

Sistem Deteksi Kecacatan Ban Dengan *Convolutional Neural Network*

1st Krisna Prayoga
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

krisnaprayoga@student.telkomuniversit
y.ac.id

2nd Rita Magdalena
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

ritamagdalenat@telkomuniversity.ac.id

3rd Sofia Saidah
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

sofiasaidahsfi@telkomuniversity.ac.id

Abstrak— Produksi kendaraan setiap tahun semakin meningkat, Setiap tahunnya pabrik kendaraan memproduksi ribuan kendaraan untuk memenuhi kebutuhan pasar disetiap negara. Ban adalah komponen sangat penting dalam suatu kendaraan, ban yang tidak maksimal atau cacat sering kali menimbulkan kecelakaan mulai dari kecelakaan ringan hingga fatal, memilih ban yang baik sangat dibutuhkan agar ketika kendaraan sedang melaju tidak menimbulkan kecelakaan seperti pecah ban atau ban tergelincir. Tujuan dari penelitian ini adalah melakukan analisis kerja sistem dalam mengidentifikasi ban yang dalam kondisi bagus dengan ban dalam kondisi rusak atau cacat. Penelitian Tugas Akhir ini meneliti bagaimana cara memilih ban yang baik dengan mengklasifikasikan ban kedalam 2 kategori yaitu ban yang bagus dengan ban yang cacat menggunakan metode Convolutional Neural Network (CNN) menggunakan CNN lima layer dan menguji paramter yang akan digunakan kedalam sistem untuk mengetahui parameter yang terbaik agar menghasilkan akurasi yang tinggi. Di dalam penelitian ini bisa diketahui hal-hal yang mempengaruhi performansi sistem, akurasi terbaik yang diperoleh dari penelitian ini yaitu 88% dengan menggunakan 1.039 sampel citra serta menggunakan parameter size 224x224, Optimizer Adam, Learning Rate 0.0001, Epoch 80, dan Batch size 16.

I. PENDAHULUAN

Setiap tahun produksi kendaraan semakin meningkat. Hal itu terjadi karena banyaknya kebutuhan setiap orang untuk mempunyai kendaraan sendiri, setiap tahunnya pabrik kendaraan memproduksi ribuan kendaraan untuk memenuhi kebutuhan pasar disetiap negara. Salah satu contoh adalah pada tahun 2015 pabrik Toyota di sunter memproduksi 195.000 unit mesin setiap tahunnya [1]. Saat ini banyak masyarakat indonesia sudah memiliki kendaran khususnya mobil, ada yang mempunyai 1 mobil hingga 3 mobil sesuai dengan kebutuhan anggota keluarganya, sering kali karena banyaknya kesibukan atau banyaknya kendaraan kita tidak memperhatikan hal penting seperti kondisi ban apakah masih dalam keadaan layak pakai atau tidak.

Ban adalah komponen sangat penting dalam suatu kendaraan karena berkaitan dengan keselamatan berkendara, ban yang tidak maksimal atau cacat sering kali menimbulkan kecelakaan mulai dari kecelakaan ringan hingga fatal. Komite Nasional Keselamatan Transportasi (KNKT) menyebutkan bahwa 80% kecelakaan di jalan Tol disebabkan oleh pecah ban [9], untuk itu memilih ban yang baik sangat dibutuhkan agar ketika kendaraan sedang melaju tidak menimbulkan kecelakaan seperti pecah ban atau ban tergelincir. Banyak para ahli yang meneliti bagaimana ban yang cacat bisa terjadi dan bagaimana cara mengatasi masalah tersebut agar ban yang dihasilkan oleh pabrik ban sangat maksimal.

II. KAJIAN TEORI

A. Ban Kendaraan

Ban Kendaraan adalah suatu *sparepart* lunak yang melindungi velg roda untuk mengurangi getaran yang disebabkan oleh ketidakrataan permukaan jalan [2]. Secara umum ban digunakan agar velg tidak bersentuhan langsung dengan permukaan jalan sehingga akan lebih stabil dan nyaman dalam berkendara.



