



FENOTIPING DIGITAL TANAMAN: TINJAUAN TERHADAP TEKNOLOGI DAN ALGORITMA PENGOLAHAN CITRA

Gian Anantrio Putra¹, Dwi Cahyani², Raizummi Fil'aini³, David Septian Sumanto Marpaung⁴

¹ Prodi Teknik Biosistem, Jurusan Teknik Proses dan Hayati, Institut Teknologi Sumatera, gian.putra@tbs.itera.ac.id

² Prodi Teknik Biosistem, Jurusan Teknik Proses dan Hayati, Institut Teknologi Sumatera, dwi.cahyani@tbs.itera.ac.id

³ Prodi Teknik Biosistem, Jurusan Teknik Proses dan Hayati, Institut Teknologi Sumatera, raizummi.filaini@tbs.itera.ac.id

⁴ Prodi Teknik Biosistem, Jurusan Teknik Proses dan Hayati, Institut Teknologi Sumatera, david.marpaung@tbs.itera.ac.id

ABSTRAK

Peningkatan konsumsi dunia akan pangan dan energi dalam skala global yang belakangan menjadi isu yang sering muncul akibat pertumbuhan jumlah penduduk dunia yang berkembang dengan pesat, terdapat sebuah kebutuhan mendasar akan adanya tanaman pangan yang memiliki produktivitas tinggi yang dapat beradaptasi pada perubahan iklim di masa depan. Untuk mewujudkan hal tersebut, dalam proses pengembangan kultivar-kultivar baru dilakukan sebuah proses fenotiping yang dimana hasil fenotiping tersebut akan dikaitkan dengan proses genotyping yang dilakukan pada proses sebelumnya. Perkembangan teknologi informasi tidak lepas dari proses penting ini, teknologi akuisisi data berbasiskan citra digital untuk proses fenotiping otomatis mengalami perkembangan kemajuan yang penting beberapa tahun terakhir. Pada tinjauan kepustakaan ini kami mendiskusikan perkembangan infrastruktur informatika pada bidang fenotiping tanaman otomatis yang meliputi teknik pengolahan citra dan prinsip-prinsip analisis data yang terkait pada proses tersebut, termasuk di dalamnya manajemen data yang berkaitan dengan fenotiping digital tanaman dimulai pada proses penyimpanan data dalam jumlah yang masif hingga algoritma-algoritma kecerdasan buatan yang terlibat dalam mengolah data-data tersebut.

Kata Kunci: fenotiping digital, kecerdasan buatan, big data, analisis data, pengolahan citra

1. PENDAHULUAN

Permintaan akan kebutuhan pertanian secara global bertumbuh dengan cepat, bukan hanya disebabkan oleh pertumbuhan jumlah penduduk bumi, tapi juga oleh faktor-faktor tidak langsung seperti persebaran pangan yang tidak merata, klaim-klaim tumpang tindih atas penggunaan lahan dan permintaan yang tinggi akan daging dan produk-produk olahan susu, karena adanya perubahan pola makan pada negara-negara maju (Rahaman, 2015). Pertanian secara khusus memiliki tantangan yang luar biasa akan produksi bahan pokok pada masa mendatang. Berdasarkan estimasi yang dilakukan oleh Food and Agriculture Organization Persatuan Bangsa-Bangsa (FAO-PBB), produksi sereal harus dilipatgandakan sebelum tahun 2050 untuk memenuhi kebutuhan pangan yang diakibatkan oleh pertambahan jumlah penduduk dunia, dan juga oleh adanya

kompetisi terhadap tanaman baik itu akan digunakan sebagai sumber bioenergi, serat, dan kebutuhan industri lainnya. Terlebih lagi, pasokan beras sebagai pemasok pangan utama di dunia sudah mulai tidak mencukupi (Furbank et al, 2009). Selain faktor-faktor biotik dan abiotik, perubahan suhu bumi dan pola hujan sebagai konsekuensi pemanasan global mengakibatkan adanya penurunan hasil panen (Sticklen, 2007). Untuk meningkatkan kualitas dan produktivitas tanaman, diperlukan adanya analisis kuantitatif akan ciri-ciri dan bentuk tanaman untuk mempercepat upaya pemilihan tanaman yang mampu beradaptasi lebih baik terhadap keterbatasan sumber daya dan kondisi tanah (Fiorani dan Schurr, 2013).

Untuk memperbaiki kualitas tanaman, banyak upaya dilakukan pada studi di bidang genomik fungsional dengan menggunakan alat-alat genomik berkinerja tinggi (Ayliffe dan Lagudah, 2004; Xing dan Zhang, 2010; Huang et al.,

2013; Pallotta et al., 2014; Valluru et al., 2014). Namun, usaha lebih masih dibutuhkan untuk memetakan hubungan antara genotip-fenotip untuk pengembangan pemuliaan tanaman pangan (Tester and Langridge, 2010).

Prosedur fenotyping konvensional yang merupakan sebuah metode yang berkaitan dengan karakter-karakter tanaman yang tentunya berhubungan dengan informasi-informasi yang disediakan oleh genotip tanaman itu, belum mampu menyediakan analisis keseluruhan dan tidak mampu menampilkan hubungan antara genotip dengan fenotipnya. Untuk mengatasi hal ini dikenal istilah fenomik (*phenomics*) yang merupakan cabang dari ilmu biologi (Furbank, 2009; Furbank and Tester, 2011). Fenomik merupakan teknologi yang mampu melakukan proses fenotyping berkinerja tinggi untuk tanaman (Rahaman, 2015).

