

Konenäköanalyysiä tekoälyllä pilvessä

25.5.2021


Vaikka otsikko onkin kyllästetty teknologisesti trendikkäillä (ns. buzz word) sanoilla, tartutaan tässä artikkelissa asiaan kuitenkin hyvin konkreettisesti konenäön näkökulmasta. Sääntöpohjaisessa, eli ns. perinteisessä konenäössä sensorin keräämä tieto analysoidaan yleensä paikallisesti johtuen mm. siitä, että dataa ei ole tarvetta viedä laskentatehon puutteen vuoksi ulkoiselle resurssille. Toisaalta tietyissä nopeatahtisissa sovelluksissa laskenta on pakko suorittaa paikallisesti, koska esimerkiksi tuotantolinjalla tuotteet voivat edetä niin nopeasti, että ihmissilmäkään ei kykene yksittäisiä tuotteita materiaalivirrasta erottamaan. Tässä tapauksessa datan siirtämiselle ja analysoimiselle ulkoisella resurssilla ei ole aikaa.

Usein valmistettavat tuotteet tai niiden jokin osa on epäsäännöllinen esimerkiksi muodoltaan, tekstuuriltaan tai väreiltään ja näissä esiintyy vielä satunnaisia laatupoikkeamia. Näissä tapauksissa kuva-analyysin rakentaminen erilaisten sääntöjen varaan on käytännössä mahdotonta. Tekoälyn soveltaminen konenäössä tuo oman lisänsä teknologiaan ja paikkaa muutamia sääntöpohjaisen konenäön puutteita ja haasteita. Erityisesti laadunvalvonnassa tekoälyn soveltaminen konenäön kanssa avaa huomattavia mahdollisuuksia erilaisten epäsäännöllisten virheiden tunnistamiseen tutkittavista kappaleista. Tekoälyn haasteena on usein kuitenkin se, että varsinkin sen opettamisvaiheessa laskentatehoa tarvitaan melko paljon ja usein myös valmiin mallin käyttäminen vaatii sääntöpohjaista konenäköä enemmän laskentatehoa.

Eräs mahdollisuus on hyödyntää pilvilaskentaa, jossa tekoälyä voidaan opettaa ja opetettua mallia käyttää analyysin tekemiseen. Yksi helppokäyttöisistä alustoista on erityisesti konenäön soveltamiseen tarkoitettu Amazon Lookout for vision -palvelu, joka on yksi AWS-pilvipalvelun tuotteista. Lyhyesti toimintamalli on sellainen, että palveluun ladataan kuvasarja hyvistä ja huonoista kappaleista, eli opetusdata. Tämän jälkeen palvelu laskee mallin pohjautuen ladattuihin opetuskuviin. Laskenta kestää sitä kauemmin, mitä enemmän dataa on annettu. Lähtökohtaisesti, mitä enemmän kuvia on, sitä varmempi analyysimalli saadaan aikaiseksi. Seuraavaksi palveluun ladataan testidata, eli kuvasarjat hyvistä ja huonoista kappaleista. Näillä opetettua mallia voidaan testata ja katsoa minkälaisia vastauksia mallia antaa testikuville. Opetettua mallia voidaan käyttää rajapinnan kautta osana omaa konenäköjärjestelmää, jolloin esimerkiksi tuotantolinjalta otettu kuva lähetetään tekoälymallin analysoitavaksi ja palvelu palauttaa vastauksen JSON-formaatissa. Vastaus kertoo todettiinko tutkittava kappale normaaliksi vai vialliseksi (anomalial), ja millä todennäköisyydellä päätös tehtiin.

Palvelun testaamiseksi käytettiin Bergmannin ym. (2019) tutkimuksessaan käyttämää kuvakokoelmaa erilaisista objekteista. Kokoelma sisältää kuvasarjoja erilaisista objekteista ja osassa on saatavilla myös versiot normaaleista ja viallisista objekteista. Testaamiseen valittiin kuvasarjat puupinnasta, joka on epäsäännöllinen ja usein sääntöpohjaiselle konenäölle haastava kohde. Tekoälymalli opetettiin 242 kuvalla normaalista pinnasta ja 48 kuvalla poikkeavasta pinnasta. Laskennan jälkeen palvelu antaa arvion mallin laadusta ja sen perusteella voi päätellä, onko tarpeellista opettaa mallia lisää uusilla kuvilla vai kannattaako siirtyä testausvaiheeseen.

Model performance metrics [Info](#)



Kuva. Lookout for vision -palvelun palauttama analyysi tekoälymallin laadusta.

Opetetun mallin testausvaiheen tuloksista ja palvelun tarkemmasta käytöstä voi lukea Etelä-Pohjanmaan Liiton Euroopan Aluekehitysrahastosta rahoittaman Laadusta kilpailukykyä konenäöllä (LAAKI) -hankkeen verkkosivuilta löytyvästä raportista osoitteesta:

<https://stage.dev.seamk.fi/yrityksille/tki-projektit/laadusta-kilpailukyky-konenaolla-laaki/>. Hankkeen tavoitteena on kehittää alueen pk-yritysten kilpailukykyä konenäköpohjaisen laadunvalvonnan kautta hyödyntämällä myös tekoälyn tuomia mahdollisuuksia.

Toni Luomanmäki

Projektipäällikkö, Laadusta kilpailukykyä konenäöllä (LAAKI)

SeAMK Tekniikka

Lähteet

Bergmann, P., Fauser, M., Sattlegger, D. & Steger, C. 2019. MVTec AD – A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection. [sähköinen tietoaaineisto]. MVTec Software GmbH.

<https://www.mvtec.com/company/research/datasets/mvtec-ad>