GAMBAR 1
(Kembang Ban [2])

B. Ban Cacat

Ban yang cacat adalah kondisi ban yang mengalami kerusakan sehingga menurunkan kualitas dari ban tersebut, hal bisa terjadi karena usia ban,

faktor lintasan yang dilewati, ataupun benda tajam yang dapat merusak ban secara langsung. Umumnya usia ban sangat mempengaruhi kualitas dari ban, ban yang sudah berusia tua akan mengakibatkan karet sebagai bahan dasar ban mengeras sehingga ban akan mudah pecah atau retak, ban yang keras akan mempengaruhi daya lekat ban terhadap aspal sehingga rawan menimbulkan kecelakaan. Berikut adalah contoh ban yang baik dan ban yang cacat



GAMBAR 2
(Ban Cacat)

C. Warna RGB

Model warna RGB adalah model warna yang terdiri dari tiga warna yaitu Red (R), Green (G) dan Blue (B). Model warna RGB digunakan untuk display pada layar komputer, RGB dipatenkan oleh CIE (Commission International de l'Eclairage) atau International Lighting Committee adalah suatu lembaga yang membakukan warna pada tahun 1931. CIE menstandarkan panjang gelombang warna-warna pokok sebagai berikut [3]:


R : 700 nm G : 546.1 nm

B : 435.8 nm

D. Deep Learning

Deep Learning merupakan cabang dari *Machine Learning* berbasis jaringan syaraf tiruan yang terinspirasi dari korteks manusia dengan menerapkan jaringan syaraf buatan yang memiliki banyak hidden layer. *Convolutional Neural Network* (CNN) merupakan salah satu metode dalam Deep Learning yang dibuat untuk menutupi kelemahan dari metode sebelumnya.

Terdapat beberapa kelemahan dalam metode sebelumnya, tetapi dengan model ini sejumlah parameter bebas dapat dikurangi dan deformasi




GAMBAR 3
(Deep Learning)

gambar input seperti translasi, rotasi dan skala dapat ditangani [5].

E. Convolutional Neural Network (CNN)


Convolutional Neural Network (CNN) adalah pengembangan dari *Multilayer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Pada kasus klasifikasi citra, MLP kurang sesuai untuk digunakan karena tidak menyimpan informasi spasial dari data citra dan menganggap setiap piksel adalah fitur yang independen sehingga menghasilkan hasil yang kurang baik [6]. CNN umumnya terdiri dari lapisan konvolusi, *pooling layer*, dan *fully connected layer* yang bekerja secara hierarkis, sehingga output di hasil sebelumnya akan menjadi input pada proses selanjutnya.



GAMBAR 4
(Arsitektur CNN)

F. Convolutional Layer

Convolution Layer melakukan operasi konvolusi pada output dari layer sebelumnya. Layer tersebut adalah proses utama yang mendasari sebuah CNN. Konvolusi adalah suatu istilah matematis yang berarti mengaplikasikan sebuah fungsi pada output fungsi lain secara berulang. Dalam pengolahan citra, konvolusi berarti mengaplikasikan sebuah kernel pada citra disemua offset yang memungkinkan. Kotak abu secara keseluruhan adalah citra yang akan dikonvolusi. Kernel bergerak dari sudut kiri atas ke kanan bawah. Sehingga hasil konvolusi dari citra tersebut dapat dilihat pada gambar disebelah kanannya. Tujuan dilakukannya konvolusi pada data citra adalah untuk mengekstraksi fitur dari citra input. Konvolusi akan menghasilkan transformasi linear dari data input sesuai informasi spasial pada data. Bobot pada layer tersebut menspesifikasikan kernel konvolusi yang digunakan, sehingga kernel konvolusi dapat dilatih berdasarkan input pada CNN




GAMBAR 5
(Operasi Konvolusi)

G. Pooling Layer

Pooling layer adalah lapisan dari CNN yang berfungsi untuk mengurangi ukuran spasial dari fitur konvolusi sehingga dapat mengurangi sumber daya komputasi yang dibutuhkan untuk memproses data melalui pengurangan dimensi dari *feature map*

(*downsampling*) sehingga mempercepat komputasi karena paramter yang diperbarui semakin sedikit.