Dalam rangka memenuhi kebutuhan akan penelitian saat ini, platform fenotyping yang dapat diandalkan, otomatis, dan berkinerja tinggi sudah dikembangkan (Hartmann et al., 2011). Platform-platform fenotyping yang tersedia pada saat ini termasuk didalamnya berbagai macam metodologi akuisisi citra untuk mendapatkan data fenotip secara invasif untuk digunakan pada studi kuantitatif akan ciri-ciri kompleks tanaman, contoh: pertumbuhan, toleransi, resistansi, fisiologi, produktivitas, dan pengukuran-pengukuran dasar atas parameter-parameter individual (Chen et al., 2014; Li et al., 2014).

Platform fenotyping dengan akuisisi citra secara otomatis yang berkinerja tinggi saat ini merupakan alat yang ideal, dan semakin hari menjadi semakin populer dan semakin canggih, dengan kemampuannya untuk mengukur beberapa parameter-parameter fisiologi dan morfologi pada sebuah tanaman. Namun terdapat imbal balik pada kecepatan dan akurasi ketika menggunakan platform otomatis ini, pengukuran secara manual jika dilakukan dengan benar, memiliki hasil yang lebih akurat dibandingkan dengan pengukuran secara otomatis namun dengan waktu yang

lebih lama. Lebih jauh lagi melalui teknik akuisisi data otomatis dapat menyediakan cara baru bagi peneliti-peneliti tanaman untuk mengamati tanda-tanda spesifik dan fungsi-fungsi tanaman melalui pemindaian profil suhu, mengukur nilai laju fotosintesis, mengamati laju pertumbuhan, dan mendapatkan citraan akan fisiologi akar (Finkel, 2009)

Dua hal penting pada platform fenotyping otomatis berbasiskan citra yang perlu dipertimbangkan adalah jenis citra yang didapatkan dan bagaimana cara mengolah data tersebut. Beberapa ulasan tentang fenomik dan akuisisi data berbasiskan citra sudah dilakukan (Araus, 2014; White, 2012; Simko, 2016; da Silva, 2016), begitu juga ulasan mengenai pengolahan citra dan analisinya, juga teknik dan pengolahan lanjutannya. Pada artikel ini kami akan mengulas metode yang ada saat ini yang berkaitan dengan hal-hal tersebut.

2. TINJAUAN PUSTAKA

2.1. AKUISISI CITRA

Akuisisi citra merupakan proses dimana kita mendapatkan representasi digital dari sebuah keadaan, representasi ini disebut dengan citra, dan elemen-elemen pembentuknya disebut dengan piksel. Alat elektronik yang digunakan untuk mengambil citra dikenal sebagai sensor citra. *Charge-coupled device* (CCD) dan *complementary metal oxide semiconductor* (CMOS) adalah teknologi yang paling banyak digunakan pada sensor citra (Perez-Sans, 2017). Kedua teknologi ini digabungkan dengan teknologi *time delay and integration* (TDI) akan meningkatkan fitur-fitur pada sistem akuisisi citra secara signifikan. Teknologi ini digunakan untuk aplikasi yang membutuhkan kemampuan untuk beroperasi pada kondisi pencahayaan yang ekstrim, yang membutuhkan baik kecepatan dan sensitivitas, seperti pada inspeksi, monitoring, sortasi, dan penginderaan jauh (Lepage, 2009; Yu et al, 2016). Teknologi akuisisi citra berkembang dengan pesat, secara umum untuk fenotyping,

teknologi ini dapat dikategorikan menjadi 6 kelompok.

2.1.1. Mono-RGB

Sistem mono-RGB disusun dari sebuah rangkaian lensa, sensor citra, perangkat keras spesifik tertentu, dan antarmuka masukan/keluaran. Sebagian besar peralatan fenotiping digital menggunakan sistem ini. Salah satu contoh penggunaan mono-RGB adalah pada pengembangan alat fenotiping digital yang dilakukan di Korea Institute of Science and Technology yang menggunakan sensor sederhana berupa kamera web digital biasa (Rahaman, 2015; Lee, 2018). Kerugian utama penggunaan sistem ini adalah sensor ini dipengaruhi oleh variasi pencahayaan ketika digunakan di lahan terbuka. Tren penggunaan sistem ini di lahan terbuka adalah dengan mengombinasikan dengan sistem lain seperti *light detection and ranging* (LIDAR) atau sensor termal (Deery, 2014; Comar, 2012).

2.1.2. Stereo

Sistem stereo digunakan untuk mengatasi masalah yang didapatkan pada sistem mono-RGB untuk pengukuran jarak. Prinsip kerja sistem ini adalah dengan menghitung jarak antara dua titik pada sistem mono, citra yang dihasilkan dikenal dengan nama *depth map* (Brown, 2003). Contoh penggunaan sistem ini adalah pada percobaan yang dilakukan oleh Biskup untuk mendapatkan fitur-fitur struktural pada kanopi tanaman. citra rekonstruksi 3 dimensi berhasil dihasilkan, hal ini merupakan salah satu bentuk keberhasilan penggunaan sistem stereo pada fenotiping tanaman (Biskup, 2007; Nguyen, 2015). Keunggulan penggunaan sistem ini adalah kesederhanaannya, dua kamera cukup untuk menghasilkan depth maps. Sistem stereo ini berkembang menjadi *multi-view stereo* (MVS) dan mendapatkan tempat di hati para peneliti fenotiping digital tanaman (Nguyen, 2016). Kelemahan sistem ini adalah begitu mudahnya ia dipengaruhi oleh perubahan iluminasi, sehingga ia membutuhkan komputasi dengan

performa tinggi untuk melakukan algoritma pencocokan citra, dan juga resolusi keluarannya sangat rendah (Schwartz, 2015).

