

Cómo Alemania respondió a inundaciones con la ayuda de tecnología espacial?

Gina Maricela Schwendemann

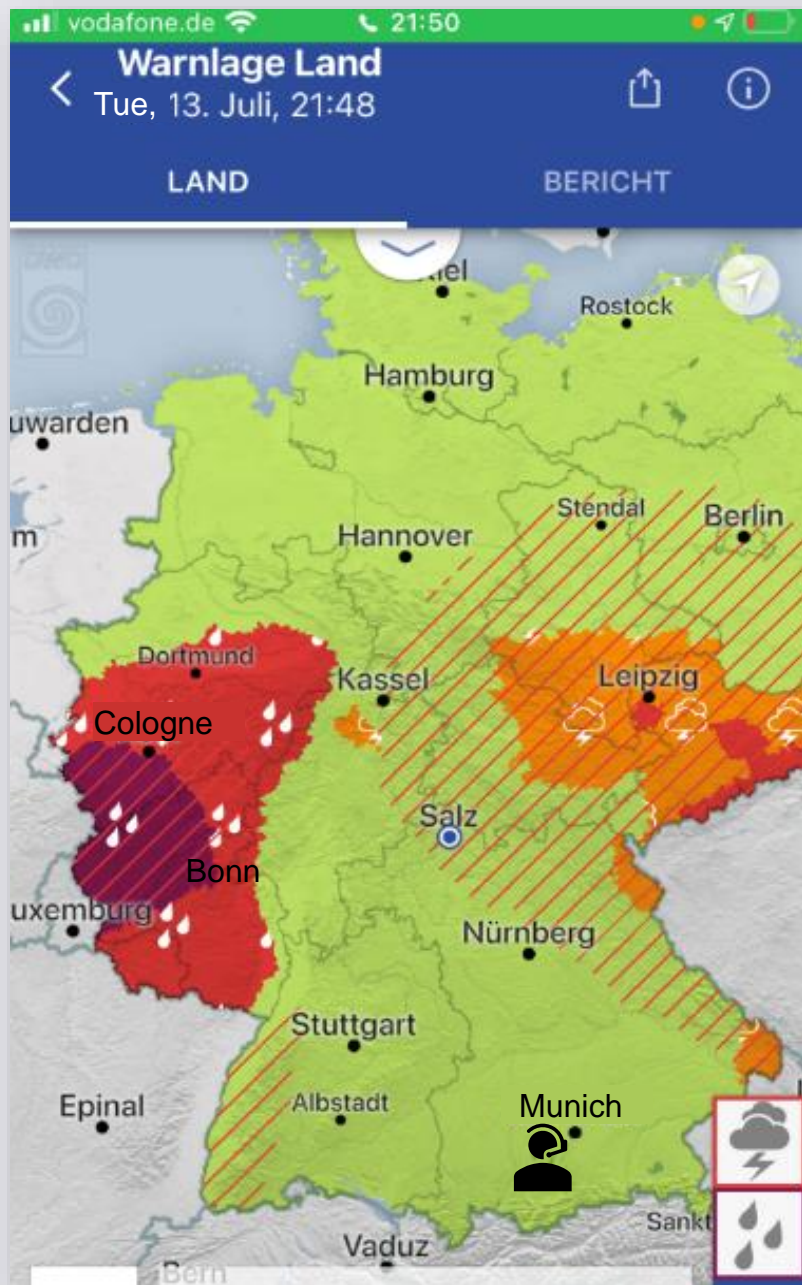
ONU-SPIDER Conferencia Regional de Expertos en
Latinoamerica

Munich, 23. Nov. 2021



Wissen für Morgen





Miércoles, 14 Julio 2021



Norte de Renania Westfalia y Renania Palatina

Agua acumulada del Martes al Jueves en la mañana será de 80-180/200 l/m².

