

LAPORAN PENELITIAN

KLASIFIKASI KEBERHASILAN MAHASISWA UNIVERSITAS TERBUKA DAN FAKTOR-FAKTOR DETERMINASINYA



Tim Peneliti:

Dr. Agus Santoso, M.Si.

Drs. Timbul Pardede, M.Si.

Dra. Dyah Paminta Rahayu, M.Si.

**FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS TERBUKA**

2023

LEMBAR PENGESAHAN
LEMBAGA PENELITIAN DAN PENGABDIAN KEPADA MASYARAKAT
UNIVERSITAS TERBUKA

1	a	Judul Penelitian	:	Klasifikasi Keberhasilan Mahasiswa Universitas Terbuka dan Faktor-faktor Determinasinya
	b	Skema penelitian	:	Kompetitif - Penelitian Terapan
2		Ketua Peneliti		
	a	Nama Lengkap & Gelar	:	Dr. Agus Santoso, M.Si.
	b	NIDN	:	0017026402
	c	Golongan Kepangkatan	:	IV-a
	d	Jabatan Akademik	:	Lektor Kepala
	e	Fakultas	:	Sains dan Teknologi
	f	Unit Kerja	:	Universitas Terbuka Yogyakarta
	g	Program Studi	:	Statistika
3		Anggota Peneliti		
	a	Jumlah	:	2 orang
	b	Nama Anggota 1	:	Drs. Timbul Pardede, M.Si.
	c	NIDN	:	0008126511
	d	Fakultas	:	Sains dan Teknologi
	e	Nama Anggota 2	:	Dra. Dyah Paminta Rahayu, M.Si.
	f	NIDN	:	0008126409
	g	Fakultas	:	Sains dan Teknologi
4	a	Tahun penelitian	:	2023
	b	Lama Penelitian	:	1 (satu) Tahun
5		Biaya Penelitian	:	
	a	Diusulkan	:	Rp 75.000.000,-
	b	Disetujui	:	Rp 61.893.000,-
6		Sumber Biaya	:	PNBP
7		Pemanfaatan Hasil Penelitian		
	a	Seminar	:	Nasional
	b	Jurnal	:	Internasional
8		Luaran Penelitian lain	:	-

Mengetahui
 Dekan Fakultas Sains dan Teknologi



Dr. Subekti Nurmawati, M.Si.
 NIP 196705181991032001

Ketua Peneliti,

Dr. Agus Santoso, M.Si.
 NIP 196402171993031001

Menyetujui
 Ketua LPPM

Prof. Dra. Dewi Artati Padmo Putri, M.A., Ph.D.
 NIP 196107241987102003

Menyetujui,
 Kepala Pusat Keilmuan

Dr. Etty Puji Lestari, SE., M.Si.
 NIP 197404162002122001

Klasifikasi Keberhasilan Mahasiswa Universitas Terbuka dan Faktor-faktor Determinasinya

ABSTRAK

Salah satu tantangan terbesar yang dihadapi oleh mahasiswa Universitas Terbuka yaitu belajar mandiri, dan dari berbagai referensi pendukung yang tersedia. Hal seperti ini tentu saja dapat mempengaruhi keberhasilan studinya. Sebagai pengelola Universitas Terbuka yang memberikan layanan terbaik kepada mahasiswa dan masyarakat luas sebagai pelanggan, umpan balik untuk perbaikan layanan di masa depan dengan mengklasifikasikan mahasiswa dan mengetahui faktor-faktor yang dapat mempengaruhi keberhasilan mahasiswa dalam menyelesaikan studinya sangat diperlukan. Penelitian ini bertujuan untuk menganalisis dan melakukan prediksi keberhasilan mahasiswa dan faktor-faktor yang mempengaruhinya melalui klusterisasi yang dieksplorasi dan pengelompokan yang ditentukan dari awal.

Penelitian ini merupakan penelitian deskriptif eksploratif kuantitatif korelasional. Data dikumpulkan menggunakan teknik dokumentasi. Ada dua jenis data yang digunakan, artikel jurnal dan dokumentasi. Artikel jurnal diunduh dengan software *Publish or Perish* dengan data base di Scopus 10 tahun terakhir. Data dokumenter yang dikumpulkan merupakan data mahasiswa yang lulus sejak 2017 sampai dengan 2022 yang meliputi indeks prestasi kumulatif (IPK), masa studi, lama bimbingan tugas akhir, jenis kelamin, status pekerjaan, dan lain-lain yang merupakan data dokumentasi yang diisikan mahasiswa ketika mendaftar kuliah atau registrasi awal. Data dibersihkan dan dikodekan terlebih dahulu, kemudian dianalisis. Analisis data dilakukan dengan bibliometri dan machine learning untuk prediksi.

Hasil bibliometric menunjukkan bahwa berupa pembahasan terkait dengan informasi rata-rata sitasi tiap tahun sepuluh most relevant sources, authors, dan afiliasi, ten most cited documents, keywords (most frequent words, treemap, wordcloud, dan trend topics), co-occurrence network (thematic map dan thematic evolution), dan social structure (collaboration network dan collaboration world map), dan pembahasan topik terkait dengan faktor yang mempengaruhi keberhasilan belajar siswa. Tren terkini terkait penelitian tentang faktor yang mempengaruhi keberhasilan belajar siswa menunjukkan bahwa gender dan self-efficacy merupakan motor themes yang berpotensi untuk diteliti lebih lanjut, sedangkan higher education, covid-19, dan factors merupakan kata-kata kunci yang menjadi basic themes. Sementara itu, dari data mining diperoleh bahwa Hasil penelitian ini menunjukkan bahwa (1) model prediksi menggunakan algoritma RF dan NN memiliki akurasi kalsifikasi dan nilai AUC tertinggi (CA: 76% dan AUC: 79%) dibanding model lainnya seperti LR, NB, dan kNN dalam memprediksi status studi mahasiswa; dan (2) variabel terpenting dalam memprediksi status studi mahasiswa bersama dengan enam varibel penting lainnya adalah nilai GPA mahasiswa.

Keyword: bibliometric, faktor yang mempengaruhi keberhasilan mahasiswa, educational data mining, machine learning, status studi mahasiswa, Universitas Terbuka.

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGESAHAN	ii
ABSTRAK	iii
DAFTAR ISI.....	iv
BAB I PENDAHULUAN.....	1
A. Latar Belakang Masalah	1
B. Rumusan Masalah Penelitian.....	5
C. Tujuan Penelitian.....	5
D. Manfaat Penelitian.....	6
BAB II KAJIAN PUSTAKA	7
A. Kajian Teori.....	7
1. Capaian Keberhasilan Mahasiswa di Perguruan Tinggi.....	7
2. Faktor-faktor yang Mempengaruhi Prestasi Mahasiswa	7
a. Status Sekolah.....	7
b. Jenis Kelamin.....	9
c. Keadaan Sosial Ekonomi	10
3. Analisis Kluster (<i>Cluster Analysis</i>)	11
4. Analisis Diskriminan (<i>Discriminant Analysis</i>).....	12
B. Pertanyaan Penelitian	19
BAB III METODE PENELITIAN	20
BAB IV HASIL DAN PEMBAHASAN.....	24
BAB V PENUTUP.....	58
DAFTAR PUSTAKA	60
LAMPIRAN-LAMPIRAN.....	72

BAB I

PENDAHULUAN

A. Latar Belakang Masalah

Penyelenggaraan pendidikan atau pembelajaran dari jenjang pendidikan dasar hingga pendidikan tinggi harapannya dapat mengembangkan sumber daya manusia yang kompeten dalam aspek kognitif, psikomotor, dan afektif. Tujuan itu dapat tercapai salah satunya ketika kegiatan pendidikan atau pembelajaran yang diselenggarakan oleh institusi pendidikan dapat berlangsung secara efektif. Terdapat banyak kriteria yang dapat digunakan untuk menentukan sejauh mana keefektifan pendidikan yang diselenggarakan oleh suatu institusi pendidikan telah tercapai. Jika ditinjau pada kasus perguruan tinggi, dua di antara banyak kriteria yang ada tersebut yaitu masa studi dan prestasi atau keberhasilan mahasiswa yang salah satunya tercermin dari indeks prestasi kumulatif (IPK) yang diperoleh (Rahmi & Yozza, 2020; Redjeki et al., 2011). Lebih lanjut, Rahmi dan Yozza (2020) menambahkan bahwa kedua hal tersebut menjadi dua di antara banyak indikator yang digunakan untuk mengukur akreditasi perguruan tinggi dari segi kualitas lulusan perguruan tinggi yang juga mencerminkan efektivitas dan produktivitas dari pendidikan yang diselenggarakan oleh perguruan tinggi tersebut. Perguruan tinggi diharapkan mengevaluasi setiap indikator tersebut tidak sekadar untuk mencapai akreditasi tertentu tetapi juga sekaligus untuk menyusun berbagai program peningkatan efisiensi penyelenggaraan pendidikan.

Efektivitas, produktivitas, dan efisiensi dari penyelenggaraan pendidikan yang dicapai untuk mendukung keberhasilan mahasiswa, seperti masa studi yang tidak lama, dan kepuasan mahasiswa tidak terlepas dari faktor pelayanan akademik yang harapannya selalu diusahakan dengan senantiasa mengedepankan pada aspek kualitas, penyediaan fasilitas yang memadai, dan manajemen yang profesional (Marthalina, 2018). Hal semacam ini tentu diharapkan dapat dilakukan oleh pihak perguruan tinggi melalui penyediaan pelayanan optimal untuk mewujudkan kepuasan mahasiswa sebagai pelanggan atau pengguna jasa pendidikan yang diselenggarakan oleh perguruan tinggi. Sejalan dengan hal ini, Universitas Terbuka tentu senantiasa berusaha memberikan pelayanan prima yang lebih baik dari waktu ke waktu kepada mahasiswa sebagai pelanggan atau pengguna jasa. Namun demikian, usaha tersebut juga membawa berbagai tantangan tersendiri mengingat mahasiswa Universitas Terbuka memiliki keragaman latar belakang yang sangat tinggi, yang meliputi keragaman dalam hal

jurusan ketika di jenjang sekolah menengah atas atau yang sederajat, jenis kelamin, sosial, ekonomi, dan budaya.