2.1.3. Kamera multi dan hiperspektral

Kamera baik multispektral dan hiperspektral digunakan pada beberapa aplikasi industri (Lee, 2004; Dozier, 2004). Resolusi spektral menjadi faktor utama yang membedakan citra multispektral dengan citra hiperspektral (Ferrato, 2012). Kamera multispektral adalah kamera yang mampu menangkap citra dari beberapa band spektral diskrit. Jumlah band yang dapat ditangkap semakin bertambah seiring dengan perkembangan teknologi. Pada saat ini produsen kamera multispektral menawarkan produknya dengan kemampuan menangkap band sebanyak 3 hingga 25 band, termasuk di dalamnya cahaya tampak, *near infrared* (NIR), dan band-band lainnya (Cubert, 2017). Sistem hiperspektral dapat menangkap resolusi panjang gelombang hingga beberapa nanometer, pada tiap pikselnya didapatkan tanda-tanda digital yang mengandung beberapa ratus band kontinu dalam rentang panjang gelombang tertentu (Kise, 2010).

2.1.4. Kamera ToF

Kamera *Time of Flight* (ToF) merupakan salah satu sensor digital yang diperkenalkan untuk penggunaan fenotiping (Klose, 2009). ToF memiliki prinsip umum pengukuran jarak antara obyek kamera pada tiap pikselnya. Hal ini dapat diraih dengan mengukur waktu yang digunakan oleh sebuah sinyal NIR untuk kembali ke sumber setelah dipantulkan kembali oleh obyek. Hal ini memungkinkan rekonstruksi citra 3D secara presisi. Sistem ini sering dipadukan dengan sistem stereo untuk meningkatkan performa dari metodologi untuk segmentasi citra digital dalam mengukur luas area daun (Song, 2011). Kelemahan sistem ini adalah pada resolusinya yang rendah dan ketergantungan yang tinggi pada permukaan obyek yang diukur jaraknya, sehingga sistem ini tidak dapat digunakan dibawah pencahayaan yang berlebih dan lebih cocok digunakan di dalam ruang (Rahaman, 2015).

Tabel 1. Ringkasan Teknik Akuisisi Citra pada Platform Fenotiping Digital Tanaman

Teknologi Pencitraan	Sensor	Data Luaran	Parameter-parameter	Aplikasi
Cahaya Tampak	Kamera	Gambar hitam-putih atau warna (<i>RGB Channel</i>)	Bagian-bagian organ atau keseluruhan organ, serial waktu (menit hingga hari)	Ciri-ciri morfologi, biomassa digital, tinggi, dll. Asesmen status pertumbuhan tanaman, status nutrisi, dan akumulasi biomassa
Fluorescence	Kamera Fluorescence	Peta piksel atas fluorescence yang tampak dalam bentuk daerah merah dan mendekati merah.	<i>Multiple chlorophyll fluorescence parameters</i> dan <i>multi-spectral fluorescence</i>	Status fotosintesis, penyakit pada daun, struktur benih
Infra Merah	Kamera <i>Thermal</i> , Kamera <i>Near-Infrared</i>	Peta piksel dari suhu permukaan	Indeks area daun, suhu permukaan, status air kanopi dan daun, komposisi benih, serial waktu (menit hingga hari)	Pengukuran transpirasi daun dan kanopi, pelepasan kalor, dll.
Spektral	Kamera Spektrometer, Hiperspektral	Spektra diskrit atau berkelanjutan	Kandungan air, komposisi benih	Asesmen keparahan penyakit, potensi pertumbuhan daun dan kanopi
3 Dimensi	Kamera Stereo, Sistem Kamera ToF	Gambar RGB/IR/Kedalaman	Morfologi, struktur, atau warna dari organ atau tanaman	Pengambilan data struktur, sudut daun, struktur kanopi, dll.
Laser	Instrumentasi Pemindaian Laser	Peta kedalaman, awan titik 3 Dimensi	Morfologi atau struktur dari organ atau tanaman	Pengambilan data struktur, sudut daun, struktur kanopi, dll.
MRI	<i>Magnetic Resonance Imagers</i>	Peta air	Kandungan air, morfologi	Kandungan air, parameter morfometrik
PED	<i>Positron Emission Detectors</i>	Peta radiotracer	Kekentalan cairan, transportasi sektoral	Visualisasi persebaran metabolisme dan transportasi radionuclides
CT	X-ray Tomography	Potongan-potongan sel/orgaan	Parameter morfometrik dalam 3 dimensi	Kepadatan jaringan sel, kualitas benih, rekonstruksi sel jaringan secara 3 dimensi

Sumber (Zhao, 2019)

