



Beeldherkenning voor verzekeringsdoeleinden



In de nabije toekomst zou beeldherkenning een plaats kunnen krijgen in de processen van verzekeraars, bijvoorbeeld voor het inschatten van autoschades op basis van foto's. Hiervoor zijn specifieke machine-learningtechnieken nodig. In dit artikel wordt hier verder op ingegaan door middel van een concreet voorbeeld.

1. ACHTERGROND

Machine-learningmodellen zijn aan een opmars bezig binnen het werkveld van verzekeraars. De meeste verzekeraars onderzoeken de mogelijkheden voor de toepassing van deze modellen voor onder andere pricing, fraudedetectie en reservering. Veelal zijn dit echter doeleinden waarvoor ook meer traditionele actuariële modellen (zoals lineaire of logistische regressie) kunnen worden gebruikt.

In de nabije toekomst zou beeldherkenning ook een plaats kunnen krijgen in de processen van verzekeraars, bijvoorbeeld voor het inschatten van autoschades op basis van foto's. Daarvoor zijn traditionele actuariële modellen niet toereikend, en zijn specifieke machine-learningtechnieken nodig.

2. STRUCTUUR VAN DE DATA

Om te begrijpen hoe machine-learningmodellen beelden kunnen herkennen, is het van belang om de structuur van de data (lees: afbeeldingen) te kennen. Een afbeelding is opgebouwd uit een heleboel pixels. Elke pixel heeft een specifieke kleur. Deze kleur is opgebouwd uit een bepaalde hoeveelheid rood, groen en blauw. De hoeveelheid van ieder van deze kleuren in een pixel wordt weergegeven met een getal tussen 0 en 255. Dit is geïllustreerd in figuur 1. De linkerzijde van de figuur toont een hoe een foto van een gezicht is opgebouwd, aan de rechterzijde wordt ingezoomd op het linkeroog. Bovenstaande betekent dat een afbeelding in zijn geheel kan worden uitgedrukt als een reeks getallen, en deze reeks getallen dient derhalve als input voor het model.

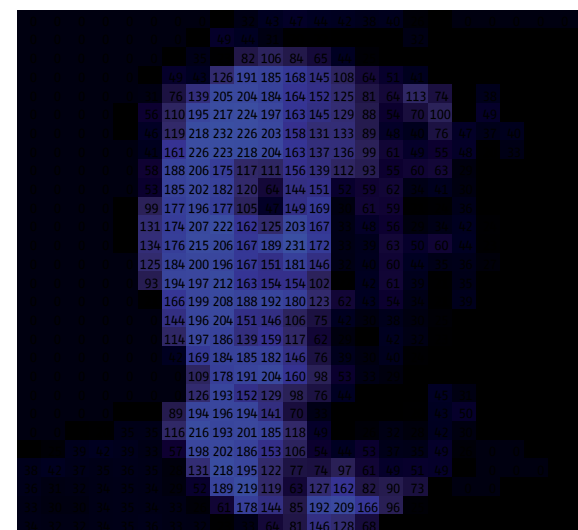

Dr. R. Plat AAG RBA is eigenaar van Richard Plat Consultancy en geeft in die hoedanigheid advies aan verzekeraars en pensioenfondsen op het gebied van waardering en risicomanagement.



226	178	172
229	167	133
229	143	112

190	132	127
197	134	81
192	111	54

175	117	111
182	120	64
177	105	67




Figuur 1: opbouw afbeelding gezicht (links), linkeroog ingezoomd (rechts)¹

3. VOORBEELD

Hieronder wordt een simpel voorbeeld uitgewerkt, waarbij het doel van het model is om te herkennen of een auto schade heeft of niet. Indien een verzekeraar meer specifieke informatie verzamelt, zoals de hoogte van de schade, kan het model verder verfijnd worden.

3.1 Data

De beschikbare dataset² voor 'training' (kalibratie) van het model bevat 1840 foto's van auto's, waarvan de helft schade heeft. Voor validatie van het model zijn in totaal 460 foto's beschikbaar, ook gelijk verdeeld over auto's met en zonder schade. Voorbeelden van foto's in de dataset zijn gegeven in figuur 2.

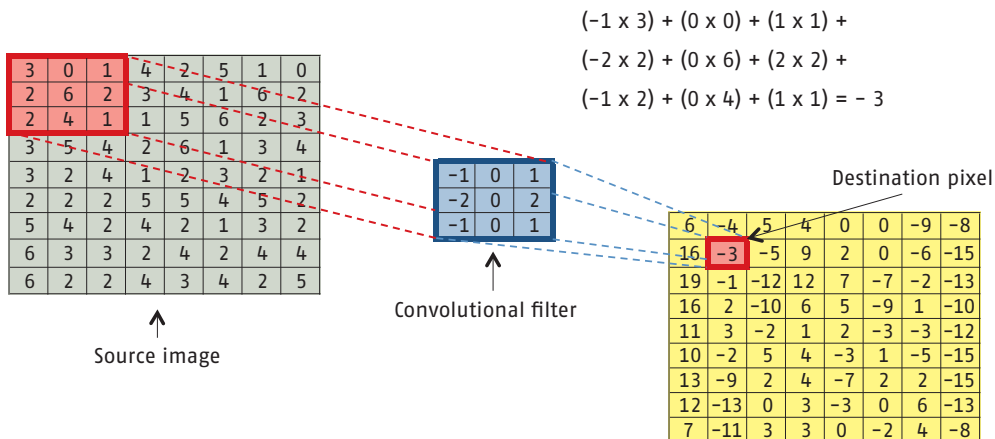


Figuur 2: voorbeelden uit dataset zonder schade (links) en met schade (rechts)

3.2 Gebruikte machine-learningmodellen

Er zijn een veelheid van machine-learningmodellen beschikbaar, zoals verschillende regressiemodellen, beslisboomgebaseerde methodes en neurale netwerken³. Voor beeldherkenning is het zogenaamde 'convolutional neural network' (CNN)⁴ al enige jaren de state of the art. Een CNN is een soort neurale netwerk met specifieke kenmerken die het geschikt maken voor beeldherkenning. Een belangrijk element daarbij is de 'convolutional filter', waarvan de werking is weergegeven in figuur 3.