Keberhasilan mahasiswa yang salah satu di antaranya tercermin oleh masa studi, waktu yang diperlukan untuk menyelesaikan semua beban belajar dan tugas akhir pada suatu strata, dipengaruhi oleh berbagai faktor. Wahyu (Samekto et al., 2014) menyebutkan faktor-faktor yang dapat mempengaruhi keberhasilan mahasiswa ditinjau dari masa studinya yang terbagi ke dalam faktor internal yang berupa adanya keterpaksaan dalam menjalani perkuliahan dan adanya pikiran salah memilih jurusan dan faktor eksternal yang berupa keaktifan dalam berorganisasi atau menekuni hobi, bekerja, dan jaminan untuk mendapat pekerjaan setelah lulus. Dari penelitian yang dilakukan oleh Samekto et al. (2014) akhirnya diperoleh temuan bahwa faktor yang dapat memengaruhi masa studi mahasiswa yaitu minat belajar, motivasi, gaya belajar, kecerdasan, sarana dan prasarana pendukung belajar, model pembelajaran, jalur masuk (reguler atau non-reguler), dan faktor lingkungan. Selain itu, penelitian lain (Ariani et al., 2013; Rahmi & Yozza, 2020; Romadhona et al., 2017) mendapati bahwa usia masuk ke perguruan tinggi, jenis kelamin, indeks prestasi kumulatif (IPK), dan daerah asal memiliki pengaruh terhadap lama studi mahasiswa.

Analisis terhadap faktor-faktor yang dapat memengaruhi keberhasilan mahasiswa dari segi lama studi secara periodik merupakan hal yang penting dilakukan oleh perguruan tinggi, termasuk Universitas Terbuka untuk menjamin kualitas dari pendidikan atau pembelajaran yang diselenggarakan. Dengan mempertimbangkan hal telah disebutkan sebelumnya bahwa di satu sisi Universitas Terbuka memiliki mahasiswa dengan jumlah yang sangat banyak dan latar belakang yang sangat beragam, sementara di sisi lain ada semacam tuntutan senantiasa mempertahankan atau bahkan meningkatkan kualitas pembelajaran yang telah ada, tentu Universitas Terbuka memiliki tantangan tersendiri dalam kaitannya menciptakan kegiatan pembelajaran yang berbeda-beda untuk mengakomodasi mahasiswa yang beragam dengan tetap menjaga kualitas yang ada. Untuk menjawab tantangan ini, diperlukan suatu analisis berupa analisis kluster (cluster analysis) dengan melakukan pengklasteran berdasarkan data yang tersedia pada sistem basis data Universitas Terbuka yang berkaitan dengan faktor-faktor yang memengaruhi keberhasilan mahasiswa yang telah disebutkan sebelumnya ke dalam kluster-kluster tertentu. Ini didasari oleh temuan bahwa data terkait faktor-faktor tersebut tersedia dalam sistem basis data Universitas Terbuka namun belum secara maksimal dimanfaatkan untuk mendukung dalam peningkatan pengelolaan dan perbaikan sistem yang ada guna meningkatkan pencapaian mahasiswanya dan menyediakan layanan yang optimal

kepada mahasiswa. Meskipun ada beberapa metode untuk melakukan analisis kluster, metode K-means dipandang sebagai metode yang lebih cocok digunakan mengingat ukuran sampel yang besar. Selanjutnya, dengan analisis kluster ini dilengkapi dengan analisis determinan untuk mengetahui faktor-faktor mana saja yang signifikan memengaruhi keberhasilan dari mahasiswa. Dengan demikian, penelitian ini bertujuan untuk menganalisis dan melakukan klasifikasi keberhasilan mahasiswa dan faktor-faktor yang mempengaruhinya dengan cara klusterisasi yang dieksplorasi dan pengelompokan yang ditentukan dari awal.

Peralihan dunia menuju ekonomi global ternyata berdampak positif pada peningkatan minat individu untuk melanjutkan pendidikan yang lebih tinggi. Individu dan negara-negara telah menyadari pentingnya pendidikan yang lebih tinggi untuk daya saing dan kesuksesan (Alturki et al., 2022). Sayangnya, peningkatan minat ini juga berdampak pada tingginya tingkat kegagalan akademik mahasiswa (drop-out) (Alturki et al., 2022). Salah satu kekhawatiran utama perguruan tinggi (PT) adalah tingginya tingkat kegagalan akademik tidak hanya menghabiskan biaya bagi individu tetapi juga berdampak pada PT dan negara (Kim et al., 2023). Di tingkat PT, kegagalan akademik berdampak negatif pada sistem pendidikan (Batool et al., 2023). Di negara-negara berkembang seperti Indonesia, kegagalan akademik dapat menghambat produktivitas, daya saing, memperburuk ketimpangan pendapatan, dan efek makroekonomi jangka panjang (Colak Oz et al., 2023; Cruz-Jesus et al., 2020). Olehnya itu, masalah kegagalan akademik mahasiswa menjadi masalah serius yang perlu mendapat perhatian, khususnya perguruan tinggi (PT).

PT memiliki peranan penting dalam meminimalkan tingkat kegagalan akademik mahasiswa. Menurut Sarra et al. (2019), tujuan akademik yang krusial adalah agar sebanyak mungkin mahasiswa dapat menyelesaikan studinya dengan sukses dalam jangka waktu yang wajar. Untuk itu, PT perlu melakukan langkah pencegahan sejak dini agar mahasiswa tidak menghamburkan waktu dan kehilangan minat studi (Kim et al., 2023). Salah satu langkah konkrit yang dapat dilakukan adalah membangun sistem responsif (model prediksi) yang dapat memprediksi perilaku mahasiswa (Alturki et al., 2022). Data yang berisi catatan mahasiswa di PT dapat berguna untuk membangun model prediksi (Cruz-Jesus et al., 2020). Seperti yang dilakukn Burgos et al. (2018), membangun model prediksi menggunakan catatan mahasiswa di PT dan berhasil menurunkan tingkat kegagalan akademik sebesar 14% dari tahun sebelumnya. Namun, sampai saat ini belum ada model yang solid untuk memprediksi keberhasilan para mahasiswa (Alturki et al., 2022; Rotem et al., 2021). Olehnya

itu, pengembangan model prediksi dengan memanfaatkan catatan mahasiswa di PT menjadi kebutuhan yang krusial dalam meminimalkan tingkat kegagalan akademik mahasiswa.

Penelitian sebelumnya terkait model prediksi dengan memanfaatkan catatan mahasiswa di PT telah banyak dilakukan. Sebagian besar menggunakan metode data mining (DM) untuk memprediksi kinerja akademik mahasiswa (Alturki et al., 2022; Batool et al., 2023; Fernandes et al., 2019; Rebai et al., 2020; Waheed et al., 2020; Yağcı, 2022) dan status studi mahasiswa (keberhasilan atau kegagalan akademik) (Beaulac & Rosenthal, 2019; Musso et al., 2020). Algoritma DM yang paling populer digunakan adalah Random Forest (Alturki et al., 2022; Rebai et al., 2020; Xu et al., 2019; Yağcı, 2022); Naive Bayes (Sassirekha & Vijayalakshmi, 2022; Yağcı, 2022); regresi logistik, k-NN (k-Nearest Neighbours) (Cruz- Jesus et al., 2020; Sassirekha & Vijayalakshmi, 2022; Yağcı, 2022); dan Neural Network (Waheed et al., 2020; Yağcı, 2022). Algoritma DM tersebut memiliki akurasi prediksi mencapai 50 hingga 81% (Yağcı, 2022). Namun, akurasi model prediksi dari algoritma DM sangat bergantung pada variabel input (atribut) yang digunakan, dan ini masih kurang diperhatikan dalam penelitian sebelumnya (Colak Oz et al., 2023). Oleh karena itu, penting untuk diidentifikasi atribut yang secara signifikan dapat meningkatkan kinerja model prediksi.

Tren saat ini dalam pemodelan prediktif untuk kinerja akademik dan status studi mahasiswa lebih cenderung berfokus pada negara-negara maju dengan database yang lengkap. Misalnya, menggunakan atribut kepribadian dan kehadiran (Alturki et al., 2022; Jenö et al., 2018; Mohd Khairy et al., 2018; Roslan & Chen, 2023); budaya (Moore et al., 2018); dan strategi belajar, persepsi dukungan sosial, motivasi, sosiodemografi, kondisi kesehatan, serta karakteristik kinerja akademik (Musso et al., 2020). Atribut-atribut tersebut sangat sulit ditemukan di negara-negara berkembang (Alturki et al., 2022), seperti Indonesia. Atribut yang terbukti signifikan dan mungkin tersedia di negara-negara berkembang adalah jenis kelamin (Cruz-Jesus et al., 2020); usia, status pekerjaan dan IPK sebelumnya (Alturki et al., 2022); pendapatan (Sarra et al., 2019); dan status pernikahan (Colak Oz et al., 2023). Selain itu, dalam penelitian ditambahkan atribut asal daerah mahasiswa dan upah minimum provinsi sebagai pengganti atribut budaya dan pendapatan, dan ini masih kurang diteliti. Oleh karena itu, penelitian terkait model prediksi di negara-negara berkembang berdasarkan variabel demografi dan data akademik masih sangat urgen untuk dilakukan.

Penelitian ini secara umum bertujuan untuk menguji algoritma DM pada model prediksi status studi mahasiswa. Secara khusus, penelitian ini bertujuan untuk mengathui faktor-faktor

(atribut) terpenting yang berkontribusi dalam menjelaskan status studi mahasiswa di negara berkembang seperti Indonesia. Tujuan umum dan khusus tersebut dijawab melalui dua pertanyaan penelitian, yakni: 1) model prediksi dengan algoritma DM seperti apa yang paling cocok untuk memprediksi status studi mahasiswa di negara berkembang seperti Indonesia ditinjau dari indikator kinerja algoritma DM?, dan 2) faktor-faktor (atribut) terpenting apa saja yang dapat menjelaskan status studi mahasiswa di negara berkembang seperti Indonesia berdasarkan model prediksi yang paling cocok?. Harapannya, dengan menjawab dua pertanyaan tersebut penelitian dapat memberikan kontribusi pada perkembangan penelitian saat ini yang fokus memanfaatkan informasi demografi dan data akademik yang tercatat dalam database PT untuk memprediksi status studi mahasiswa di negara berkembang seperti Indonesia.