2.1.5. Teknologi LIDAR

LIDAR merupakan teknologi penginderaan jauh yang dikembangkan ada awal tahun 70-an untuk memonitor permukaan bumi. LIDAR digunakan juga untuk mengakuisisi citra dari

kejauhan dengan jarak kilometer hingga sentimeter, menunjukkan potensi yang besar dari teknologi ini untuk penggunaan di fenotip tanaman. Satelit yang berbasis teknologi LIDAR banyak digunakan untuk pengukuran

tinggi kanopi tanaman luar area, volum biomassa dan lain lain (Chen, 1996; Gwenzi, 2017; Kellndorfer, 2010). Beberapa kelemahan LIDAR pada penggunaannya di fenotiping digital tanaman adalah ketiadaannya warna, waktu yang banyak untuk melakukan komputasi, presisi yang rendah untuk fenotiping dalam jumlah besar, dan gangguan yang diakibatkan oleh angin, hujan, serangga, dan partikel-partikel kecil di udara yang dapat menurunkan kualitas citra yang didapatkan melalui teknologi ini (Lin, 2015).

2.1.6. Citra termografi dan fluorescence

Citra termografi merupakan salah satu teknologi yang banyak digunakan pada penginderaan jauh dan fenotiping tanaman (Padhi, 2012; Gullion, 2008; Kranner, 2010). Kamera termografi mampu menangkap citra dalam rentang panjang gelombang 300 hingga 14000 nm (Fiorani, 2012), sehingga memungkinkan untuk melakukan konversi dari energi iradiasi ke nilai suhu ketika suhu lingkungannya juga diketahui (Mallona, 2011). Teknologi ini juga dapat digunakan untuk mengukur nilai evapotranspirasi pada bagian-bagian tanaman yang berbeda (Sheehan, 2015). Citra fluorescence juga digunakan banyak eksperimen, awal mula pemakaian citra ini adalah pada identifikasi phenylpropanoid synthesis mutant pada tanaman Arabidopsis (Chapple, 1992). Kedua bentuk sistem pencitraan ini menghasilkan citra yang mudah untuk dianalisis karena segmentasi dapat diaplikasikan secara mudah di bentuk citra ini, dan kombinasi keduanya juga dapat menghasilkan data yang sangat baik jika jaringan syaraf tiruan diaplikasikan (Perez-Bueno, 2016).

2.2. ANALISIS CITRA

Mengambil informasi dari citra yang dihasilkan sensor dilakukan melalui proses segmentasi. Tujuan proses segmentasi adalah untuk mengekstrak komponen dari citra sebuah obyek yang kita inginkan, misal latar belakang tanaman, atau bagian tertentu dari tanaman. Hal ini berdasarkan karakteristik-karakteristik tertentu dari obyek seperti warna, indeks

vegetasi, deteksi pinggiran, atau kombinasi beberapa hal dengan *machine learning* (Solem, 2012; Navarro, 2016).

2.2.1. Segmentasi Citra

Seperti sudah disampaikan di atas, bahwa segmentasi citra merupakan inti dari pengolahan citra untuk fenotiping tanaman berbasis citra. Proses segmentasi ini mengidentifikasi dan mengisolasi obyek tertentu dari satuan citra, dan bertujuan untuk menanggalkan latar belakang atau obyek-obyek yang dirasa tidak diperlukan (Singh, 2017). Salah satu algoritma yang paling sederhana yang biasa digunakan untuk segmentasi adalah dengan mengelompokkan intensitas warna hitam-putih pada citra, pendekatan ini dilakukan oleh suatu aplikasi android bernama ApLeaf untuk mengidentifikasi daun dari citra (Zhao, 2015).

Metode Otsu (Otsu, 1979) adalah algoritma segementasi yang mencari batas nilai tertentu kemudian meminimalkan nilainya dalam variansi tertentu, metode ini biasa digunakan untuk mengekstraksi latar belakang pada suatu platform fenotiping digital (Liu, 2015).

Metode *transformasi watershed* (Vincent, 1991) merupakan algoritma yang juga populer dalam segmentasi. Metode ini memperlakukan citra sebagai permukaan topologi. Dia digunakan untuk mengetahui laju pertumbuhan (Patil, 2013), identifikasi mahkota pohon secara individual (Barnes, 2017), dan juga segmentasi dedaunan (Vukadinovic, 2015). *Libraries* yang bersifat *open-source* dapat kita lihat pada tabel 2.

Tabel 2. Daftar perangkat lunak untuk pengolahan citra.

Library	Sumber	Bahasa
OpenCV	http://opencv.org	C++, Python, Java, C#
PlantCV	http://plantcv.danforthcenter.org	Python

Scikit-image	http://scikit-image.org	Python
SimpleCV	http://simplecv.org	C++
FastCV	https://developer.qualcomm.com/software/fastcv-sdk	C++
OpenIMAJ	http://openimaj.org	Java
JavaCV	https://github.com/bytedec/o/javacv	Java

Sumber (Perez-Sans, 2017)

2.2.2. Ekstraksi Fitur

Ekstraksi fitur merupakan tahapan mengidentifikasi dan mengklasifikasi obyek dari citra komputer. Fitur yang diambil dari citra biasa dinamakan vektor fitur. Fitur-fitur utama yang biasa diekstrak dari citra antara lain adalah pinggiran (batas), intensitas warna pada piksel tertentu, bentuk geometri, tekstur, transformasi citra (*Fourier, Wavelet*), atau kombinasi piksel tertentu menggunakan sistem pewarnaan yang berbeda (Van der Heijden, 2012; Pape, 2015; Minervini, 2014; Mouille, 2003; Guijarro, 2015; Navarro, 2016).

