

# Itseluokitteleva Neuroverkko

Noel Guiland  
2025

## Johdanto

Neuroverkkojen hyödyntäminen on nyky-päivänä tehokkain ratkaisu moneen kone-oppimista vaativaan tehtävään. Neuroverkot suoriutuvat varsin hyvin merkittävistä datamääristä, kuten suurien kielimallien käsittelystä.

Ongelmana on, että kaupalliset neuroverkot tarvitsevat laajoja määriä käsiteltä dataa, jonka hankkiminen on hidasta ja kallista. Itseluokittelukeinot pyrkivät tarjoamaan vaihtoehdoisen tavan lähestyä neuroverkon kouluttamista. Ne kykenevät hyödyntämään käsittelemätöntä aineistoa tekoälyn normaalin kouluttamisen ohella.

Työssäni sovelsin neuroverkkojen kouluttamiseen itse kehitettyjä itseluokittelukeinoja, joiden tulosta vertasin vastaaviin perinteisiin malleihin. Toteutin neuroverkkojen suunnittelun ja rakentamisen osana projektia.

## Teoria

Teoria, johon neuroverkot pohjautuvat on lähinnä matematiikkaa, mutta oikean idean voi myös saada käsitteellisestä näkökulmasta.

Neuroverkon rakenne sisältää syötteen ja sen perusteella laskettavan tuloksen. Käsitteelliset neuronit asettautuvat neuronikerroksille, joiden välillä tietoa kuljetetaan eteenpäin. Viimeisellä neuronikerroksella saadaan numeerinen arvo,  $[0,1]$ -väliltä jokaiselle neuronille. Arvot kuvaavat neuroverkon tuloksen varmuutta.

Neuroverkkoa voidaan säätää parametreilla, jonka perusteella neuroverkon syöte painottuu. Parametrien arvoja voidaan muuttaa tietoisesti, tiedostaen niiden vaikutuksen lopputulokseen.

Oppimista voidaan kuvailla käsitteellisesti niin, että kyseessä on moniulotteinen pinta, jossa korkeuden sijaan arvona on virhe. Neuroverkon tehtävänä on päästä pinnan alhaisimpaan pisteeseen, joka on väistämättä laakso.

Vaihtaessa parametreja, tiedossa on vain maan jyrkkyys, sekä jyrkimmän kallistuksen suunta. Tavoitteenamme on päästä mahdollisimman alhaiseen kohtaan tasossa, joten kuljemme jyrkimpään alaspäin kulkevaan suuntaan.

Tarkempi kuvaus neuroverkkoon liittyvästä teoriasta – muun muassa matematiikasta – löytyy alla olevan QR-koodin kautta.



## Itseluokittelu

Itseluokittelukeinojen toimivuudesta on vaikea päästä mihinkään lopputulokseen ennen empiiristä päättelyä, sillä vaikuttavia muuttujia on epätavallisen monta.

Työn osana laadin kaksi erilaista itseluokittelukeinoja. Kummankin luokittelun toimivuuden motivaatio on olemassa, mutta ei ole perusteltavissa ilman testaamista.

Menetelmä 1. "Kiihtyvyyden seuraaminen":

Tässä menetelmässä odotetaan sellaista hetkeä, jolloin tarkkuus on ylittänyt tietyn raja-arvon ja on viimeisen kahden kierroksen aikana ollut laskusuuntainen. Tämän jälkeen aloitetaan käsittelemättömän datan syöttö neuroverkkomallille, joka laatii päätelmän luokittelemattomalle dataotokselle. Näitä 'itseluokiteltuja' esimerkkejä käytetään jatkossa osana koulutusta.

Menetelmä 2. "Jatkuva syöttö":

Tämä menetelmä perustuu luokittelemattoman datan jatkuvaan käsittelyyn. Käsittelemisen tarkoituksena on painottaa otosmäärää ja suhteuttaa otosta huomioiden virheen suuruus. Tässä yhteydessä virhe kuvaa sitä, kuinka kaukana neuroverkkomalli oli oikeasta lopputuloksesta.

$$\hat{m} \approx E \cdot m, \hat{m} \in \mathbb{Z}_+, E \in [0,1]$$

Menetelmä 2. Periaate matemaattisesti ilmaistu.

## Rakentaminen

Rakensin neuroverkkomallini alusta asti Python-ohjelmointikielillä. Hyödynsin NumPy-kirjastoa, joka sisältää monta matriisilaskentaan liittyvää työkalua. Neuroverkot käsittelevät MNIST handwritten digits -datasettia, joka koostuu 28x28 mustavalkoista yksilukuisten kuvista [1]. Kyseistä MNIST-datasettia pidetään kiintopisteinä koneoppimisen alalla.


Rakensin työn aikana yhteensä kaksi prototyyppiä. Ensimmäisessä ilmeni monia virheitä sekä sen toiminnassa, että muokattavuudella. Kehitin lopullisen mallin korjaten edeltävän mallin virheitä. Muilta osin prototyypit ovat lähes identtisiä.




Kuvassa 1. Esiintyvä näyte MNIST handwritten digits -datasettista.

## Tulokset

Tutkimuskysymys oli "Voiko itseluokittelumenetelmiä hyödyntävä neuroverkko olla samoilla parametreilla koulutettua feedforward-neuroverkkoa tarkempi?".



Itseluokittelumenetelmä 2. Prototyyppi 2.



Itseluokittelumenetelmä 1. Prototyyppi 2.

Kuvissa on itseluokittelevan- ja feedforward-mallin tarkkuuden aikakehitys 200:n koulutuskerroksen aikana.

Kummassakin taulukossa itseluokittelumenetelmää hyödyntävä neuroverkko suoriutuu normaaliin verrattuna heikommin.

## Johtopäätökset

Tutkimustulosten perusteella ei voi päätellä positiivista korrelaatiota itseluokittelumenetelmien ja tarkkuuden välillä. Päinvastoin, itseluokittelumenetelmää hyödyntävät mallit olivat vähemmän tarkkoja feedforward-neuroverkon normaaliin oppimiseen verrattuna.

Tästä voi päätellä, että keksimäni itseluokittelukeinot eivät ole edullisia feedforward-malleille, ilman muita tarkkuutta parantavia ominaisuuksia tai uusia menetelmiä.

Aiemmissä tutkimuksissa itseluokittelevat neuroverkot ovat tulleet tarkemmiksi, kun itseluokittelun osana on hyödynnetty esikäsitteilyä, sekä regularisointitekniikoita. Päätin olla käyttämättä näitä tekniikoita, sillä ne toisi työn tulosten tulkitsemiseen liian monta muuttujaa saadakseen ehdoton lopputulos.

## Lähteet

<https://iq.opengenus.org/mnist-handwritten-recognition-dataset/> Kuva 1  
<https://iatransformacion.com/3-modelos-de-redes-neuronales-ia-generativa/> Taustakuva

Muut lähteet löytyvät tutkimusraportista