B. Rumusan Masalah Penelitian

Rumusan masalah penelitian ini sebagai berikut.

1. Bagaimanakah hasil analisis bibliometric tentang penelitian-penelitian terdahulu terkait factor-faktor yang mempengaruhi keberhasilan perkuliahan di Universitas Terbuka?
2. Bagaimanakah hasil analisis capaian keberhasilan mahasiswa Universitas Terbuka menggunakan metode *machine learning*?
3. Jika keberhasilan mahasiswa ditetapkan atau diklasifikasikan peneliti dari awal, faktor apa saja yang signifikan mempengaruhi perbedaan pada klasifikasi tersebut?

C. Tujuan Penelitian

Sesuai dengan rumusan masalah, penelitian ini memiliki dua tujuan utama sebagai berikut.

1. Melakukan analisis bibliometri faktor-faktor yang mempengaruhi keberhasilan pembelajaran di Universitas Terbuka
2. Menganalisis klasterisasi capaian keberhasilan mahasiswa Universitas Terbuka dengan menggunakan metode *machine learning*.
3. Menganalisis faktor-faktor apa saja yang secara signifikan mempengaruhi perbedaan pada klasifikasi tersebut.

D. Manfaat Penelitian

Hasil dari penelitian ini memberikan informasi faktor-faktor yang dapat mempengaruhi klasterisasi capaian keberhasilan mahasiswa. Dengan menggunakan informasi tersebut, baik informasi pengklasteran maupun faktor-faktor yang mempengaruhinya, akan diperoleh bahan pembinaan bagi pihak manajemen Universitas Terbuka untuk mengelola dan memperbaiki sistem yang ada dalam meningkatkan capaian mahasiswanya dan menyediakan layanan yang optimal.

BAB II

KAJIAN PUSTAKA

A. Kajian Teori

1. Capaian Keberhasilan Mahasiswa di Perguruan Tinggi

Keberhasilan mahasiswa di perguruan tinggi dapat diasosiasikan dengan capaian pada aspek tertentu. Aspek ini bisa berupa masa studi, yaitu waktu yang tempuh oleh mahasiswa untuk menyelesaikan beban belajar dan tugas akhir pada strata tertentu; capaian indeks prestasi (IP) dan indeks prestasi kumulatif (IPK); dan keaktifan berorganisasi. Keberhasilan mahasiswa yang salah satu di antaranya tercermin oleh masa studi, waktu yang diperlukan untuk menyelesaikan semua beban belajar dan tugas akhir pada suatu strata, dipengaruhi oleh berbagai faktor. Wahyu (Samekto et al., 2014) menyebutkan faktor-faktor yang dapat mempengaruhi keberhasilan mahasiswa ditinjau dari masa studinya yang terbagi ke dalam faktor internal yang berupa adanya keterpaksaan dalam menjalani perkuliahan dan adanya pikiran salah memilih jurusan dan faktor eksternal yang berupa keaktifan dalam berorganisasi atau menekuni hobi, bekerja, dan jaminan untuk mendapat pekerjaan setelah lulus. Dari penelitian yang dilakukan oleh Samekto et al. (2014) akhirnya diperoleh temuan bahwa faktor yang dapat memengaruhi masa studi mahasiswa yaitu minat belajar, motivasi, gaya belajar, kecerdasan, sarana dan prasarana pendukung belajar, model pembelajaran, jalur masuk (reguler atau non-reguler), dan faktor lingkungan. Selain itu, penelitian lain (Ariani et al., 2013; Rahmi & Yozza, 2020; Romadhona et al., 2017) mendapati bahwa usia masuk ke perguruan tinggi, jenis kelamin, indeks prestasi kumulatif (IPK), dan daerah asal memiliki pengaruh terhadap lama studi mahasiswa.

2. Faktor-faktor yang Mempengaruhi Prestasi Mahasiswa

Berbagai variabel diduga memiliki pengaruh terhadap capaian mahasiswa di Indonesia selama mereka menyelesaikan studinya. Beberapa variabel tersebut di antaranya yaitu status sekolah asal, jenis kelamin, keadaan sosial ekonomi keluarga, dan lama membaca daerah. Pada bagian ini disajikan hasil kajian pada tiga variabel pertama, yaitu status sekolah, jenis kelamin, dan keadaan sosial ekonomi keluarga.

a. Status Sekolah

Berbagai jenis sekolah menengah atas (SMA) atau sekolah menengah kejuruan (SMK) diselesaikan calon mahasiswa Universitas Terbuka sebelum akhirnya mendaftar, diterima,

dan melakukan registrasi. Sekolah yang telah diselesaikan ini bisa sekolah dengan status negeri dan sekolah swasta. Masyarakat umum meyakini bahwa sekolah negeri dan sekolah swasta memiliki berbagai perbedaan. Perbedaan-perbedaan tersebut di antaranya dapat ditinjau dari segi pendanaan dan sistem penerimaan siswa. Pendanaan merupakan perbedaan utama dari kedua jenis sekolah tersebut. Sekolah negeri mendapatkan pendanaan dari pemerintah, sedangkan sekolah swasta dapat memilih untuk mendapatkan pendanaan dari pemerintah atau sumber lain seperti yayasan, donatur, dan/atau iuran bulanan siswa. Pendanaan yang diperoleh dari pemerintah membuat sekolah negeri harus taat dengan peraturan yang diberlakukan pemerintah. Berbeda dengan sekolah negeri, sekolah swasta yang pendanaannya tidak dari pemerintah memiliki kelonggaran dalam menyelenggarakan pendidikan atau pembelajaran bagi siswanya, salah satunya yaitu kelonggaran atau keluwesan dalam mengembangkan kurikulumnya (Barrington, 2022).

Perbedaan antara sekolah negeri dan swasta selanjutnya yaitu sistem penerimaan siswanya. Sekolah merupakan perpanjangan tangan dari pemerintah untuk menyediakan pendidikan bagi seluruh rakyatnya. Oleh sebab itu, sekolah negeri harus menerima siswa dengan berbagai perbedaan, seperti perbedaan status ekonomi, sosial, dan agama. Berbeda dengan sekolah negeri, sekolah swasta dapat menentukan kriteria untuk siswa dan/atau orang tua siswa. Tidak jarang sekolah swasta menyelenggarakan tes masuk bagi siswanya dan diikuti dengan tes wawancara bagi orang tua siswa. Dimungkinkan bahwa sekolah swasta memilih siswa-siswa yang memiliki motivasi yang tinggi untuk belajar, sehingga hal ini akan membawa atmosfer yang baik bagi kegiatan pembelajaran yang berlangsung (DeGerolamo, 2020; Grossberg, 2019).

Jika dikaitkan dengan teori neoliberalisme, sekolah swasta diduga akan menghasilkan siswa dengan hasil belajar, termasuk capaian literasi membaca, yang lebih baik daripada siswa dari sekolah negeri. Neoliberalisme merupakan suatu teori ekonomi-politik yang berkeyakinan bahwa kesejahteraan individu dapat ditingkatkan dengan cara memberikan kebebasan dan keterampilan kepada setiap individu untuk berwirausaha, diakui hak milik pribadinya, serta diberikan kebebasan untuk memasuki pasar dan perdagangan bebas. Bagi teori ini, peran pemerintah dibatasi pada berbagai hal, seperti jaminan keamanan, penegakan aturan pasar, dan pemberian kebebasan kepada swasta untuk memiliki peran dalam pasar. Teori tersebut diaplikasikan dalam dunia pendidikan dengan cara memberikan peluang kepada pihak (sekolah) swasta untuk berperan dalam menyelenggarakan pendidikan dengan memperhatikan regulasi yang ditetapkan oleh pemerintah. Pemberian kewenangan kepada

swasta diasumsikan akan membuat penyelenggaraan pendidikan menjadi lebih efisien dan dapat dicapai peningkatan kualitas dalam dunia pendidikan (Dudley-Marling & Baker, 2012; Friedman, 1995).

b. Jenis Kelamin

Jenis kelamin merupakan salah satu variabel yang banyak dibahas oleh para ahli dari berbagai latar belakang bidang ilmu yang berbeda, seperti kedokteran, psikologi, sosiologi, hingga pendidikan. Walaupun demikian, para ahli sepakat bahwa jenis kelamin merupakan variabel biologis yang mengategorikan manusia dan makhluk hidup lainnya ke dalam tiga kategori, yaitu lelaki, perempuan, dan inter-seks. Kategorisasi tersebut didasarkan pada faktor kromosom, fungsi organ reproduksi, genetik, dan juga hormon (Miles, 2020; Newman, 2018; Peters & Norton, 2018).

Mengacu pada pengertian tersebut, variabel jenis kelamin melekat pada setiap makhluk hidup, khususnya dalam penelitian ini adalah manusia, sejak kelahirannya. Bahkan teknologi yang semakin mutakhir memungkinkan bayi untuk diketahui jenis kelaminnya sejak sebelum mereka lahir menggunakan teknik ultrasonografi, sebuah teknik yang digunakan untuk menampilkan citra dan/atau kondisi dari bagian dalam tubuh menggunakan suara ultra. Berdasarkan hasil pengamatan, selanjutnya bayi atau calon bayi tersebut dilabeli dengan jenis kelamin tertentu oleh dokter, keluarga, atau orang-orang yang berkompeten. Dalam kondisi tertentu, seperti bayi dilahirkan dengan organ kelamin dan kromosom yang tidak sesuai dengan karakteristik yang dimiliki oleh jenis kelamin laki-laki atau perempuan, selanjutnya bayi tersebut digolongkan dalam kelompok inter-seks (Jones, 2018; United Nations, 2015). Menurut hasil penelitian, jumlah individu yang berjenis kelamin inter-seks adalah 0,05% hingga 1,7% dari keseluruhan populasi (Carpenter, 2016; United Nations, 2015).