La inundación ocurrió en la noche del 14 July 2021



Viernes, 16 Julio 2021



DLR



Bayerisches Rotes Kreuz



Federal Office of Civil Protection and Disaster Assistance



by DFD/DLR



Artificial Intelligence for Emergency Response



29 Empleados



DLR



Center for Satellite Based Crisis Information
– Emergency Mapping & Disaster Monitoring –
a service of DFD



©Uwe Kippnich





Horas de vuelo

31 (Avioneta),
17(Helicoptero)



Datos enviados


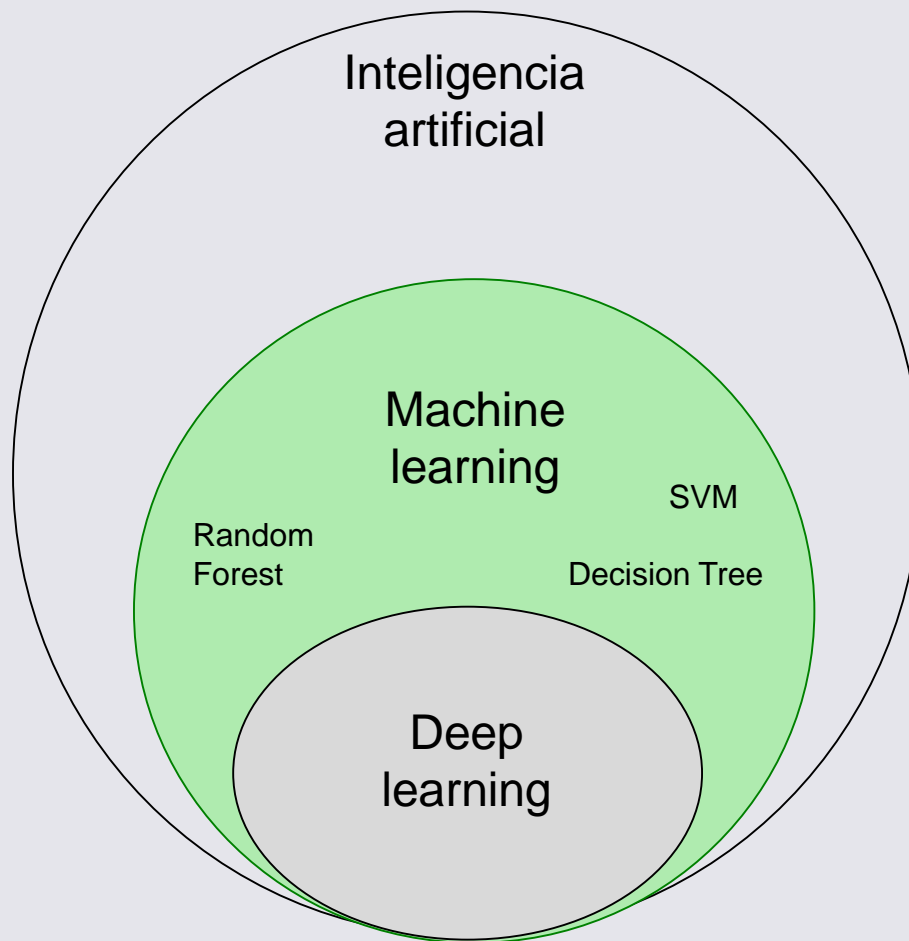
~ 600 GB



El software aprende y piensa como seres humanos

El algoritmo aprende sin haber sido explícitamente programado



Red Neuronal Artificial aprende de grandes cantidades de datos




```

41 // CLASSIFY WATER
42 //=====
43 var classifyWater = function(img) {
44   var vv = img.select('VV_Filtered');
45   var water = vv.lt(-16).rename('Water'); //Identify all pixels below threshold and set them equal to 1.
46   //All other pixels set to 0
47   water = water.updateMask(water); //Remove all pixels equal to 0
48
49

```



Identificación de inundaciones aplicando los métodos de Machine learning en Sentinel-1 (SAR imagen), 10 m resolución. Erfstadt, 16 Julio 2021



Mosaico de fotografías aéreas de Erfstadt del Viernes 16 de Julio y el Domingo 18 de Julio del 2021. Combinación de bandas RGB, 0.15 m resolución




