


Tässä demonstraatiodokumentissa kuvataan Amazon Lookout for vision -palvelun testaus puupinnan laaduntarkastelussa. Lookout for vision -palvelu on osa Amazonin laajaa AWS-pilvilaskentakokonaisuutta, jossa on lukuisia erilaisia työkaluja pilvi-infrastruktuurin rakentamiseen. Kuvadatanä käytetään Bergmannin ym. (2019) tutkimuksessaan käyttämää kuvakokoelmaa erilaisista objekteista. Kokoelma sisältää kuvasarjoja erilaisista objekteista ja osassa on saatavilla myös versiot normaaleista ja viallisista objekteista.

Palvelu/Ohjelmisto: Amazon Lookout for vision. Saatavilla: <https://aws.amazon.com/lookout-for-vision/>

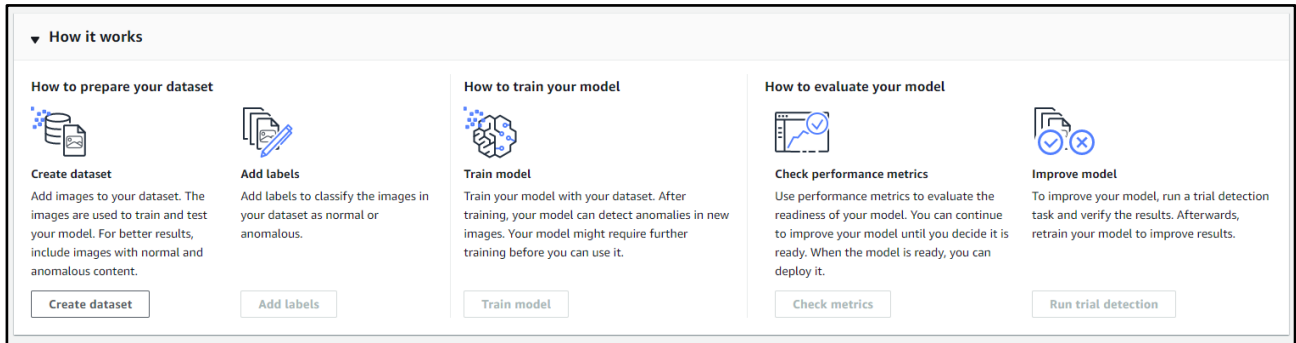
Kuvadata saatavilla: <https://www.mvtec.com/company/research/datasets/mvtec-ad>

Palvelun perusideana on konenäköanalyysin toteuttaminen pilvessä. Palvelu keskittyy anomalioiden, eli poikkeamien tunnistamiseen normaaleista kappaleista. Tekoälyyn pohjautuva luokittelumalli lasketaan opetusdatan pohjalta pilvessä, mutta myös esim. tuotantolinjalta otetut kuvat lähetetään pilveen analysoitavaksi. Palvelu palauttaa API:n kautta vastauksen, jossa on luokittelun tulos ja sen todennäköisyys. Palvelun hinnoittelu on käyttöperusteinen, jossa ainakin opetuslaskenta-aika ja varsinainen analyysiaika on hinnoiteltu erikseen. Lisäksi laskentatehoa voi skaalata, joka vaikuttaa hinnoitteluun. Seuraavassa käydään läpi palvelun perusteet analyysimallin opettamisesta ja testaamisesta.