Bagaimanapun juga, masih terdapat kerancuan pada penggunaan istilah jenis kelamin dan *gender* meskipun istilah jenis kelamin biasa digunakan dalam keseharian. Teori tentang *gender* pertama kali dikenalkan di tahun 1981 oleh seorang psikolog yang bernama Sandra Bem. Sandra mengemukakan bahwa anak-anak mempelajari peran lelaki atau perempuan dari kebudayaan tempat dia tinggal (Cherry, 2020). Berbeda dengan jenis kelamin yang mengacu pada perbedaan biologis antara lelaki dan perempuan, *gender* merupakan status sosial yang merujuk pada peran, kebiasaan, kegiatan, dan atribut yang disematkan oleh lingkungan pada seorang individu (Peters & Norton, 2018; Newman, 2018; Srivastava, et al., 2014). Maka dari itu, *gender* berdampak pada sikap, peran, kewajiban, dan kebiasaan dari pemuda/pemudi atau lelaki/wanita dalam kehidupan sosial. Dengan demikian, istilah *gender* digunakan untuk

mendeskripsikan peran sosial seseorang, sedangkan jenis kelamin mengacu pada perbedaan biologis antara orang yang satu dengan orang lainnya (WHO, 2002).

Variabel jenis kelamin memiliki peran yang penting dalam berbagai bidang ilmu, seperti kedokteran, sosiologi, hingga pendidikan. Dalam dunia pendidikan, terdapat stereotip yang melekat pada siswa lelaki dan perempuan. Salah satu stereotip tersebut berasal dari perbedaan pada bidang keahlian, salah satunya dalam bidang STEM (*Science, Technology, Engineering, and Mathematics*). STEM dianggap sebagai ranah lelaki dan pekerjaan terkait STEM didominasi oleh kaum lelaki. Bertentangan dengan fenomena tersebut, perempuan dianggap memiliki kemampuan matematika yang kurang dan lebih tertarik pada pekerjaan dalam bidang bahasa, sosial, dan pekerjaan lainnya yang berhubungan dengan manusia (Lazarides & Lauermann, 2019; Makarove et al., 2019).

Perbedaan keahlian dan ketertarikan tersebut diduga berasal dari perbedaan struktur otak antara lelaki dan perempuan sehingga memunculkan istilah *neurosexism*. Perbedaan struktur otak ini berhubungan dengan perbedaan kecerdasan, emosional, kelainan syarafantara lelaki dan perempuan (Xin et al., 2019). Selain perbedaan-perbedaan tersebut, hal yang membedakan antara lelaki dan perempuan disebabkan oleh hormon. Hormon menjadi salah satu faktor yang memengaruhi perbedaan lelaki dan perempuan karena hormon mengatur sebagian besar aspek perilaku sosial, mulai dari reproduksi dan pemilihan pasangan hingga interaksi dan agresi sosial. Dengan kata lain, hormon memerankan peran penting dalam perbedaan antara lelaki dan perempuan (Choleris et al., 2018). Berdasarkan teori tersebut, perlu dibuktikan perbedaan keberhasilan mahasiswa di Indonesia ditinjau dari perbedaan jenis kelamin.

c. Keadaan Sosial Ekonomi

Status sosial ekonomi atau *socio economic status* (SES) diartikan sebagai kedudukan sosial atau kelas individu atau kelompok (APA, 2018). Dalam penelitian yang dilakukan oleh Bofah dan Hannula (2017), SES merupakan salah satu variabel laten yang populer digunakan untuk mengukur latar belakang keluarga. Variabel ini populer dikarenakan setiap individu (subjek penelitian) memiliki perbedaan yang berpengaruh pada kedudukan sosial mereka. Perbedaan atau ketimpangan sosial ini merupakan hasil dari suatu proses sosial (Hoffmann, 2008). Variabel ini didasarkan pada teori yang dikemukakan oleh sosiolog yang berasal dari Prancis yang bernama Pierre Bourdieu yang dikenal dengan teori dari Bourdieu (Hoffmann, 2008). Berdasarkan teori ini, terdapat tiga modal yang menentukan SES seseorang, yaitu ekonomi, budaya, dan sosial.

Sesuai dengan namanya, modal ekonomi berkaitan erat dengan uang dan kepemilikan barang yang dapat dikonversikan dengan uang. Modal yang kedua, yaitu modal budaya dibedakan menjadi tiga, yaitu modal budaya berwujud, seperti tingkat pendidikan; modal budaya berbentuk benda, seperti jumlah mobil, jumlah buku, dan jumlah kepemilikan barang lainnya; dan modal budaya berbentuk lembaga, seperti gelar akademik. Modal yang ketiga, yaitu modal sosial, berkaitan dengan pengakuan serta timbal balik yang diperoleh seseorang dari suatu institusi dan relasinya (Hoffmann, 2008; Richardson, 1986). Terkait dengan hal tersebut, faktor ekonomi dapat dikatakan sebagai modal untuk mencapai keberhasilan dalam pendidikan.

3. Analisis Kluster (*Cluster Analysis*)

Analisis kluster (*cluster analysis*) merupakan salah satu teknik statistik multivariat untuk mengidentifikasi sekelompok obyek yang memiliki kemiripan karakteristik tertentu. Pada analisis ini, jumlah kelompok yang dapat teridentifikasi tergantung pada banyak dan variasi data obyek. Hasil dari analisis kluster ini berupa grup atau sekumpulan objek yang memiliki homogenitas internal (antar anggota dalam satu kluster) yang tinggi dan memiliki heterogenitas eksternal (antara kluster yang satu dengan kluster yang lainnya) yang tinggi.

Konsep dasar dalam penggunaan analisis kluster meliputi konsep pengukuran jarak dan kesamaan. Jarak yaitu ukuran tentang jarak pisah antar obyek, sedangkan kesamaan yaitu ukuran kedekatan. Konsep ini mendasar karena pengelompokan pada analisis kluster berdasar pada kedekatan. Tujuan utama *clustering* adalah untuk menemukan atau mencari pola yang bermanfaat atau berguna pada suatu basis data, kemudian merangkumnya dan membuat lebih mudah untuk dipahami. Tujuan utama dari analisis kluster adalah untuk mengelompokkan sekumpulan data obyek ke dalam beberapa kelompok yang memiliki karakteristik tertentu dan dapat dibedakan satu sama lain untuk analisis dan interpretasi lebih lanjut sesuai dengan tujuan penelitian yang dilakukan (Gudono, 2011; Johnson & Wichern, 2014).

Analisis kluster banyak digunakan dalam mengolah data yang terkumpul dari kuesioner dengan jumlah responden yang besar. Analisis homogenitas dalam kluster terbagi ke dalam dua jenis, yakni homogenitas internal (dalam kluster) yang merupakan analisis kemiripan antar anggota dalam satu kluster dan analisis heterogenitas eksternal (antar kluster) yang berfokus pada identifikasi perbedaan antara kluster yang satu dengan kluster yang lainnya (Johnson & Wichern, 2014).

Untuk melakukan analisis kluster, ada syarat-syarat yang harus dipenuhi, yakni sampel harus representatif. Makna dari representatif di sini yakni sampel yang digunakan sudah mempresentasikan atau mewakili populasi keseluruhan. Syarat kedua yaitu tidak terjadinya multikolinearitas. Tidak adanya multikolinearitas berarti bahwa variabel yang satu bebas dari variabel lainnya. Dengan kata lain, sebuah variabel bukan merupakan kombinasi linear dari variabel-variabel lainnya.

Ada dua jenis analisis kluster, yaitu hierarki dan non-hierarki. Analisis kluster hierarki dimulai dengan pengelompokan dengan dua atau lebih objek yang mempunyai kesamaan paling dekat. Pada analisis ini terdapat tingkatan (hierarki) yang jelas antar objek, dari yang paling mirip hingga yang paling tidak mirip. Salah satu cara menyajikan kemiripan adalah dengan diagram pohon atau *dendrogram* yang dapat digambar secara manual atau dengan menggunakan program. Adapun untuk analisis kluster non-hierarki, prosedur analisis dimulai dengan terlebih dahulu menentukan terlebih dahulu jumlah kluster yang diinginkan (dua, tiga, atau yang lain). Setelah jumlah kluster ditentukan, proses kluster dilakukan dengan tanpa mengikuti proses hierarki. Metode kluster secara non-hierarki (*non-hierarchical clustering method*) ini juga biasa disebut metode *K-means*.

4. Analisis Diskriminan (*Discriminant Analysis*)

Analisis diskriminan merupakan teknik analisis statistika dependensi yang memiliki kegunaan untuk mengklasifikasikan objek beberapa kelompok. Pengelompokan ini dilakukan untuk melihat pengaruh satu atau lebih variabel lain yang merupakan variabel independen. Variabel-variabel yang mempengaruhi ini selanjutnya digunakan untuk melihat faktor-faktor yang mempengaruhi kriteria dengan membentuk kombinasi linear. Kombinasi linier dari variabel-variabel ini akan membentuk suatu fungsi diskriminan (Hair et al., 1998).

Analisis diskriminan itu mirip regresi linier berganda (atau *multivariable regression*). Perbedaannya dengan regresi linear berganda yaitu variabel dependennya (variabel terikat) bersifat kategoris (yaitu menggunakan skala ordinal maupun skala nominal) dan variabel independennya (variabel bebas) menggunakan skala metrik (yaitu interval dan rasio). Regresi berganda variabel dependennya harus metrik, sedangkan variabelnya independennya dapat berupa skala metrik maupun non-metrik (Johnson & Wichern, 2014).

Model analisis diskriminan ditandai dengan ciri khusus yaitu data variabel dependen yang harus berupa data kategori, sedangkan data independen justru berupa data non kategori.