Pooling layer terbagi kedalam dua jenis, yaitu *max pooling* dan *average pooling*. *Max pooling* adalah mengembalikan nilai maksimum dari bagian gambar yang dicakup oleh kernel sedangkan *average pooling* adalah mengembalikan nilai rata – rata dari bagian gambar yang dicakup oleh kernel [8]



GAMBAR 6
(Pooling Layer)


H. Dropout

Dropout adalah salah satu teknik regularisasi jaringan syaraf tiruan, beberapa neuron akan dipilih secara acak dan tidak dipakai selama pelatihan. Neuron neuron ini dapat dibuang secara acak. Hal ini berarti bahwa kontribusi neuron yang dibuang akan diberhentikan sementara jaringan dan bobot baru juga tidak diterapkan pada neuron pada saat melakukan *backpropagation* [9].

Dropout merupakan proses mencegah terjadinya *overfitting* [9] dan juga mempercepat proses *learning*. *Dropout* mengacu kepada menghilangkan neuron yang berupa hidden mapun layer yang visible didalam jaringan. Dengan menghilangkan suatu neuron, berarti menghilangkannya sementara dari jaringan yang ada. Neuron yang akan dihilangkan akan dipilih secara acak. Setiap neuron akan diberikan probabilitas yang bernilai antara nol dan satu [9].

I. Flattening

Flattening adalah salah satu proses dari CNN untuk mengkonversikan hasil array 2 dimensi pada operasi *convolutional pooling* menjadi vektor linear panjang yang terus menerus. Proses dari *flattening* yaitu mengambil baris demi baris dari inputan dan menggabungkannya menjadi satu kolom, setelah itu dilanjutkan dengan baris kedua sampai dengan baris terakhir seperti gambar dibawah ini



GAMBAR 7
(Proses Flattening)

J. Subsampling Layer


Subsampling adalah proses mereduksi ukuran sebuah data citra. Dalam pengolahan citra,

subsampling juga bertujuan untuk meningkatkan invariansi posisi dari fitur. Dalam sebagian besar CNN, metode subsampling yang digunakan adalah *max pooling*

III METODE

A. Desain Sistem

Pada Tugas Akhir ini akan meneliti dan mengklasifikasikan antara ban yang dalam kondisi bagus dengan ban yang terdapat kecacatan dengan menggunakan *Convolutional Neural Network* dengan model ditunjukkan pada gambar berikut.



GAMBAR 8
(Diagram Blok Sistem)

B. Parameter Performansi Sistem

Pengujian pada sistem adalah tahapan yang paling penting untuk menunjukkan seberapa besar keberhasilan suatu sistem yang sudah dirancang dan dilakukan beberapa analisis terhadap hasil pengujian tersebut, sehingga bisa diketahui kelebihan dan kekurangannya. Perangkat keras yang digunakan untuk membangun dan menguji sistem memiliki spesifikasi sebagai berikut :

1. Laptop Accer Aspire 4740
2. Processor: Intel® Core™ i3-6200U
3. CPU @2.30GHz 2.40GHz
4. RAM: 2 GB
5. Hard Disk Drive: 394 GB

Perangkat lunak yang digunakan untuk membangun dan menguji sistem memiliki spesifikasi sebagai berikut:

1. Sistem Operasi Windows 7 64bit
2. Aplikasi Google Drive
3. Aplikasi Google Colab
4. Microsoft Office 2010

Untuk menghasilkan akurasi yang tinggi maka diperlukan pengujian dari parameter-parameter yang digunakan, kami melakukan beberapa tahap pengujian seperti mencari nilai *Resize* terbaik, menentukan *Optimizer*, menentukan nilai *Learning Rate*, *Epoch*, dan *Batch Size*. Saat memulai pengujian kami menggunakan citra RGB dengan total sebanyak 1.039 dengan rincian citra ban kondisi bagus sebanyak 540 dan citra ban cacat sebanyak 499. Kami menggunakan test size 0,2 yaitu citra uji 20% dan citra training 80%.