Hingga saat ini proses ini merupakan proses yang sulit, membutuhkan ratusan kali percobaan dan kombinasi komponen-komponen yang berbeda. Kesuksesan proses ini tidak hanya tergantung pada metode klasifikasinya, namun juga pada data citra yang tersedia.

2.2.3. Machine Learning

Proses ekstraksi fitur yang bekerja akan menghasilkan data dengan jumlah yang sangat banyak sekali, dan penggunaan statistik ML akhirnya digunakan pada proses akhir untuk melakukan analisis data. Fenotiping sendiri dapat menghasilkan data dalam rentang *terabytes*, dan ML mampu menyediakan *framework* yang baik untuk melakukan analisis data terhadap data-data tersebut. Daftar *libraries* ML dapat kita lihat pada tabel 3.

Tabel 3. Daftar perangkat lunak untuk analisis data menggunakan ML

Library	Sumber	Bahasa
MICE, rpart, Party, CARET, randomFo rest, nnet, e1071, KernLab, igraph, glmnet, ROCR, tree, Rweka, earth, klaR,	https://cran.r-project.org/	R
Scikit-learn	http://scikit-learn.org/stable/	Python
TensorFlow	http://scikit-learn.org/stable/	Python
Caffe	http://caffe.berkeleyvision.org/	Python
PyBrain	http://pybrain.org/	Python
Weka	http://www.cs.waikato.ac.nz/ml/weka/	Java
LibSVM	http://www.csie.ntu.edu.tw/~cjlin/libsvm/	C#, C++, C

Sumber (Perez-Sans, 2017)

Diantara algoritma-algoritma ML yang ada, model prediksi regresi digunakan untuk melakukan proses fenotiping pada daun *Arabidopsis* berdasarkan fitur geometri dan dataset untuk supervisi. Tiga algoritma diujicoba yaitu *k Nearest Neighbour* (kNN), *Support Vector Machine* (SVM), dan *Naïve Bayes* (Pape, 2016).

Konsep saat ini yang merupakan turunan dari ML adalah *Deep Learning* (DL). Metode ini memungkinkan pengembangan konsep yang sederhana menjadi lebih kompleks sehingga

metode ini lebih dekat dengan prinsip-prinsip kecerdasan buatan (173). Convolutional neural networks (CNN) adalah salah satu contoh dari DL yang merupakan pengembangan dari Artificial neural networks (ANN). Dan belakangan DL metode CNN sudah diimplementasikan untuk mengidentifikasi dan mengklasifikasikan bagian-bagian tumbuhan yang berbeda (Pound, 2016). Metode CNN juga sudah digunakan untuk mendeteksi serangan penyakit pada tanaman. Meskipun waktu yang dibutuhkan untuk *training* sangat panjang, berat komputasinya, membutuhkan beberapa jam dari kluster-kluster komputer untuk melatih modelnya, proses klasifikasi dapat dilakukan dalam waktu kurang dari 1 detik (Mohanty, 2016). DL merupakan metode lanjutan dari ML dan memiliki potensi yang besar untuk manajemen dan analisis data yang dihasilkan dari percobaan-percobaan fenomik.

3. SIMPULAN DAN SARAN

Pendekatan penomik digital membutuhkan sensor-sensor yang terintegrasi baik sensor citra dan sensor yang berdasarkan panjang gelombang agar dapat mengidentifikasi obyek secara baik. Banyak penelitian dilakukan di dalam ruang, sehingga dapat menghasilkan keluaran citra yang seragam dan memudahkan proses analisinya, berbeda dengan pelaksanaan fenotiping di luar ruang. Penerapan teknologi-teknologi yang terus berkembang diharapkan dapat memberikan hasil yang lebih baik.

Pendekatan *big data* dapat menghasilkan proses fenotiping digital yang lebih baik. Metode-metode analisis citra pada umumnya menggunakan tahapan-tahapan yang tetap dari proses pengukuran dan pemrosesan citra, yang dibuat oleh penciptanya untuk memenuhi kebutuhan prosedur tertentu. Pada akhirnya ketika suatu *tools* digunakan untuk keperluan hal lain yang sedikit berbeda seringkali membutuhkan penulisan ulang perangkat lunak yang nyaris merubah keseluruhan perangkat lunak tersebut. Dalam beberapa tahun belakangan, metode DL, terutama CNN

telah menunjukkan hasil yang mencengangkan dan diadopsi secara luas pada komunitas *computer vision* (Long, 2015; Krizhevsky, 2012). Metode CNN menawarkan potensi untuk menyediakan solusi generik atas problem-problem analisis citra tanaman (Tardieu, 2017).

Di masa depan, teknik-teknik dan metode-metode baru yang berdasarkan pada kecerdasan buatan akan diperkenalkan dalam fenotiping. Sistem fenotiping digital tanaman otomatis menghasilkan fitur-fitur digital dalam jumlah besar yang perlu dianalisis menggunakan metode statistika terkini yang tentu saja termasuk dalam bagian kecerdasan buatan.