Hal ini dapat dimodelkan sebagai berikut.

$$Y = X_1 + X_2 + X_3 + \dots + X_n$$

dengan variabel independen ($X_1, X_2, X_3, \dots, X_n$) adalah data metrik, yaitu data berskala interval atau rasio dan variabel dependen (Y_1) ialah data kategoris atau nominal, dimana ketika data kategoris tersebut hanya terdiri dari dua kode saja disebut analisis diskriminan dua kelompok (*two-groups discriminant analysis*) dan apabila terapat lebih dari dua kode atau kategori disebut sebagai analisis diskriminan ganda (*multiple discriminant analysis*).

Analisis diskriminan ini digunakan untuk mengetahui perbedaan yang signifikan antar grup pada variabel dependen. Jika perbedaan yang signifikan ditemukan, variabel independen mana pada fungsi diskriminan yang membuat perbedaan tersebut selanjutnya diidentifikasi. Fungsi atau model diskriminan (yang mirip dengan persamaan regresi) dibuat setelah terlebih dahulu melakukan klasifikasi terhadap obyek ke dalam kelompok atau grup.

Ada beberapa asumsi yang harus dipenuhi pada analisis diskriminan. Asumsi tersebut meliputi variabel bebas yang harus terdistribusi normal (adanya normalitas) (Gudono, 2011). Asumsi yang kedua yaitu matriks kovarians semua variabel independen (bebas) harus sama (*equal*). Asumsi yang ketiga yaitu tidak terjadi multikolinearitas atau dalam hal ini tidak terdapat korelasi antar variabel bebas. Asumsi yang keempat yaitu tidak terdapat data yang bersifat ekstrem (*outlier*).

Langkah analisis diskriminan selanjutnya yaitu menentukan variabel-variabel yang akan menjadi variabel terikat (*dependent variable*) dan variabel bebas (*independent variable*). Dengan adanya variabel bebas dan variabel terikat ini, dapat dibuat fungsi pembeda atau disebut sebagai fungsi diskriminan. Ada metode yang dapat dilakukan untuk menentukan fungsi diskriminan. Metode-metode tersebut di antaranya yaitu *simultaneous estimation* dengan memasukkan semua variabel secara bersama-sama lalu disusun fungsi diskriminan *step-wise estimation* dengan variabel dimasukkan satu per satu ke dalam model diskriminan; dengan menguji signifikansi fungsi diskriminan yang terbentuk; dengan menggunakan Wilk's lambda, Pillai's trace, F test, dan lainnya; dan dengan menguji ketepatan klasifikasi dari fungsi diskriminan (secara individual dengan menggunakan *casewise diagnostics*). Setelah disusun fungsi diskriminan, interpretasi fungsi diskriminan dan validasi fungsi diskriminan dapat dilakukan dengan mengidentifikasi yang cocok dengan yang tidak cocok dengan data validasi (Johnson & Wichern, 2014). Adanya fungsi diskriminan ini digunakan untuk membuat model yang dapat secara jelas menunjukkan perbedaan atau diskriminasi antar partisipan yang dibedakan dengan menggunakan variabel bebas.

5. Analisis dengan Machine Learning

Pada era Society 5.0, artificial intelligence (AI) telah banyak dimanfaatkan di semua bidang. AI ini memanfaatkan data besar untuk kesejahteraan manusia. Salah satu dari aplikasi AI adalah machine learning (ML). Adanya bantuan komputer untuk mengerjakan algoritma komputer menggunakan data besar menjadi salah satu pemicu berkembangnya machine learning ini. Machine learning merupakan cabang ilmu komputer yang memberikan kepercayaan kepada komputer untuk dapat belajar tanpa diprogram secara eksplisit (Samuel, 1959).

Salah satu pendekatan pada AI ini menirukan bagaimana proses manusia atau makhluk cerdas belajar, mengenali pola dan membuat generalisasi. Proses ini dilakukan dengan pelatihan, pembelajaran, atau training. Untuk keperluan ini, banyak data yang digunakan untuk keperluan analisis dengan machine learning. Karena data yang diperlukan sangat banyak untuk proses training, data yang dipergunakan ini disebut dengan data training. Konsep kerja machine learning yakni diawali dengan menerima dan menganalisis data yang diinputkan. Data input ini digunakan untuk memprediksi nilai keluaran atau output. Dengan menggunakan input tersebut, dikenali polanya dan pola ini dimanfaatkan untuk membangun model dan mengambil keputusan. Machine learning merupakan penerapan matematika dan statistika. Pola yang dikenali dalam machine learning merupakan generalisasi dan dirumuskan dengan fungsi matematis dengan menggunakan data training. Untuk keperluan generalisasi dan pembuatan keputusan, machine learning berhubungan dengan ketidakpastian/uncertainty yang mana hal tersebut sangat erat kaitannya dengan statistika.

Machine learning seperti sebuah yang identik dengan rumus matematika (Nurhidayat et al., 2021). Machine learning memiliki minimal dua tujuan dengan menerapkan statistical learning theory, yaitu memprediksi masa depan (kejadian yang tidak dapat diamati) dan memperoleh ilmu pengetahuan (penemuan pengetahuan atau penemuan struktur yang tidak diketahui sebelumnya) yang dalam mencapai tujuan tersebut dibutuhkan data dan model untuk menggeneralisasi pola data sehingga data digunakan untuk mendapat informasi dan membuat keputusan (Putra, 2020). Statistika berperan sebagai basis dalam melakukan inferensi dan interpretasi dari model, sedangkan machine learning difokuskan pada penggunaan model untuk prediksi atau interpretasi data baru di mana semakin banyak informasi variabel independen pada model maka prediksi akan menjadi semakin akurat.

Machine learning menggunakan teknik tertentu untuk melakukan inferensi data dengan pendekatan matematis, yaitu dengan membuat model matematis yang menggambarkan pola data (Putra, 2020). Langkah awal yang dilakukan dalam membuat machine learning yaitu menentukan algoritma pembelajaran yang akan digunakan oleh mesin atau sistem dengan serangkaian input dan output. Untuk memahami struktur data dengan baik, machine learning membutuhkan pendekatan model secara statistik yang akan menghasilkan teori yang terbukti benar secara matematika dan selanjutnya output yang dihasilkan akan melalui pengujian model yang dihasilkan oleh algoritma untuk diuji keakuratan atau nilai kesalahan/error dengan menggunakan metode pengelompokan, regresi, dan peramalan (Nurhidayat et al., 2021). Menurut Jordan dan Mitchell, pendekatan pada machine learning ditandai dengan penggunaan algoritma untuk mengolah data dan memperkirakan fungsi matematika yang merepresentasikan dari input untuk dihubungkan ke

output sehingga dapat merumuskan prediksi pada data baru dengan menggunakan model (Taufiq & Mariyah, 2021).

Pada statistical machine learning pemilihan sampel atau data training yang dapat merepresentasikan populasi (mampu membangun model yang baik) akan digunakan untuk melatih mesin dan 16 kemudian model diuji kinerjanya dengan testing. Model tersebut dihasilkan oleh algoritma machine learning. Algoritma machine learning dibagi menjadi beberapa macam, yaitu supervised learning, semi-supervised learning, unsupervised learning, dan reinforcement learning (Putra, 2020). Untuk aplikasi statistika pada machine learning, fondasi yang digunakan adalah teori peluang. Teori peluang digunakan sebagai alat ukur dari derajat ketidakpastian (Fathony, 2017). Pengetahuan lain yang digunakan dalam machine learning di antaranya yaitu aljabar linear, kalkulus, dan teknik optimasi. Algoritma dalam machine learning dibagi menjadi dua kategori, yaitu parametrik (sebagai contoh yaitu model linier) dan non-parametrik (sebagai contoh yaitu Naive Bayes, decision tree, dan k-nearest neighbors) (Putra, 2020). Selain teori peluang, statistika dan machine learning membentuk konsep yang disebut statistical machine learning dengan menggunakan model regresi logistik. Seperti regresi linear, model regresi logistik adalah sebuah pendekatan untuk membuat model prediksi dengan skala dikotomi yaitu skala data nominal dengan dua kategori, seperti ya dan tidak, baik dan buruk, dan sebagainya (Roshadi, 2018). Selain itu, machine learning juga terkait dengan konsep random variable, distribusi statistik, expected value, variansi, dan konsep distribusi prior dan posterior.

Analisis utama pada machine learning yaitu klasifikasi dan prediksi. Klasifikasi adalah metode dalam machine learning yang digunakan oleh mesin untuk memilah atau mengklasifikasikan objek berdasarkan karakteristik tertentu sebagaimana manusia mencoba membedakan benda satu dengan yang lain. Sedangkan prediksi atau regresi digunakan oleh mesin untuk menduga keluaran dari suatu data masukan berdasarkan data yang sudah dipelajari dalam training.

Berikut metode machine learning yang digunakan untuk pengklasifikasian maupun prediksi :

1. Support Vector Machine (SVM) Support Vector Machine (SVM) adalah algoritma klasifikasi yang memiliki kinerja yang bagus, tingkat keakuratan yang dinilai cukup tinggi untuk pengklasifikasian data, dan error rate yang dihasilkan minimum. Adapun keuntungan dari algoritma SVM adalah dapat menentukan hyperplane atau pemisah dengan memilih bidang yang memiliki optimal margin maka generalisasi pada SVM dapat terjaga dengan sendirinya, tingkat generalisasi pada SVM tidak dipengaruhi oleh jumlah data latih dengan menentukan parameter soft margin dan noise dapat dikontrol pada kesalahan klasifikasi sehingga proses pelatihan menjadi jauh lebih ketat.

2. Naive Bayes 17 Naive Bayes merupakan metode pengklasifikasian berdasarkan probabilitas sederhana dan dirancang agar dapat dipergunakan dengan asumsi antar variabel penjelas saling bebas (independen). Pada algoritma ini pembelajaran lebih ditekankan pada estimasi probabilitas. Algoritma Naive Bayes pengklasifikasian tidak membutuhkan adanya pemodelan maupun uji statistik. Keuntungan lain algoritma Naive Bayes adalah tingkat nilai error yang didapat lebih rendah ketika data set berjumlah besar, selain itu akurasi Naive Bayes dan kecepatannya lebih tinggi pada saat diaplikasikan ke dalam data set yang jumlahnya lebih besar.