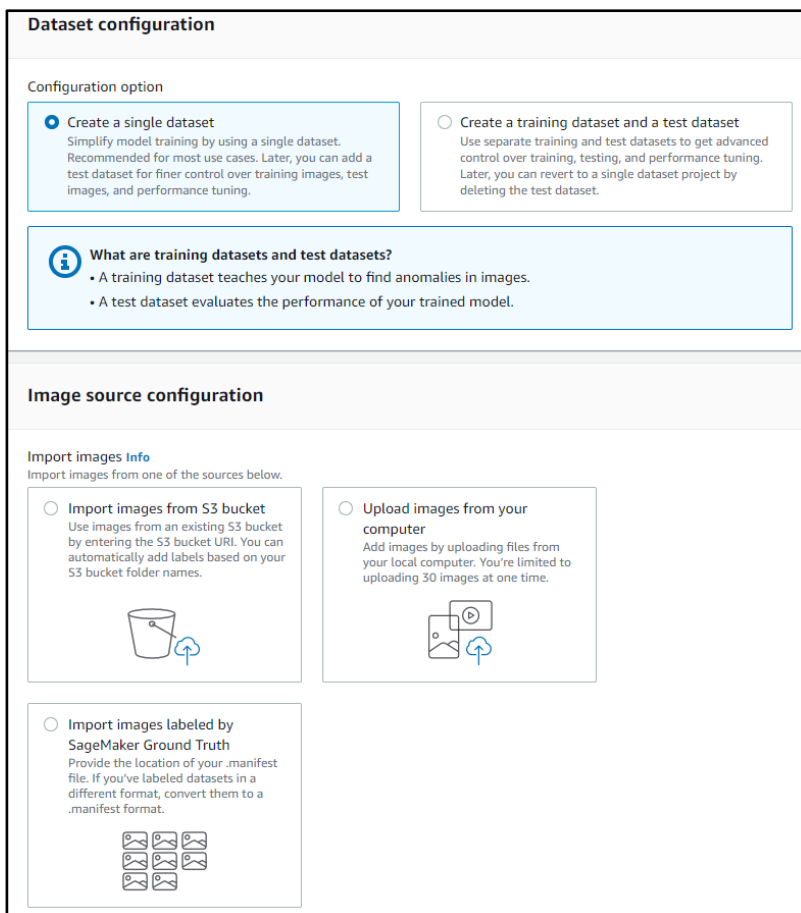
1. Palveluun kirjautumisen jälkeen aloitetaan luomalla uusi projekti.




2. Palvelu on hyvin selkeä ja hyvin ohjeistettu. Alla olevassa kuvassa on prosessin keskeisimmät vaiheet.



3. Seuraavaksi luodaan datasetti, eli määritellään opetuskuvat. Ne voidaan ladata suoraan omalta koneelta tai sitten käyttäen AWS S3 -ympäristöä, joka on datavarasto AWS-ympäristössä. Jos käytetään S3:sta, niin nimeämällä kansiorakenteen siellä normal- ja anomaly-nimillä kuvien luokittelu tehdään automaattisesti kansioiden perusteella.





4. S3-datavarastoon viitataan suoraan URilla. Kuvien automaattisen luokittelun voi halutessaan aktivoida tai deaktivoida. Kuvakoko tulee olla jokaisella kuvalla sama ja korkeintaan 8 MP kokoinen.

S3 URI

Supported image formats: JPG, PNG. Maximum images per dataset: 20,000. Maximum image size: 8 MB, Minimum size (px): 64 x 64. Maximum size (px): 4096 x 4096. Images must have the same dimensions.

Automatic labeling
To automatically label your images, create the following folder structure. Place anomalous images in the anomaly folder. Place normal images in the normal folder. Images in other folders are added as unlabeled images.

Automatically attach labels to images based on the folder name

image_folder

- anomaly
 - image icon
- normal
 - image icon
 - image icon

Cancel

5. Tuonnin jälkeen kuvat on luokiteltu automaattisesti joko normaaleiksi tai poikkeaviksi. Analyysimallin opettamiseksi palveluun ladattiin 242 kuvaa normaaleista kappaleista ja 48 kuvaa poikkeavista.

Filters


Images (290)

Labeled (290)

Unlabeled (0)

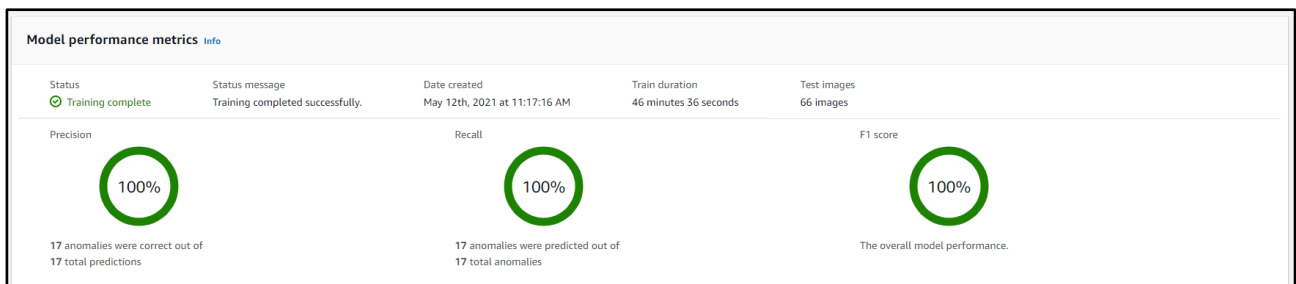
Normal (242)

Anomaly (48)




6. Seuraavaksi voidaan asettaa palvelu opettamaan analyysimallia. Palveluun pitää ladata vähintään 20 kuvaa normaaleista ja 10 kuvaa poikkeavista kappaleista, jos käytetään yhtä datasettiä opettamiseen. Suositeltavaa on kuitenkin käyttää laajempaa kuvamassaa mallin laadun parantamiseksi.