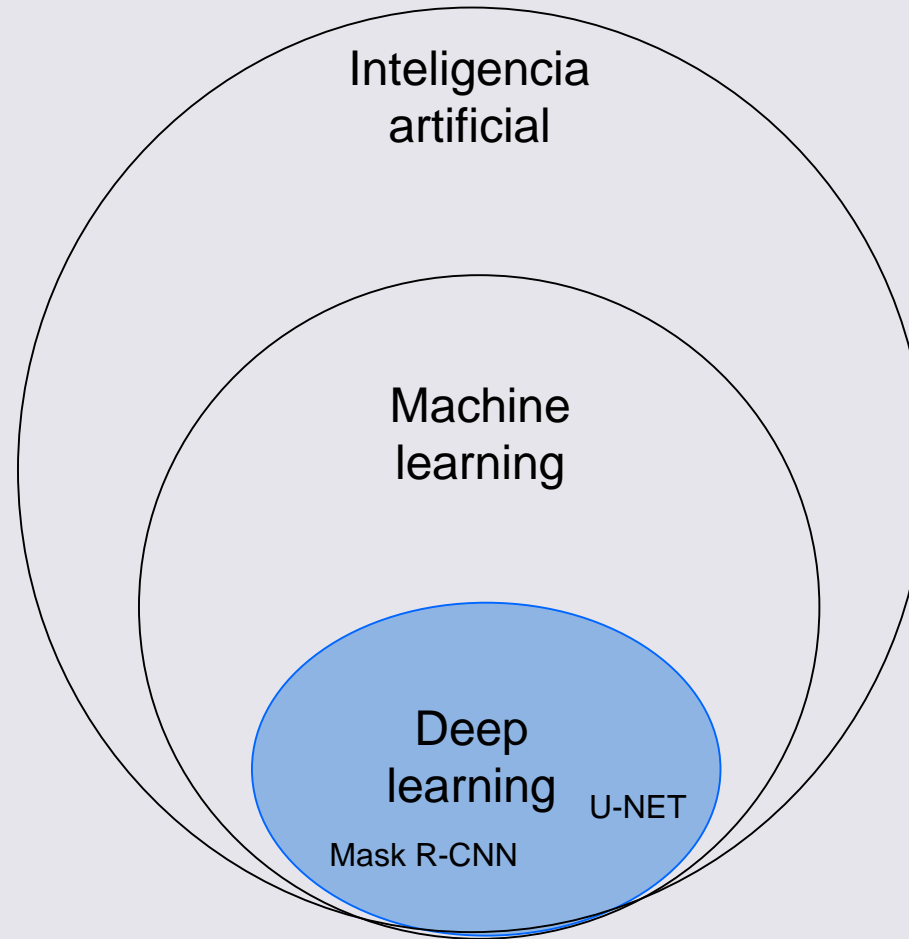
Resultados sin editar de daños por inundación con la ayuda de Deep learning