3. Regresi Linier Regresi adalah salah satu teknik dalam machine learning, dimana teknik ini berasal dari ilmu statistik untuk mencari parameter-parameter dalam persamaan linear yang dapat memetakan input dan output. Ada setidaknya tiga kegunaan dalam analisis regresi, yaitu mendeskripsi fenomena data atau kasus yang sedang diteliti, untuk tujuan kontrol, dan untuk tujuan prediksi. Inti dari regresi linier yaitu memprediksi variabel target dengan mencocokkan dengan fungsi relasi linier terbaik di antara variabel bebas dan terikat.

4. Random Forest Random Forest merupakan salah satu algoritma yang digunakan untuk pengklasifikasian data set dalam jumlah besar. Proses klasifikasi pada Random Forest berawal dari memecah data sampel yang ada dalam decision tree secara acak. Setelah pohon terbentuk, dilakukan voting pada setiap kelas dari data sampel. Kemudian, dengan menggabungkan vote dari setiap kelas, diambil vote yang paling banyak. Dengan menggunakan Random Forest pada klasifikasi data dihasilkan vote yang paling baik.

Pada saat proses klasifikasi selesai dilakukan, inisiasi dilakukan dengan sebanyak data berdasarkan nilai akurasi. Keuntungan penggunaan random forest yaitu mampu mengklasifikasi data yang memiliki atribut yang tidak lengkap, dapat digunakan untuk klasifikasi dan regresi. Banyak software yang dapat digunakan untuk melakukan analisis machine learning, di antaranya yaitu dengan menggunakan software R, Python, GoogleCloud AutoML, Orange3, Scikit-Learn, atau Tensorflow.

Ada beberapa tahapan untuk melakukan analisis. Jika peneliti bekerja pada data utuh, data bisa dipecah menjadi dua bagian dengan perbandingan 80:20. Pemecahan data ini dilakukan antara data training dan data testing. Langkah selanjutnya adalah pengujian dengan 10-fold Cross Validation. Pada pengujian ini dilakukan dengan membagi data set menjadi 10 bagian subset data dengan setiap subset dilakukan pengulangan iterasi sebanyak 10 kali untuk training dan testing dengan setiap iterasi disisakan satu subset untuk testing dan subset yang lain digunakan untuk training. Tujuan pengujian untuk menghindari terjadinya overfitting. Cross validation ini digunakan untuk memperkirakan keterampilan model pada machine learning pada data yang belum pernah dilihat sebelumnya. Kemudian pengujian overfitting dilakukan untuk mengetahui perbandingan metode ketika melakukan analisis dengan menggunakan beberapa metode sekaligus dengan melihat MSE.

Ada beberapa teknik algoritma pembangunan model pada machine learning. Algoritma tersebut masing-masing disajikan sebagai berikut.

1. Random Forest (RF)

RF merupakan algoritma DM yang diawasi. Algoritma ini membangun beberapa pohon keputusan dan menggabungkannya. Selain itu, algoritma ini menggunakan mekanisme voting dari beberapa pohon keputusan untuk meningkatkan kekurangan dari sebuah pohon keputusan tunggal dan mendapatkan prediksi yang lebih akurat (Biecek, 2018; Hannaford et al., 2021). Setiap pohon dalam RF memberikan prediksi kelas, dan kelas dengan suara terbanyak menjadi prediksi model. salah satu keuntungan utama dari RF dibandingkan dengan teknik lainnya adalah kemampuannya untuk melawan atau setidaknya membatasi overfitting (Cruz-Jesus et al., 2020).

2. Neural Networks (NN)

NN merupakan serangkaian algoritma DM yang berusaha untuk mengenali hubungan-hubungan yang mendasari dalam satu set data dengan meniru proses informasi otak manusia (Alturki et al., 2022; Cruz-Jesus et al., 2020). Ini terjadi dalam dua fase. Pertama, jaringan dilatih dengan data berpasangan untuk menentukan pemetaan input-output. Kemudian, bobot hubungan antara neuron-neuron dibuat tetap, dan jaringan digunakan untuk menentukan klasifikasi dari satu set data baru. Masalah utama ketika menggunakan NN adalah bahwa model akhirnya merupakan kotak hitam yang hanya terdiri dari set bobot pada koneksi antara neuron (Cruz-Jesus et al., 2020). Oleh karena itu, keterbacaan model sangat terbatas.

3. Logistic Regression (LR)

LR merupakan algoritma DM yang diawasi. Algoritma ini mencoba untuk membedakan antara kelas (atau kategori) dengan menganalisis hubungan antara fitur-fitur independen yang ada (Alturki et al., 2022; Yağcı, 2022). Dalam penelitian ini, regresi logistik biner digunakan ketika fitur dependen hanya memiliki dua hasil yang mungkin dan regresi logistik multinomial, di mana fitur dependen memiliki tiga hasil yang mungkin (Boehmke & Greenwell, 2019).

4. Naïve Bayes (NB)

NB merupakan algoritma DM yang diawasi. Algoritma ini mengasumsikan bahwa fitur-fitur saling independen satu sama lain (Alturki et al., 2022). Algoritma ini didasarkan pada teorema Bayes, yang menyatakan bahwa jika peristiwa B telah terjadi, maka kita dapat menemukan probabilitas peristiwa A, dan direpresentasikan sebagai berikut: $P(A|B) = (P(B|A) * P(A))/P(B)$.

5. k-Nearest Neighbor (kNN)

kNN merupakan algoritma DM yang diawasi. Algoritma ini memperkirakan kemungkinan bahwa suatu titik data akan menjadi bagian dari satu kelompok berdasarkan pengukuran jarak antara contoh klasifikasi dan contoh pelatihan terdekat di ruang fitur (Cruz-Jesus et al., 2020). Algoritma ini sangat mudah diimplementasikan, dan kinerjanya hanya bergantung pada pilihan parameter K (Cruz-Jesus et al., 2020).

Untuk mengevaluasi keefektifan model dalam memprediksi status studi mahasiswa, data train dan test digunakan. Proses evaluasi model prediksi dilakukan dalam dua langkah, yakni langkah pembelajaran pada data train dan langkah prediksi atau klasifikasi pada test (data tak terlihat). Pada langkah prediksi, model melakukan klasifikasi data yang tidak terlihat ke dalam salah satu kelas berikut: true-positive (TP), false-positive (FP), true-negative (TN), dan false-negative (FN) seperti yang ditunjukkan pada Tabel 2 yang disebut confusion matrix. Berdasarkan data dari matriks kebingungan tersebut, maka ada lima metrik yang digunakan untuk mengevaluasi efisiensi model prediksi, yakni classification accuracy, F-Score, precision, dan recall.

1. Classification Accuracy (CA)

CA merupakan rasio pengamatan yang diprediksi dengan benar (TP + TN) terhadap jumlah total pengamatan (TP + TN + FP + FN). Akurasi menarik jika TP dan TN lebih penting

daripada FP dan FN. Namun, akurasi mungkin tidak sangat informatif ketika salah satu kategori biner lebih dominan (disebut label yang tidak seimbang) (Biecek & Burzykowski, 2021; Yağcı, 2022). Misalnya, jika data pengujian mengandung 90% keberhasilan, sebuah model yang selalu memprediksi keberhasilan akan mencapai akurasi 0,9, meskipun dapat diperdebatkan bahwa ini bukan model yang sangat berguna. Ada situasi di mana FP atau FN mungkin lebih mengkhawatirkan. Oleh karena itu, ukuran lain yang difokuskan pada hasil palsu (FP dan FN), mungkin menarik.

2. Precision

Precision merupakan rasio pengamatan yang diprediksi dengan benar (TP) terhadap total pengamatan positif yang diprediksi (TP + FP). Nilai precision berada dalam rentang [0,1] (Yağcı, 2022). Precision tinggi jika jumlah FP rendah. Oleh karena itu, precision menjadi ukuran yang berguna ketika hukuman untuk melakukan kesalahan Jenis I (FP) tinggi (Biecek & Burzykowski, 2021).

3. Recall

Recall merupakan rasion pengamatan positif yang diprediksi dengan benar (TP) terhadap total pengamatan dalam kelas sebenarnya (TP + FN). Nilai recall berada dalam rentang [0,1] (Yağcı, 2022). Recall tinggi jika jumlah FN rendah. Oleh karena itu, recall menjadi ukuran yang berguna ketika hukuman untuk melakukan kesalahan Jenis II (FN) tinggi (Biecek & Burzykowski, 2021).

4. F-Score (F1)

Skor F1 cenderung memberikan nilai rendah jika precision maupun recall rendah, dan nilai tinggi jika precision dan recall keduanya tinggi. Misalnya, jika presisi adalah 0, maka skor F1 juga akan menjadi 0 tanpa memperhatikan nilai recall. Oleh karena itu, ini merupakan ukuran yang berguna jika kita harus mencari keseimbangan antara precision dan recall yang dapat dihitung sebagai skor $F1 = (2 * Precision * Recall) / (Precision + Recall)$.

Table 2. The Confusion Matrix

		Predicted	
		Negative (0)	Positive (1)
Actual	Negative (0)	TN	FN
	Positive (1)	FP	TP

Selain menggunakan informasi pada tabel confusion matrix, keefektifan model prediksi status studi mahasiswa juga dievaluasi berdasarkan informasi area under curve (AUC) dari kurva receiver operating characteristics (ROC). Kurva AUC-ROC digunakan untuk mengevaluasi kinerja sebuah masalah klasifikasi. AUC-ROC adalah metrik yang banyak digunakan untuk mengevaluasi kinerja algoritma ML, terutama dalam kasus di mana terdapat dataset yang tidak seimbang (Yağcı, 2022), dan menjelaskan seberapa baik model dalam

melakukan prediksi (Wang et al., 2023). Semakin luas area yang tercakup, semakin baik algoritma pembelajaran mesin dalam membedakan kelas-kelas yang diberikan. AUC memiliki nilai ideal 1.

B. Pertanyaan Penelitian

Pertanyaan penelitian pada penelitian ini yaitu sebagai berikut.