Mallin opettaminen kestää hetken aikaa riippuen kuvien määrästä ja koosta. Tänä aikana palvelusta voi kirjautua uloskin laskennan keskeytyttä. Opetuksen tulos nähdään laskennan jälkeen alla olevan kuvan mukaisesti. Opetuksen yhteydessä palvelu käyttää osan kuvista vain mallin testaamiseen.



7. Mikäli mallin laatu on riittävä, voidaan siirtyä testausvaiheeseen. Ensimmäiseen palveluun ladattiin 12 kuvaa poikkeavista kappaleista. Nämä kuvat eivät olleet opetusdatan mukana.






8. Palvelu palautti luokittelutiedon ja onnistui luokittelemaan kaikki kuvat virheelliseksi

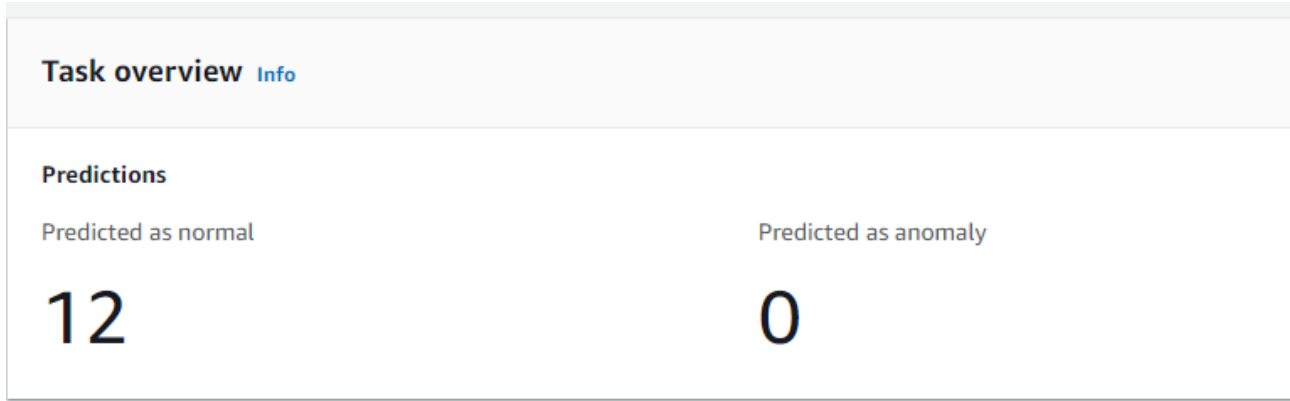
Task overview Info	
Predictions	
Predicted as normal	Predicted as anomaly
0	12

9. Seuraavaksi ladattiin 12 kuvaa normaaleista tuotteista. Myöskään nämä kuvat eivät olleet osana opetusdataa.





10. Palvelu palautti luokittelutiedon ja onnistui luokittelemaan kaikki kuvat normaaleiksi.



11. Testiajojen tulokset voidaan liittää osaksi mallia ja opettaa se uudestaan. Järjestelmälle kerrotaan, miten testiajo meni ja mahdolliset väärät tunnistukset luokitellaan vääräksi, jolloin järjestelmä ottaa ne huomioon mallia päivittäessään.

Kokonaisuutena palvelu toimi vakuuttavasti haastavallakin tunnistusongelmalla. Palvelu on erittäin yksinkertainen käyttää, mutta mallin opettamiseen tai säätämiseen ei juurikaan ole mahdollisuuksia. Valmista analyysimallia on mahdollista käyttää osana omaa ohjelmistoa rajapinnan kautta ja palveluun löytyy jo valmis SDK, jolla integraatio onnistuu. Tätä ei kuitenkaan vielä tässä yhteydessä testattu, mutta mielenkiintoista olisi saada tuloksia siitä, miten kauan koko sykli kestää kuvanotosta analyysin valmistumiseen asti.

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>