El software aprende y piensa como seres humanos

El algoritmo aprende sin haber sido explícitamente programado

Red Neuronal Artificial aprende de grandes cantidades de datos




CNN – Red Neuronal Artificial



Source: www.medium.com

Deep Learning Neural Network

Source: <https://towardsdatascience.com/>

```

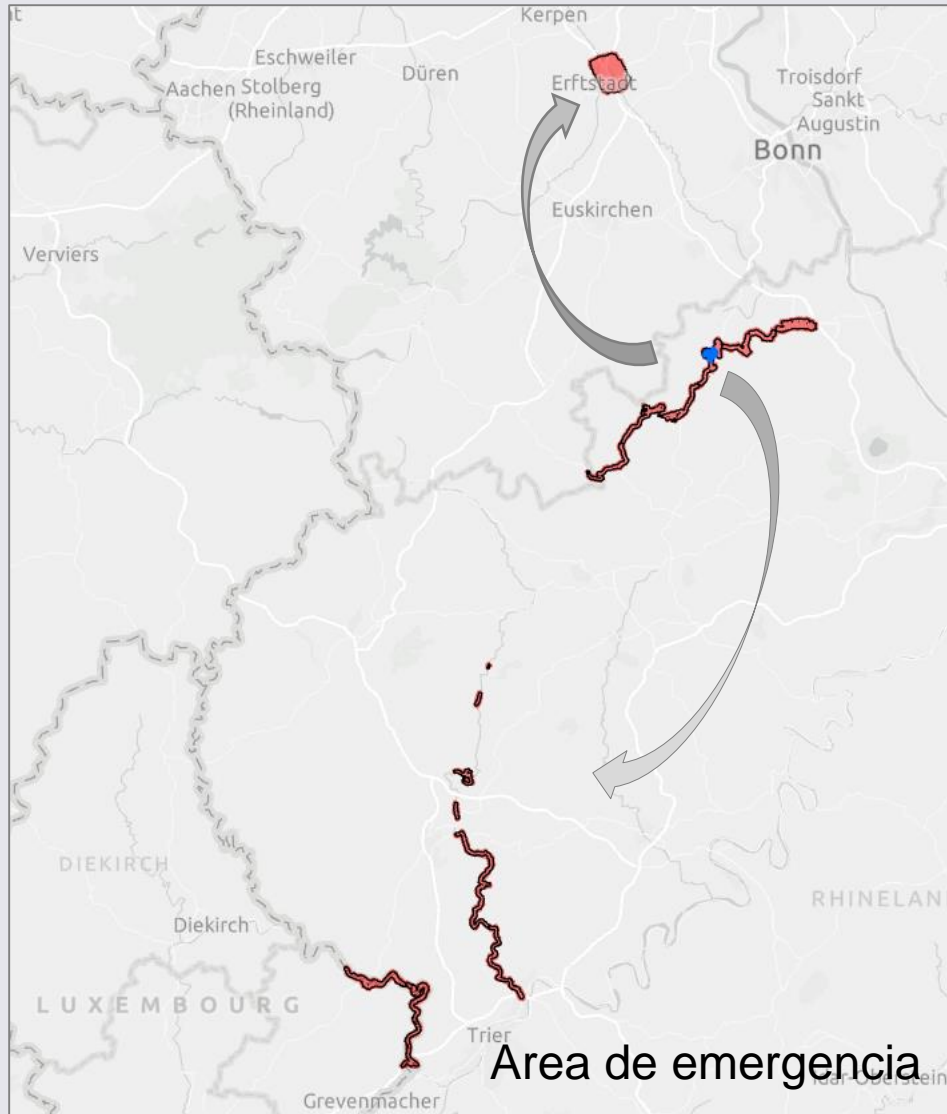
X_train = X_train.reshape(-1,28,28,1)
X_test = X_test.reshape(-1,28,28,1)

model = tf.keras.models.Sequential() # 28*28
model.add(tf.keras.layers.Conv2D(32, (3, 3), padding = 'same', activation=tf.nn.relu,
                                input_shape=(28, 28, 1))) # 28*28*32
model.add(tf.keras.layers.Dropout(0.5)) # 28*28*32
model.add(tf.keras.layers.MaxPooling2D((2, 2))) # 14*14*32
model.add(tf.keras.layers.Conv2D(64, (3, 3), padding = 'same', activation=tf.nn.relu)) # 14*14*64
model.add(tf.keras.layers.Dropout(0.5)) # 14*14*64
model.add(tf.keras.layers.MaxPooling2D((2, 2))) # 7*7*64


```



Deep learning en tu rutina diaria



Muestras en azul



Deep learning en tu rutina diaria



python™



Geoprocessing

Export Training Data For Deep Lear...

Parameters Environments

* Input Raster

Additional Input Raster

* Output Folder

Input Feature Class Or Classified Raster Or Table

Class Value Field

Buffer Radius

Input Mask Polygons

Image Format
TIFF format

Tile Size X

Tile Size Y

Stride X

Stride Y

Rotation Angle

Reference System
Map space

Output No Feature Tiles

Metadata Format
RCNN Masks

Run

jupyter DE_Flood_damage_with_MaskRCNN_model Last Checkpoint: 04.08.2021 (autosaved)

Flood damage detection with Mask RCNN model

```
In [1]: import arcgis
from arcgis.learn import MaskRCNN, prepare_data

In [2]: data = prepare_data(path='C:\...',
batch_size = 4,
chip_size = 400) #chip 400, stride 0

In [3]: data.show_batch(rows = 2, alpha = 0.3, statistics_type='DRA')
```

```
In [4]: model = MaskRCNN(data) #model = MaskRCNN(data = data, pointer

In [5]: lr = model.lr_find()
```

```
In [6]: # Training
model.fit(30, lr = lr) #model.lr_find() #model.fit(epochs=10,
```

epoch	train_loss	valid_loss	time
0	4.196047	3.385234	00:46
1	2.805269	2.355183	00:46
2	2.070822	1.951641	00:46