1. Bagaimana hasil analisis bibliometrik factor-faktor yang mempengaruhi keberhasilan studi di universitas terbuka?
2. Bagaimanakah hasil analisis klasifikasi dan prediksi capaian keberhasilan mahasiswa Universitas Terbuka menggunakan *machine learning*?
3. Jika keberhasilan mahasiswa ditetapkan atau diklasifikasikan peneliti dari awal, faktor-apa saja yang secara signifikan mempengaruhi klasifikasi tersebut?
4. Bagaimana pemanfaatan dari hasil pengelompokan mahasiswa untuk melakukan analisis kebijakan manajemen mahasiswa di Universitas Terbuka?

BAB III

METODE PENELITIAN

Ada dua jenis studi review tentang faktor-faktor yang mempengaruhi keberhasilan studi di Universitas Terbuka. Studi pertama adalah *systematic literature review* menggunakan bibliometri. Studi kedua merupakan studi statistik deskriptif eksploratif menggunakan pendekatan kuantitatif, menggunakan metode *data mining* (DM). Ada dua alasan untuk menjelaskan penggunaan metode DM. Pertama, metode DM mampu membuat model prediksi dengan menganalisis data di dalam database (model prediktif) (Yağcı, 2022). Kedua, metode DM mampu menggambarkan perilaku (model deskriptif) (Yağcı, 2022). Kedua alasan tersebut erat kaitannya dengan tujuan penelitian ini yang bermaksud membuat model prediksi dan mengidentifikasi faktor-faktor (atribut) terpenting yang dapat menjelaskan status studi mahasiswa.

Dataset yang digunakan dalam penelitian ini ada dua jenis. Data pertama adalah data jurnal-jurnal dari penelitian-penelitian yang telah dipublikasikan di jurnal terindeks Scopus. Data kedua adalah dataset dari institusi pendidikan tinggi yang secara rutin menyimpan semua data tentang mahasiswa dalam bentuk elektronik. Data ini bisa berupa berbagai jenis dan volume, mulai dari demografi mahasiswa hingga pencapaian akademiknya. Dalam penelitian ini, data kedua dikumpulkan dari Sistem Informasi Akademik di sebuah perguruan tinggi negeri di Indonesia. Data tersebut berisi catatan demografi dan akademik dari 132734 mahasiswa yang memulai studinya pada tahun ajaran 2014 sampai 2018.

A. Studi Bibliometri

Penelitian pada bagian bibliometri ini merupakan *literature review* berupa analisis bibliometrik. Data yang dianalisis merupakan metadata yang diekspor dari situs web Scopus. Scopus merupakan database multidisipliner yang besar, mencakup berbagai bidang penelitian dan menyediakan berbagai alat untuk melakukan analisis bibliometrik (AIRyalat et al., 2019). Adapun prosedur pencarian hingga memperoleh metadata yang akan dianalisis yaitu:

1. Melakukan pencarian pada situs web Scopus (www.scopus.com) dengan menggunakan fitur *advanced search*: “TITLE-ABS-KEY (factors AND influencing AND student OR college AND success AND online OR learning OR distance OR education OR lms)” dengan mengaktifkan fitur *sort by relevance*. Dari langkah ini diperoleh 562 metadata.
2. Mengekspor keseluruhan informasi (*citation information, bibliographical information, abstract and keywords, funding details, dan others*) ke dalam format .csv.
3. Membersihkan 15 metadata yang tidak memiliki informasi penulis, menjadi 547 metadata.
4. Memfilter tahun publikasi mulai dari 2013 hingga 2023, menjadi 383 metadata.

Dengan menggunakan 383 metadata yang telah dipilih kemudian dianalisis menggunakan *software R* dengan *package bibliometrix* (Aria & Cuccurullo, 2017). Analisis yang dilakukan mencakup *overview, sources, authors, documents, conceptual structure, intellectual structure, dan social structure*. *Overview* memuat *main information, annual scientific*

production, average citations per year. Sources memberikan informasi tentang *most relevant sources* dan *most local cited sources*, sedangkan pada bagian *authors* memuat *most relevant authors, most relevant affiliations*, dan *corresponding author's countries*. Analisis terhadap *documents* menghasilkan informasi tentang *most global cited documents, most frequent words, wordcloud, treemap*, dan *trend topics*. Hasil analisis dari *conceptual structure* berupa *co-occurrence network, thematic map*, dan *thematic evolution*, sedangkan *intellectual structure* meliputi *co-citation network* dan *historiograph*.

Kami juga melakukan analisis bibliometrik dengan *software* VOSviewer. VOSviewer menekankan representasi grafis terhadap peta bibliometrik (van Eck & Waltman, 2010). Dibandingkan *software* pemetaan ilmiah lainnya, VOSviewer merupakan salah satu pilihan terbaik untuk melakukan analisis pemetaan ilmiah (Moral-Muñoz et al., 2020). Selain tidak memerlukan pengetahuan tentang pemrograman, VOSviewer lebih *user-friendly* namun tetap mampu memenuhi kebutuhan para penggunanya (Arruda et al., 2022). Langkah-langkah analisis yang dilakukan yaitu:

1. Memilih langkah *create a map based on bibliographic data*
2. Memilih opsi *read data from bibliographic database files*
3. Menginputkan fail .csv yang telah diunduh dari situs web Scopus
4. Memilih *type of analysis: co-occurrence, unit of analysis: author keywords, counting method: full counting*.
5. Menentukan *minimum number of occurrences of a keyword: 5*. Dari langkah ini akan muncul tulisan *of the 1546 keywords, 31 meet the threshold*
6. Menentukan *number of keywords to be selected: 31*

VOSviewer menyajikan tiga opsi visualisasi kata kunci, yaitu *network visualization, overlay visualization*, dan *density visualization* (Moral-Muñoz et al., 2020). *Network visualization* menyajikan pemetaan terhadap kata kunci yang berupa lingkaran-lingkaran yang terhubung dengan garis dan labelnya masing-masing. Volume lingkaran dan ukuran label menandakan pentingnya kata-kata kunci. Semakin penting atau relevan kata kunci tersebut, lingkaran dan labelnya akan semakin besar. Setiap lingkaran diberi warna yang berbeda, yang menandakan kluster yang terbentuk. Berikutnya adalah *overlay visualization*. Semakin terang warna lingkaran dan link pada map, menandakan tema tersebut semakin baru dan terkini. Terdapat dua jenis pemetaan untuk *density visualization*, yaitu *item density* dan *cluster density*. Pada pemetaan *item density*, semakin terang warna kuning pada label, maka semakin besar *weighing* (dalam hal ini adalah *occurrence*). Adapun untuk pemetaan *cluster density*, warna dibedakan menurut kluster masing-masing. Kepadatan warna tergantung pada *occurrence*.

B. Data Mining (DM)

Ada dua kriteria yang digunakan untuk memandu pemilihan variabel independendalam penelitian ini, yakni (1) variabel harus tersedia dalam database sistem informasi akademik perguruan tinggi; (2) variabel adalah prediktor yang signifikan dalam memprediksi capaian akademik atau status studi mahasiswa berdasarkan penelitian sebelumnya. Akhirnya, tujuh variabel terpilih sebagai variabel independen. Ketujuh variabel ini dikelompokkansebagai faktor demographics dan academic data. Tabel 1 menunjukkan deskripsi dari masing-masing variabel.

Tabel 1. Deskripsi Variabel Independen

Category	Variable Name	Description	Type	Value
Demographics	Age	Usia mahasiswa	Numerical	≥ 20
	Gender	Jenis kelamin mahasiswa	Categorical (Binary)	0= Perempuan 1 = Laki-Laki
	Marital	Status pernikahan mahasiswa	Categorical (Binary)	0 = Belum 1 = Menikah
	Employ	Status pekerjaan mahasiswa	Categorical (Multi)	0 = Lain-Lain 1 = Guru ASN 2 = Guru Yayasan 3 = Guru Honor 4 = Tidak Diketahui 5 = Bukan Guru
	Region	Daerah asal mahasiswa	Categorical (Multi)	1 = IDN-Barat 2 = IDN-Timur 3 = IDN-Tengah
	Min_Wage	Upah minimum provinsi daerah asal mahasiswa	Numerical	≥ 910000
Academic data	GPA	Nilai akhir mahasiswa	Numerical	≥ 1.98

Masa studi mahasiswa digunakan sebagai variabel dependen dalam penelitian ini. Masa studi mahasiswa ini berkisar antara 8 sampai 17 semester. Selanjutnya, masa studi mahasiswa dikategorikan menjadi data biner. Mahasiswa dengan masa studi kurang dari atau sama dengan 10 semester maka dikodekan dengan 1 (sukses) dan yang di atas 10 semester dikodekan dengan 0 (tidak sukses).

Dalam penelitian ini, model yang akan dibangun adalah model prediksi status studi mahasiswa (sukses atau tidak sukses) dengan memanfaatkan software R package “psych” (William Revelle, 2023), “caret” (Kuhn, 2008), dan “DALEX” (Biecek, 2018). Model ini dibuat dengan menganalisis data train dan divalidasi menggunakan cross validation 10-Fold. Ada lima model DM yang diterapkan dalam penelitian ini untuk memprediksi status studi mahasiswa, yakni random forest, neural network, logistic regression, naïve bayes, dan k-nearest neighbour. Kelima model tersebut memiliki efisiensi dan akurasi yang lebih baik ketika digunakan untuk memprediksi (Delen, 2010; Huang &

Fang, 2013; Nandeshwar et al., 2011; Vandamme et al., 2007). Selanjutnya dilakukan uji presisi akurasi menggunakan data validasi.

Adapun *langkah* penelitian ini disajikan pada Gambar 1.