4. UCAPAN TERIMA KASIH

Kami ingin mengucapkan terima kasih kepada Institut Teknologi Sumatera (ITERA) yang menyediakan dukungan melalui skema hibah penelitian mandiri dengan nomor kontrak 134af/IT9.C1/PP/2018.

5. DAFTAR PUSTAKA

- Ayliffe, M. A., and Lagudah, E. S. 2004. Molecular genetics of disease resistance in cereals. *Ann. Bot.* 94, 765–773. doi: 10.1093/aob/mch207
- Araus, J.L., Cairns, J.E. 2014. Field high-throughput phenotyping: the new crop breeding frontier. *Trends Plant Sci* 19, 52–61.
- Barnes, C., Balzter, H., Barrett, K. et al. 2017. Individual tree crown delineation from airborne laser scanning for diseased larch forest stands. *Remote Sens*, 9, 231.
- Biskup, B., Scharr, H., Schurr, U. et al. 2007. A stereo imaging system for measuring structural parameters of plant canopies. *Plant Cell Environ*, 30, 1299–308.

- Brown, M.Z., Burschka, D., Hager, G.D. 2003. Advances in computational stereo. *IEEE Trans Pattern Anal Mach Intell*, 25, 993–1008.
- Chapple, C.C., Vogt, T., Ellis, B.E. et al. 1992. An *Arabidopsis* mutant defective in the general phenylpropanoid pathway. *Plant Cell*, 4, 1413, 24.
- Chen, J.M., Cihlar, J. 1996. Retrieving Leaf Area Index of boreal conifer forests using Landsat TM images. *Remote Sens Environ*, 55, 155, 62.
- Chen, D., Neumann, K., Friedel, S., Kilian, B., Chen, M., Altmann, T., et al. 2014. Dissecting the phenotypic components of crop plant growth and drought responses based on high-throughput image analysis. *Plant Cell* 26, 4636–4655. doi: 10.1105/tpc.114.129601.
- Comar, A., Burger, P., de Solan, B. et al. 2012. A semi-automatic system for high throughput phenotyping wheat cultivars in field conditions: description and first results. *Funct Plant Biol*, 39, 914.
- Cubert, S. 2017. 137 - ButterfIEYE NIR - Cubert-GmbH. Available at: <http://cubert-gmbh.com/product/s-137-butterfeye-nir/>.
- da Silva, Marques J. 2016 Monitoring photosynthesis by *in vivo* chlorophyll fluorescence: application to high-throughput plant phenotyping. *Appl Photosynth-New Prog*, Intech, 3–22.
- Deery, D., Jimenez-Berni, J., Jones, H. et al. 2014. Proximal remote sensing buggies and potential applications for field-based phenotyping. *Agronomy*, 4, 349–79.
- Dozier, J., Painter, T.H. 2004. Multispectral and hyperspectral remote sensing of alpine snow properties. *Annu Rev Earth Planet Sci*, 32, 465, 94.
- Ferrato, L.J. 2012. Comparing hyperspectral and multispectral imagery for land classification of the lower donriver, Toronto. MSc Thesis. Ryerson University. Available at: <http://www.geography.ryerson.ca/wayne/MSA/LisaJenFerratoMRP2012.pdf>
- Finkel, E. 2009. With ‘Phenomics’. Plant scientists hope to shift breeding into overdrive. *Science* 325, 380–381.
- Fiorani, F., Rascher, U., Jahnke, S. et al. 2012. Imaging plants dynamics in heterogenic environments. *Curr Opin Biotechnol*, 23, 227, 35.
- Fiorani, F., and Schurr, U. 2013. Future Scenarios for Plant Phenotyping. *Ann. Rev. Plant Biol.* 64, 267–291. doi: 10.1146/annurev-arplant-050312-120137
- Furbank, R. T. 2009. Plant phenomics: from gene to form and function. *Funct. Plant Biol.* 36, 5–6. doi: 10.1071/FPv36n11_FO
- Furbank, R. T., and Tester, M. 2011. Phenomics-technologies to relieve the phenotyping bottleneck. *Trends Plant Sci.* 16, 635–644. doi: 10.1016/j.tplants.2011.09.005
- Furbank, R. T., Von Caemmerer, S., Sheehy, J., and Edwards, G. 2009. C-4 rice: a challenge for plant phenomics. *Funct. Plant Biol.* 36, 845–856. doi: 10.1071/FP09185.
- Guijarro, M., Riomoros, I., Pajares, G. et al. 2015. Discrete wavelets transform for improving greenness image segmentation in agricultural images. *Comput Electron Agric*, 118, 396–407.