IV HASIL DAN PEMBAHASAN

Pada pengujian sistem terbagi menjadi dua bagian, yaitu *training* dan *testing*. Hasil dari pengujian sistem ini berupa Akurasi, *Loss*, *Presisi*,

Recall dan *F1-Score*, Pengujian dilakukan menggunakan aplikasi *Google Colaboratory* dengan parameter *Resize*, *Optimizer*, *Learning rate*, *Epoch* dan *Batch Size*.

A. Pengujian Resize

Pengujian *resize* adalah pengujian yang pertama kali dilakukan, tujuannya untuk mencari ukuran citra yang cocok dengan sistem agar menghasilkan *output* yang maksimal, kami melakukan tiga test terhadap ukuran-ukuran citra yaitu 64x64, 128x128, dan 224x224 dengan parameter awal yaitu *Optimizer Adam*, *Learning rate* 0.0001, *Epoch* 50 dan *Batch Size* 16. Berikut adalah hasil pengujiannya:

TABEL 1
(Hasil Pengujian Ukuran Citra)

Resize	Akurasi	Loss	Precision	Recall	F1-Score
64x64	0.78	0.69	0.81	0.81	0.81
128x128	0.78	0.66	0.79	0.85	0.82
224x224	0.82	0.47	0.83	0.86	0.85

Dari tabel di atas hasil pengujian ukuran citra 224x224 menghasilkan akurasi yang lebih tinggi dibandingkan ukuran citra 64x64 dan 128x128, bisa disimpulkan bahwa citra 224x224 adalah ukuran citra yang baik untuk pengujian ini maka pengujian selanjutnya tetap menggunakan ukuran 224x224.

B. Pengujian Optimizer

Pengujian kedua yang dilakukan adalah pengujian *optimizer*, umumnya ada banyak sekali jenis *optimizer* yang bisa digunakan, masing masing *optimizer* punya kelebihan dan kekurangannya masing-masing. Untuk pengujian kali ini kami melakukan pengujian tiga *optimizer*, yaitu *adam*, *SGD* dan *RMSprop* untuk menentukan *optimizer* yang menghasilkan akurasi terbaik dari ketiga *optimizer* tersebut, parameter awal yaitu ukuran citra 224x224, *Learning rate* 0.0001, *Epoch* 50 dan *Batch Size* 16, berikut adalah hasil pengujiannya:

TABEL 2
(Hasil Pengujian Optimizer)

Optimizer	Akurasi	Loss	Precision	Recall	F1-Score
Adam	0.82	0.47	0.83	0.86	0.85
SGD	0.57	0.69	0.57	1.00	0.72
RMSprop	0.77	0.52	0.78	0.83	0.81

Dari tabel pengujian *Optimizer* di atas, *Adam* menghasilkan akurasi terbaik dibandingkan *SGD* dan *RMSprop*. *Optimizer adam* juga menghasilkan *loss* yang kecil dibandingkan yang lain sehingga dapat disimpulkan bahwa *optimizer* yang akan digunakan pada pengujian selanjutnya adalah *optimizer adam*.

C. Pengujian Learning Rate

Pengujian ketiga yang dilakukan adalah pengujian *Learning Rate*. Kami menguji 4 nilai *Learning Rate* untuk mencari akurasi yang tinggi, yaitu 0.1, 0.01, 0.001, dan 0.0001. Parameter awal pengujian yaitu ukuran citra 224x224, *Optimizer Adam*, *Epoch* 50 dan *Batch Size* 16. Berikut adalah hasil pengujiannya:

TABEL 3
(Hasil Pengujian Learning Rate)

Learning Rate	Akurasi	Loss	Precision	Recall	F1-Score
0.1	0.57	0.69	0.57	1.00	0.72
0.01	0.57	0.69	0.57	1.00	0.72
0.001	0.57	0.69	0.57	1.00	0.72
0.0001	0.84	0.56	0.88	0.82	0.85

Pada pengujian *Learning Rate*, 0.1, 0.01, dan 0.001 menghasilkan akurasi, *loss*, *precision*, *recall*, dan *F1-Score* yang sama, tetapi untuk *learning rate* 0.0001 menghasilkan nilai yang tinggi, maka pengujian selanjutnya akan menggunakan *learning rate* yang sama yaitu 0.0001. Parameter awal pengujian yaitu ukuran citra 224x224, *Optimizer Adam*, *Epoch* 50 dan *Batch Size* 16.

