhan	2023	Unleashing a new era of productivity in investment banking through the power of generative AI	Sijoitukset, riskienhallinta, operatiivinen toiminta, regulaatio
052	Harmaa kirjallisuus, Deloitte	Deloitte	2024	Banks look to AI for high yield on transformation	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, petosten tunnistus, regulaatio
053	Harmaa kirjallisuus, Accenture	Keri Smith, Michael Abbott, Mauro Centonze	2024	Banking in the age of generative AI	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, regulaatio
054	Harmaa kirjallisuus, Suomen Pankki	Tatu Räsänen	2024	Generatiivinen tekoäly voi mullistaa rahoitussektoria	
055	Harmaa kirjallisuus, American Banker	Catherine Leffert	2023	How banks can adopt generative AI	riskienhallinta, operatiivinen toiminta, asiakaspalvelu, petosten tunnistus, regulaatio
056	Google Scholar	Archana Todupunuri	2024	Generative AI For Predictive Credit Scoring And Lending Decisions Investigating How AI Is Revolutionising Credit Risk Assessments And Automating Loan Approva	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, regulaatio
057	Harmaa kirjallisuus, Thomson Reuters	Thomson Reuters	2023	Generative AI in banking: Opportunities and pitfalls abound with this new technology	Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu, regulaatio
058	Google Scholar	Laxman doddipatla, Ramakrishna Ramadugu, Sai Teja Sharma R, Roaan Reddy Yerram	2024	Ethical and Regulatory Challenges of Using Generative AI in Banking: Balancing Innovation and Compliance	Riskienhallinta, operatiivinen toiminta, asiakaspalvelu, regulaatio
059	Google Scholar	Roosa aaltonen	2024	Tekoälyn hyödyntäminen pankkitoiminnassa	Sijoitukset, Riskienhallinta, Operatiivinen tehokkuus, asiakaspalvelu
060	Google Scholar	Pauliina Tuusa	2025	Generatiivisen tekoälyn eettiset periaatteet suomalaisella pankkisektorilla	Riskienhallinta, asiakaspalvelu, regulaatio
061	Google Scholar	Kia Kemppainen	2024	Kehittyvän tekoälyn riskit pankkialalla	Riskienhallinta, asiakaspalvelu, regulaatio