- Guilioni, L., Jones, H.G., Leinonen, I. et al. 2008. On the relationships between stomatal resistance and leaf temperatures in thermography. *Agric For Meteorol*, 148, 1908, 12.
- Gwenzi, D., Helmer, E., Zhu, X. et al. 2017. Predictions of tropical forest biomass and biomass growth based on stand height or canopy area are improved by Landsat-scale phenology across Puerto Rico and the U.S. Virgin Islands. *Remote Sens*, 9, 123.
- Huang, R., Jiang, L., Zheng, J., Wang, T., Wang, H., Huang, Y., et al. 2013. Genetic bases of rice grain shape: so many genes, so little known. *Trends Plant Sci*. 18, 218–226. doi: 10.1016/j.tplants.2012.11.001.
- Kellndorfer, J.M., Walker, W.S., LaPoint, E. et al. 2010. Statistical fusion of lidar, InSAR, and optical remote sensing data for forest stand height characterization: a regional-scale method based on LVIS, SRTM, Landsat ETM+, and ancillary data sets. *J Geophys Res Biogeosciences*, 115.
- Kise, M., Park, B., Heitschmidt, G.W. et al. 2010. Multispectral imaging system with interchangeable filter design. *Comput Electron Agric*, 72, 61, 8.
- Klose, R., Penlington, J. 2009. Usability study of 3D time-of-flight cameras for automatic plant phenotyping. Bornimer. Available at: <https://www.hs-osnabrueck.de/fileadmin/HSOS/Home/pages/COALA/Veroeffentlichungen/2009-CBA-3DToF.pdf>.
- Kranner, I., Kastberger, G., Hartbauer, M. et al. 2010. Noninvasive diagnosis of seed viability using infrared thermography. *Proc Natl Acad Sci U S A*, 107, 3912, 7.
- Krizhevsky, A., Sutskever, I., and Hinton, G.E. 2012. Imagenet classification with deep convolutional neural networks. *Adv. Neural Inf. Process. Syst.* 25, 1097–1105.
- Lee, K.S., Cohen, W.B., Kennedy, R.E. et al. 2004. Hyperspectral versus multispectral data for estimating leaf area index in four different biomes. *Remote Sens Environ*, 91, 508, 20.
- Lee, U.S., Chang, S.Y., Putra, G.A., Kim, H.S., Kim, D.H. 2018. An automated, high-throughput plant phenotyping system using machine learning-based plant segmentation and image analysis. *PLoS one*, 13, 4, e0196615.
- Li, L., Zhang, Q., and Huang, D. 2014. A review of imaging techniques for plant phenotyping. *Sensors (Basel)* 14, 20078–20111. doi: 10.3390/s141120078
- Lin, Y. 2015. LiDAR: An important tool for next-generation phenotyping technology of high potential for plant phenomics? *Comput Electron Agric*, 119, 61–73.
- Liu J-C, Lin T-M. 2015. Location and image-based plant recognition and recording system. *J Inform Hiding and Multimedia Signal Processing*, 6(5), 898–910. Available at: <http://www.jihmsp.org/~jihmsp/2015/vol6/JIH-MSP-2015-05-007.pdf>
- Lepage, G., Bogaerts, J., Meynants, G. 2009. Time-delay-integration architectures in CMOS image sensors. *IEEE Trans Electron Devices*, 56, 2524–33.
- Long, J., Shelhamer, E., and Darrell, T. 2015. Fully convolutional networks for

- semantic segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. pp. 3431–3440.
- Mallona, I., Egea-Cortines, M., Weiss, J. 2011. Conserved and divergent rhythms of CAM-related and core clock gene expression in the cactus *Opuntia ficus-indica*. *Plant Physiol*, 156, 1978–89.
- Minervini, M., Abdelsamea, M.M., Tsafaris, S.A. 2014. Image-based plant phenotyping with incremental learning and active contours. *Ecol Inform*, 23, 35–48.
- Mohanty, S.P., Hughes, D., Salathé, M. 2016. Using deep learning for image-based plant disease detection. 1–7.
- Mouille, G., Robin, S., Lecomte, M. et al. 2003. Classification and identification of *Arabidopsis* cell wall mutants using Fourier Transform InfraRed (FT-IR) microspectroscopy. *Plant J*, 35, 393–404.
- Navarro, P.J., Pérez, F., Weiss, J. et al. 2016. Machine learning and computer vision system for phenotype data acquisition and analysis in plants. *Sensors (Switzerland)*, 16, 641.
- Nguyen, T.T., Slaughter, D.C., Max, N. et al. 2015. Structured light-based 3D reconstruction system for plants. *Sensors (Switzerland)*, 15, 18587–612.
- Nguyen, T.T., Slaughter, D.C., Maloof, J.N. et al. 2016. Plant phenotyping using multi-view stereo vision with structured lights. In: Valasek J, Thomasson JA, eds. International Society for Optics and Photonics. Baltimore, Maryland, USA: SPIE Commercial + Scientific Sensing and Imaging, 986608. doi: 10.1117/12.2229513.
- Otsu N. 1979. A threshold selection method from gray-level histograms. *IEEE Trans Syst Man Cybern*, 9, 62–6.
- Padhi, J., Misra, R.K., Payero, J.O. 2012. Estimation of soil water deficit in an irrigated cotton field with infrared thermography. *F Crop Res*, 126, 45–55.
- Pallotta, M., Schnurbusch, T., Hayes, J., Hay, A., Baumann, U., Paull, J., et al. 2014. Molecular basis of adaptation to high soil boron in wheat landraces and elite cultivars. *Nature* 51, 88–91. doi: 10.1038/nature13538.
- Pape, J-M., Klukas, C. 2015. Utilizing machine learning approaches to improve the prediction of leaf counts and individual leaf segmentation of rosette plant images. In: Computer Vision Problems in Plant Phenotyping (CVPPP 2015). British Machine Vision Association, 1–12. Available at:<http://www.bmva.org/bmvc/2015/cvpp/papers/paper003/index.html>.
- Patil, S., Soma, S., Nandyal, S. 2013. Identification of growth rate of plant based on leaf features using digital image processing techniques. *Int J Emerg Technol Adv Eng*, 3.
- Pérez-Bueno, M.L., Pineda, M., Cabeza, F.M. et al. 2016. Multicolor fluorescence imaging as a candidate for disease detection in plant phenotyping. *Front Plant Sci*, 7, 1790.
- Perez-Sans, F., Navarro, P.J., Egea-Cortinez, M. 2017. Plant phenomics: an overview of image acquisition technologies and image data analysis algorithms. *GigaScience*, 6, 1–18. doi: 10.1093/gigascience/gix092