Figuur 3: voorbeeld werking convolutional filter

De figuur laat zien dat de convolutional filter, welke in dit voorbeeld bestaat uit 9 te kalibreren gewichten, met eenvoudig vermenigvuldigen een vlak van 3x3 pixels vertaalt naar één getal. Door dit filter te verschuiven over het gehele beeld ontstaat er uiteindelijk een nieuw beeld, waarbij de samenhang tussen aaneengesloten pixels in het originele beeld is geadresseerd door middel van de filters. Op deze manier kan het model patronen in het beeld herkennen. Er kunnen meerdere filters tegelijk toegepast worden op een beeld, die verzameld worden in één laag van het model. Het model bestaat uit verschillende lagen. Naast de filters bevat het model lagen waarbij ofwel een niet-lineaire operatie wordt toegepast, ofwel de grootste waarden worden verzameld ('pooling' laag). Gedurende de training leert het CNN de gewichten behorende bij de filters of de andere lagen. De kracht van het model is dat door de structuur met lagen met filters het automatisch:

- gedetailleerde kenmerken herkent zoals randen, kleurveranderingen en vormen;
- op basis hiervan vormen herkent, gevolgd door kenmerken zoals gezichten, delen van een auto, et cetera;
- tot slot op basis van deze kenmerken een inschatting maakt van wat er op de afbeelding staat (met bijbehorende kansen).

Een CNN model heeft veel parameters, wat impliceert dat er ook heel veel afbeeldingen nodig zijn om het model betrouwbaar te kunnen schatten. Die zijn over het algemeen niet beschikbaar bij verzekeraars voor dit soort doeleinden. Een oplossing hiervoor kan zijn om een reeds bestaand (en gekalibreerd) CNN als basis te nemen en alleen de laatste laag te (her)kalibreren op basis van de beschikbare dataset. Dit heet 'Transfer Learning'. In het voorbeeld in dit artikel is hiervoor het zogenaamde 'VGG16'⁵ model gebruikt, gekalibreerd aan de bekende ImageNet dataset (met ongeveer 15 miljoen afbeeldingen).

3.3 RESULTATEN

Op de dataset zijn 5 verschillende CNN varianten toegepast, waarbij gevarieerd is in onder andere het aantal lagen en het aantal filters per laag. Daarnaast is ook een Transfer Learning aanpak toegepast op basis van VGG16. De modellen zijn gekalibreerd aan de training dataset, en vervolgens is de nauwkeurigheid van de modellen gemeten op basis van de validatie dataset. De resultaten zijn weergegeven in tabel 1.

Model	Nauwkeurigheid
CNN variant 1	77,7%
CNN variant 2	72,3%
CNN variant 3	69,4%
CNN variant 4	75,7%
CNN variant 5	78,6%
CNN / VGG16	93,0%

Tabel 1: nauwkeurigheid verschillende CNN modellen

De tabel toont aan dat de nauwkeurigheid van de normale CNN varianten niet boven de 80% uitkomt. Daarnaast is er waarschijnlijk sprake van overfitting, omdat er miljoenen parameters gebruikt worden. De kwaliteit van Transfer Learning op basis van het VGG16 model laat significant betere resultaten zien. Kennelijk zijn de op basis van de algemene ImageNet dataset gekalibreerde parameters goed toepasbaar als basis voor specifieke datasets zoals de dataset in dit artikel.

4. CONCLUSIE

De resultaten in dit artikel impliceren dat bij beeldherkenning een hoge nauwkeurigheid bereikt kan worden met een relatief kleine dataset. Als verzekeraars datasets verzamelen met meer afbeeldingen van schades alsmede de bijbehorende kosten van de schades, dan zouden dit soort modellen een plaats kunnen krijgen in de processen van verzekeraars om de hoogtes van autoschades automatisch te kunnen inschatten. Ook voor alle andere (toekomstige) doeleinden waarbij afbeeldingen een rol spelen, kunnen de in dit artikel genoemde modellen gebruikt worden. ■

1 – Bron: <https://towardsdatascience.com/cutting-edge-face-recognition-is-complicated-these-spreadsheets-make-it-easier-e7864dbf0e1a>

2 – Bron: <https://github.com/halloTheCoder/car-damage-evaluation-using-deep-learning/tree/master/code>

3 – Zie Plat – 'Data Science en mMachine Learning: concreet voorbeeld verzekeringsportefeuille', De Actuaris (september 2017).

4 – Zie bijvoorbeeld <https://medium.freecodecamp.org/an-intuitive-guide-to-convolutional-neural-networks-260c2de0a050>

5 – http://www.robots.ox.ac.uk/~vgg/research/very_deep/