Detect Objects Using Deep Learning

Parameters Environments

* Input Raster

* Output Detected Objects

* Model Definition

Arguments

Name	Value
<input type="text"/>	<input type="text"/>

Non Maximum Suppression

Run





Imágen del 30 de Junio 2019



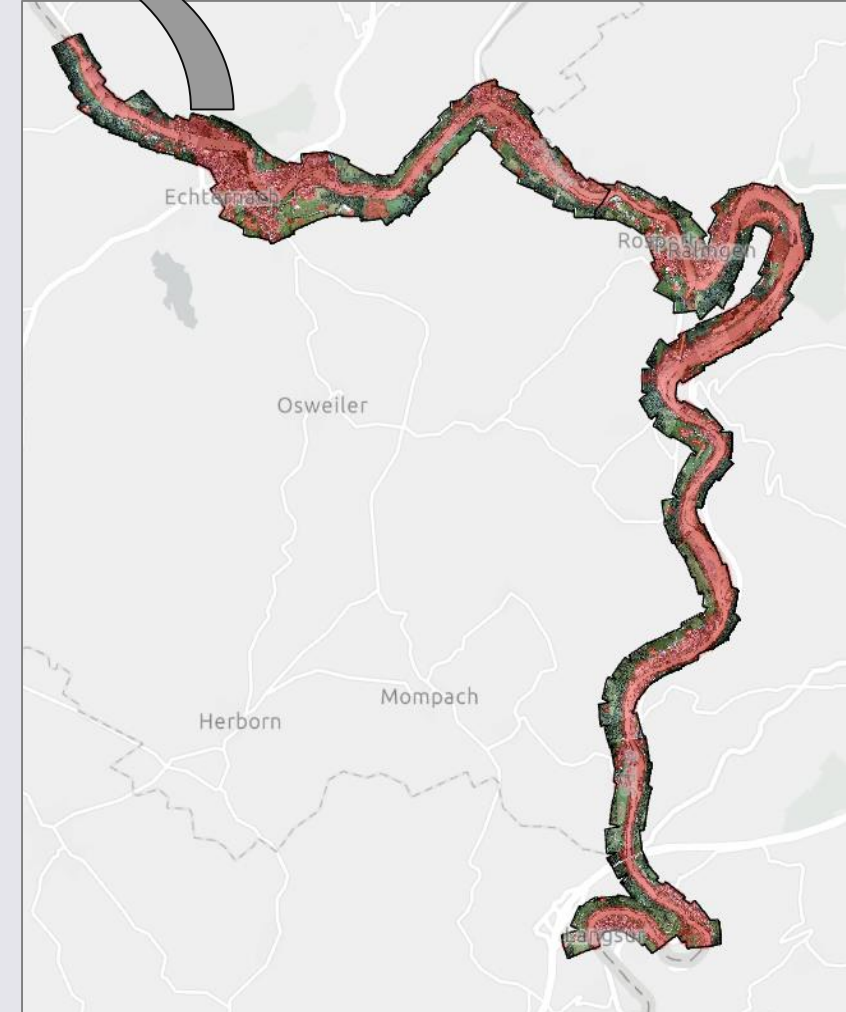
Imágen del 16 Julio 2021



Resultado sin editar del método Deep learning



Resultados editados (mejorados)






Center for Satellite Based
Crisis Information (ZKI)

Search

- Research and Development
- Services and Operations
- News Archive
- Activations
- FAQs
- Contact



en/desktopdefault.aspx/tabid-5231/

ZKI Cornerstones



IF-Bund

Innovative Remote Sensing
for the German Federal
Administration



Europe

Participation in the European

www.zki.dlr.de

11 años apoyando a países
alrededor del mundo en
emergencias naturales o
humanas

Productos/datos enviados
en Julio 2021



Maps
26



Images
~ 40,000



Center for Satellite Based Crisis Information
– Emergency Mapping & Disaster Monitoring –
a service of DFD



Domingo, 25 Julio 2021



Center for Satellite Based Crisis Information
- Emergency Mapping & Disaster Monitoring -
a service of DFD




Generador de emergencia



SpaceX internet – Star Link Fuente de alimentación energética móvil




Viernes, 29 Octubre 2021




Algunas cifras


- Las inundaciones el 14 de Julio del 2021 causó 182 Muertos en Renania del Norte Westfalia y Renania Palatina.
- Mapas fueron un excelente instrumento para que los jefes, coordinadores tomen decisiones.
- Es necesario tener un experto en seguridad en la zona in-situ para coordinar las operaciones de rescate e interpretar el análisis de los mapas.
- Los daños de las inundaciones es estimada en 29 Mi. EUR.



56,000
Habitantes



17,000
Lost their
posessions



4,200
Casas /
edificios



3,000
Casas
afectadas



467
Casas
destruidas



Source: www.swr.de



Cómo Alemania respondió a inundaciones con la ayuda de tecnología espacial?

Gina Schwendemann

gina.schwendemann@dlr.de

zki@dlr.de