D. Pengujian Epoch

Pada pengujian *Epoch*, kami menguji banyak *epoch* untuk melihat *epoch* yang terbaik dan seberapa besar pengaruh *epoch* terhadap hasil pengujian, pengujian *epoch* dilakukan dengan nilai 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110 dan 120. Parameter awal pengujian yaitu ukuran citra 224x224, *Optimizer Adam*, *Learning Rate* 0.0001, dan *Batch Size* 16. Berikut adalah hasil pengujiannya:

TABEL 4
(Hasil Pengujian Epoch)

Epoch	Akurasi	Loss	Precision	Recall	F1-Score
10	0.71	0.56	0.80	0.64	0.71
20	0.75	0.46	0.80	0.76	0.78
30	0.85	0.69	0.86	0.88	0.87
40	0.82	0.59	0.90	0.76	0.83
50	0.87	0.69	0.90	0.86	0.88
60	0.80	0.59	0.87	0.76	0.81
70	0.85	0.69	0.88	0.84	0.86
80	0.88	0.62	0.91	0.86	0.89
90	0.82	0.73	0.88	0.79	0.83
100	0.74	0.86	0.79	0.75	0.77
110	0.81	0.99	0.85	0.80	0.82
120	0.84	1.00	0.85	0.87	0.86

Pada pengujian *epoch*, bisa kita lihat *epoch* terkecil menghasilkan akurasi yang rendah, puncak akurasi *epoch* berada di nilai *epoch* 80 setelah itu akurasi akan menurun dan *Loss* semakin besar, maka bisa disimpulkan bahwa *epoch* terbaik untuk sistem ini adalah *epoch* 80, maka untuk pengujian selanjutnya *epoch* akan diganti dengan nilai 80.

E. Pengujian Batch Size

Pengujian terakhir yang dilakukan adalah pengujian *batch size*, kami menguji empat *batch size* yaitu 8, 16, 24, dan 32 untuk menentukan *batch size* yang terbaik untuk sistem ini, Parameter awal pengujian yaitu ukuran citra 224x224, *Optimizer Adam*, *Learning Rate* 0.0001, dan *Epoch* 80. Berikut adalah hasil pengujiannya:

TABEL 5
(Hasil Pengujian *Batch Size*)

Batch Size	Akurasi	Loss	Precision	Recall	F1-Score
8	0.83	0.80	0.85	0.84	0.85
16	0.87	0.98	0.88	0.88	0.88
24	0.80	0.66	0.87	0.75	0.81
32	0.86	0.57	0.92	0.82	0.87

Pada tabel tersebut, pengujian *Batch Size* 16 menghasilkan akurasi yang baik dibandingkan yang lainnya, tetapi terdapat kekurangan yaitu nilai *Loss* yang tinggi dibandingkan yang lainnya, namun untuk hasil *Precision*, *Recall* dan *F1-Score* *batch size* 16 menghasilkan nilai yang tinggi. Maka disimpulkan *batch size* 16 adalah *batch size* terbaik.

F. Hasil Terbaik

Dari hasil lima pengujian parameter, dapat diketahui akurasi-akurasi terbaik setiap parameter. Dari pengujian ini ukuran citra 224x224, *optimizer adam*, *Learning Rate* 0.0001, *Epoch* 80, dan *Batch Size* 16 menghasilkan akurasi terbaik dibandingkan nilai lainnya, namun *loss* yang dihasilkan juga semakin tinggi menandakan harus ada pengembangan lebih lanjut mengapa *loss* tinggi bisa terjadi, karena hal tersebut sangat berpengaruh terhadap keberhasilan suatu sistem.