- Pound, M.P., Burgess, A.J., Wilson, M.H., et al. 2016. Deep machine learning provides state-of-the-art performance in image-based plant phenotyping. *BioRxiv* 2016;53033
- Rahaman, M.M., Chen, D., Gillani, Z., Klukas, C., and Chen. M. 2015. Advanced phenotyping and phenotype data analysis for the study of plant growth and development. *Front. Plant Sci.* 6:619. doi: 10.3389/fpls.2015.00619
- Schwartz, S. 2015. An overview of 3D plant phenotyping methods. *Phenospec Smart Plant Anal.* Available at: <https://phenospec.com/blog/an-overview-of-3d-plant-phenotyping-methods/#ref>
- Sheehan, H., Moser, M., Klahre, U., et al. 2015. MYB-FL controls gain and loss of floral UV absorbance, a key trait affecting pollinator preference and reproductive isolation. *Nat Genet.* Available at: <http://www.nature.com/doifinder/10.1038/ng.3462>.
- Simko, I., Jimenez-Berni, J.A., Sirault, X.R.R. 2016. Phenomic approaches and tools for phytopathologists. *Phytopathology.* doi: 10.1094/PHYTO-02-16-0082-RVW.
- Singh, V., Misra, A.K. 2017. Detection of plant leaf diseases using image segmentation and soft computing techniques. *Inf Process Agric.* 4, 41–9.
- Solem, J.E. 2012. Programming computer vision with python. In: Andy Oram, Mike Hendrikson, eds. *Programming Computer Vision with Python.* 1st ed. Sebastopol, CA: O'Reilly Media, 264. Available at: <http://programmingcomputervision.com/>.
- Song, Y., Glasbey, C.A., van der Heijden, G.W.A.M. et al. 2011. Combining Stereo and Time-of-Flight Images with Application to Automatic Plant Phenotyping. Berlin: Springer, 467, 78.
- Sticklen, M. B. 2007. Feedstock crop genetic engineering for alcohol fuels. *Crop Sci.* 47, 2238–2248. doi: 10.2135/cropsci2007.04.0212
- Tardieu, F., Cabrera-Bosquet, L., Pridmore, T., Bennett, M. 2017. Plant Phenomics, From Sensors to Knowledge. *Current Biology* 27, R770–R783
- Tester, M., and Langridge, P. 2010. Breeding technologies to increase crop production in a changing world. *Science* 327, 818–822. doi: 10.1126/science.1183700
- Valluru, R., Reynolds, M. P., and Salse, J. 2014. Genetic and molecular bases of yield-associated traits: a translational biology approach between rice and wheat. *Theor. Appl. Genet.* 127, 1463–1489. doi: 10.1007/s00122-014-2332-9.
- Van Der Heijden, G., Song, Y., Horgan, G. et al. 2012. SPICY: towards automated phenotyping of large pepper plants in the greenhouse. *Funct Plant Biol.* 39, 870–7.
- Vincent, L., Vincent, L., Soille, P. 1991. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. *IEEE Trans Pattern Anal Mach Intell.* 13, 583–98.
- Vukadinovic, D., Polder, G. 2015. Watershed and supervised classification based fully automated method for separate leaf segmentation. *The Netherland Congress on Computer Vision,* 1–2.

Available at:
<http://edepot.wur.nl/385470>.

White, J., Andrade-Sanchez, P., Gore, M. et al. 2012. Field-based phenomics for plant genetics research. *F Crop*, 133, 101-12.

Xing, Y., and Zhang, Q. (2010). Genetic and molecular bases of rice yield. *Ann. Rev. Plant Biol.* 64, 421–442. doi:10.1146/annurevplant-042809-112209

Yu, C., Nie, K., Xu, J. et al. 2016. A low power digital accumulation technique for digital-domain CMOS TDI image sensor. *Sensors*, 16, 1572.

Zhao, C., Zhang, Y., Du, J., Guo, X., Wen, W., Gu, S., Wang, J. and Fan, J. 2019. Crop Phenomics: Current Status and Perspectives. *Front. Plant Sci.* 10, 714.

Zhao, Z.Q., Ma, L.H., Cheung, Y.M., et al. 2015. ApLeaf: an efficient android-based plant leaf identification system. *Neurocomputing*, 151, 1112–9

6. NOMENKLATUR

ANN	Artificial Neural Networks
CCD	Charge-coupled device
CMOS	Complementary Metal Oxide Semiconductor
CNN	Convolutional Neural Networks
DL	Deep Learning
KNN	k Nearest Neighbour
LIDAR	Light Detection and Ranging
ML	Machine Learning
MRI	Magnetic Resonance Imagers
MVS	Multi-View Stereo
NIR	Near Infrared
PED	Positron Emission Detectors
RGB	Red Green Blue
SVM	Support Vector Machine
TDI	Time Delay and Integration
ToF	Time of Flight