V. KESIMPULAN

Berdasarkan hasil dari pengujian dan analisa yang dilakukan pada sistem deteksi kecacatan ban dengan *Convolutional Neural Network*, menghasilkan beberapa kesimpulan sebagai berikut:

- Pengujian Sistem Deteksi Kecacatan Ban dengan *Convolutional Neural Network* lima layer berhasil dilakukan dengan F-1 Score tertinggi 0.88 atau 88%
- Hasil pengujian tertinggi yaitu dengan parameter pixel 224x224, *Optimizer adam*, *Learning Rate* 0.0001, *Epoch* 80, dan *Batch size* 16.

- Keberhasilan sistem deteksi kecacatan ban menggunakan *Convolutional Neural Network* dalam mendeteksi ban yang cacat sebesar 88% dan sebanyak 12% sistem mendeteksi salah.

REFERENSI

- I Wayan Suartika E. P, Arya Yudhi Wijaya, dan Rully Soelaiman Teknik Informatika, "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) pada Caltech 101", Fakultas Teknologi Informasi, Institut Teknologi SepuluhNopember (ITS).
- S. Sumahasan , Udaya Kumar Addanki , Navya Irlapati , Amulya Jonnala, "Object Detection using Deep Learning Algorithm CNN", Department of Computer Science and Engineering, G.V.P.C.E.W, Visakhapatnam, India.
- S Z Zhang , "Design of Tire Damage Image Recognition System Based on Deep Learning" J. Phys.: Conf. Ser. 1631 012015, 2020.
- Analisa Cacat Dan Kegagalan Produk Pada Vulkanisir Ban Sistem Dingin, Proposal Skripsi Almanaf Program Studi Teknik Mesin SI Fakultas Teknik Universitas Riau 2015.
- R. Aditya and A. Rakhmatsyah, "ANALISIS DAN IMPLEMENTASI FUZZY NEURAL NETWORK UNTUK," pp. 2–5.
- IRZAL AHMAD SABILLA NRP , ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUKKLASIFIKASI JENIS DAN KESEGARAN BUAH PADA NERACA BUAH,.
- Tire Defects Classication with Multi-Contrast Convolutional Neural Networks, International Journal of Pattern Recognition and Articial Intelligence Vol. 32, No. 4 (2018) 1850011 (17 pages) World Scientific Publishing Company DOI: 10.1142/S0218001418500118.
- Company Profile PT Toyota Motor Manufacturing Indonesia 2017.
- Dwinanda, Reiny. 2019. KNKT: 80 Persen Kecelakaan di Tol Akibat Pecah Ban. <https://www.republika.co.id/berita/q0jh4b414/knkt-80-persen-kecelakaan-di-tol-akibat-pecah-ban> . Rabu 6 Nov 2019.
- Sarirotul Ilahiyah, Agung Nilogiri, IMPLEMENTASI DEEP LEARNING PADA IDENTIFIKASI JENIS TUMBUHAN BERDASARKAN CITRA DAUN

MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK.

- [11] Sofia Sa'idah, Andi Fany, I Putu Yowan Nugraha Suparta, "Convolutional Neural Network GoogleNet Architecture for Detecting the DefectTire School of Electrical Engineering Telkom University Bandung, Indonesia.
- [12] Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation, oleh Ari Peryanto, Anton Yudhana, Rusydi Umar Program Studi Magister Teknik Informatika, Universitas Ahmad Dahlan Program Studi Teknik Elektro, Universitas Ahmad Dahlan, 2020.
- [13] KLASIFIKASI PATOLOGI MAKULA RETINA MELALUI CITRA OCT MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR MOBILENET, Oleh: Putri Nada Zakiya¹, Ledy Novamizanti², Syamsul Rizal³, 5 Oktober 2021.
- [14] Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle, Muhammad Rafly Alwanda^{*1}, Raden Putra Kurniawan Ramadhan², Derry Alamsyah³, Vol. 1, No. 1, Oktober 2020, Hal. 45 – 56.
- [15] Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network, Sarirotul Ilahiyah¹, Agung Nilogiri²,) Jurusan Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Jember.
- [16] Interpretasi dan Pengolahan Citra, Rinaldi Munir, Program Studi Teknik Informatika, 2019.