Tabel 1. Tahapan Analisis Data

Tahapan	Deskripsi	Pengumpulan/Analisis Data
Studi 1 Menjaring atau mengumpulkan data (<i>data mining</i>) artikel-artikel jurnal yang terindeks Scopus	Data dijaring atau dikumpulkan dari sistem menggunakan software Publish or Perish	Dokumentasi
Melakukan analisis bibliometri	Melakukan analisis bibliometri mulai dari kemunculan, tahun, kata-kata yang dominan, dan topic-related menggunakan artikel yang ada	Menggunakan VosViewer dan Biblioshiny
Menuliskan artikel	Menuliskan artikel bibliometric hasil biblioshiny dan Vosviewer	Kualitatif
Studi 2 Pembersihan data (<i>data cleaning</i>)	Dari data yang telah diperoleh, data tersebut diskor ulang dan dilakukan pembersihan data (<i>data cleaning</i>)	Kuantitatif, dengan <i>software</i> Microsoft Excel
Analisis prediksi	Analisis prediksi dengan menggunakan <i>machine learning</i> dilakukan untuk melakukan pengelompokan mahasiswa menggunakan faktor-faktor yang tercatat	Kuantitatif, dengan <i>software</i> R
Identifikasi faktor atau variabel yang signifikan untuk analisis prediksi	Mengidentifikasi faktor-faktor yang memengaruhi klasifikasi keberhasilan secara signifikan	Kuantitatif, dengan <i>software</i> R
Merefleksikan kebijakan terkait manajemen memperhatikan faktor-faktor yang signifikan mempengaruhi keberhasilan mahasiswa	Analisis dilakukan untuk mengestimasi parameter butir, parameter kemampuan, nilai fungsi informasi, dan kecocokan model	Kuantitatif, dengan <i>software</i> R
Merekap hasil analisis	Hasil analisis dari tiap perangkat tes disajikan dalam tabel	Menggunakan tabel
Interpretasi	Hasil analisis diinterpretasikan dan dibahas	Kualitatif
Menuliskan artikel studi 2	Dengan menggunakan hasil analisis, dituliskan artikel jurnal yang relevan	Kualitatif
Pelaporan hasil penelitian	Penulisan laporan	
Publikasi	Penulisan artikel ilmiah dan <i>submit</i> di jurnal	

BAB IV

HASIL DAN PEMBAHASAN

A. Studi Bibliometri


Berikut ini akan dijelaskan hasil analisis bibliometrik menggunakan *software* R, meliputi *overview* sampai *social structures*. Pada bagian ini, akan dibahas tentang deskripsi database yang digunakan untuk analisis bibliometrik (lihat Gambar 1). Database yang dianalisis merupakan 383 dokumen yang terbit dari tahun 2013 hingga 2023, dengan rata-rata usia dokumen 4 tahun. Dokumen-dokumen tersebut berasal dari 303 sumber. Meskipun banyak dokumen tergolong banyak, rupanya tingkat pertumbuhan tahunan untuk publikasi dokumen terkait topik ini berada pada angka negatif (-0.51%) menandakan bahwa banyak publikasi dokumen menurun dibandingkan tahun sebelumnya. Sebanyak 1298 penulis berpartisipasi dalam penulisan dokumen, dengan 52 diantaranya sebagai penulis tunggal. Sebesar 15.4% dari total dokumen melibatkan kolaborasi internasional antar *co-author*. Rata-rata per dokumen ditulis oleh 3 *co-authors* lainnya. Terkait dengan pengutipan, setiap dokumen memiliki rata-rata sitasi sebanyak 10.57 kali yang tergolong cukup besar. Angka sitasi ini menandakan masih relevannya dokumen tersebut untuk dijadikan referensi penelitian-penelitian terkait dengan faktor-faktor yang mempengaruhi keberhasilan mahasiswa belajar online/belajar jarak jauh (FSSO).



Gambar 1. Main Information

Annual scientific production


Grafik berikut ini merupakan annual scientific production (lihat Gambar 2). Secara keseluruhan, grafik menunjukkan kenaikan yang stabil, terutama pada tahun 2014-2015 dan 2016-2018. Berikutnya, kenaikan terbesar mulai terjadi pada tahun 2019 ke tahun 2020. Produksi artikel paling banyak berada pada tahun 2022. Grafik ini menunjukkan bahwa tema penelitian terkait FSSO masih relevan hingga saat ini. Adapun penurunan tajam yang terjadi pada tahun 2022 ke tahun 2023 bisa jadi disebabkan karena tahun 2023 baru berjalan sekitar 5 bulan saat peneliti mengeksplor database dari website Scopus, dimana kemungkinan artikel sedang dalam proses penerbitan.



Gambar 2. Annual Scientific Production

Average citations per year

Grafik berikutnya adalah rata-rata sitasi per tahun (lihat Gambar 3). Secara keseluruhan, rata-rata sitasi per tahun terlihat fluktuatif. Pada rentan tahun tertentu, rata-rata sitasi mengalami kenaikan, namun juga mengalami penurunan yang signifikan. Rata-rata sitasi terlihat mencapai angka tertinggi pada tahun 2020. Hal ini berbanding lurus dengan *annual scientific production* pada tahun tersebut, dimana produksi dokumen sedang mengalami kenaikan yang cukup besar dari tahun 2019 ke 2020. Temuan unik terlihat pada rata-rata sitasi pada tahun 2020 hingga 2023. Grafik menunjukkan penurunan rata-rata sitasi yang cukup tajam berturut-turut selama 3 tahun, padahal *scientific production* pada tahun 2019 hingga 2022 mengalami kenaikan yang tinggi. Adapun pada tahun 2023, rata-rata sitasi mencapai angka terendah dibandingkan tahun-tahun sebelumnya.




Gambar 3. Average Citation per Year

Most relevant sources

Berikutnya kita akan membahas tentang *most relevant sources* yang disajikan pada Gambar 4. Gambar ini menyajikan sepuluh *sources* yang menerbitkan dokumen terbanyak tentang FSSO pada rentang waktu 2013 hingga 2023. Tercatat ada 10 dokumen yang terbit di ASEE Annual Conference and Exposition, Conference Proceedings, disusul 8 dokumen dari Education and Information Technologies. Berikutnya, jurnal *Frontiers in Psychology* mempublikasikan 7 artikel yang berkaitan dengan tema. Tiga jurnal secara berurutan menerbitkan 6 dokumen, yaitu *BMC Medical Education*,


Nurse Education Today, dan Sustainability (Switzerland). Berikutnya, ACM International Conference Proceeding Series dan International Journal of Environmental Research and Public Health masing-masing menerbitkan empat artikel. Terakhir, British Journal of Educational Technology dan CEUR Workshop Proceedings mempublikasikan tiga artikel yang terkait dengan FSSO.



Gambar 4. *Most Relevant Sources*

Most local cited sources

Berikutnya adalah hasil bibliometrik tentang *most local cited sources* (lihat Gambar 5). Grafik ini menyajikan sepuluh *sources* yang memiliki sitasi terbanyak atas dokumen-dokumen yang terbit di *sources* tersebut pada artikel yang juga diterbitkan pada *sources* yang sama. Secara keseluruhan, setiap *sources* memiliki lebih dari 50 sitasi. Jurnal *Computers & Education* memiliki sitasi terbanyak sebesar 228 kali. Dengan selisih hampir 100 sitasi, jurnal *Computers in Human Behavior* berada di posisi kedua terbanyak disitasi dengan 113 sitasi. Kedua jurnal berada di naungan Elsevier, dimana Elsevier sangat populer di kalangan penerbit akademis (Schmitt, 2015). Artikel terkait dengan FSSO yang terbit pada jurnal *Computer Education* telah disitasi sebanyak 82 kali, disusul oleh *MIS Quarterly* sebanyak 72 kali. Banyak sitasi yang sama juga didapat pada artikel-artikel yang terbit di jurnal *Research in Higher Education*. *The Internet and Higher Education journal* mencatat ada 62 *local citation*, disusul oleh jurnal *Studies in Higher Education* yang disitasi sebanyak 56 kali oleh penelitian yang diterbitkan pada jurnal yang sama. *Medical Education journal* menjadi satu-satunya jurnal di bidang kesehatan yang berada pada *Top 10 local citation* dengan 55 kali sitasi. Jurnal *Sustainability* juga memiliki banyak sitasi yang serupa yaitu 55 *local citation*. Yang terakhir, *British Journal of Educational Technology* menghasilkan 54 *local citation* pada jurnal terkait.




Gambar 5. *Most local cited sources*

Most relevant authors

Diagram pada Gambar 6 berikut menyajikan sepuluh *most relevant authors* yang meneliti tentang FSSO. Unit analisis ini melihat produktivitas penulis dalam menerbitkan dokumen/artikel yang berkaitan dengan tema tersebut. Dari Gambar 6 diperoleh bahwa Zhang Y merupakan *authors* paling produktif dengan empat publikasi. Beliau menerbitkan empat publikasi tersebut pada tahun 2022. Judul artikel yang beliau terbitkan salah satunya membahas tentang motivasi siswa China pada jenjang K-12 dalam belajar online. Berikutnya adalah Almaiah MA dan Althunibat A yang masing-masing menerbitkan 3 dokumen. Dua diantara tiga dokumen tersebut merupakan hasil kolaborasi antar dua author tersebut. Penelitian yang dilakukan berfokus pada faktor yang mempengaruhi penggunaan *mobile learning* dan pelaksanaan e-learning di *higher education* selama masa pandemi covid-19. Tujuh *authors* selain yang telah disebutkan memiliki 2 publikasi yang terkait dengan faktor yang mempengaruhi keberhasilan belajar siswa pada pembelajaran online/pembelajaran jarak jauh, yaitu Al-Adwan AS, Al-Khasawneh A, Albelbisi NA, Chen J, Chen L, Chen Y-H, dan Dang MY. Al-Adwan AS mempublikasikan dua dokumen yang terbit tahun 2020 dan 2021 yang membahas tentang *self-regulated learning and satisfaction* sebagai faktor yang mempengaruhi kesuksesan moocs dan perspektif TAM untuk menginvestigasi faktor yang mendorong dan menghambat penerapan moocs.


Berikutnya, Al-Khasawneh A merupakan *co-author* dari salah satu artikel yang sama-sama ditulis oleh Almaiah MA dan sebelumnya telah menerbitkan artikel yang membahas tentang sebuah *case study* mengenai faktor yang berkontribusi dalam kesuksesan e-learning di universitas pada tahun 2015. Albelbisi NA menulis dua publikasi, dimana salah satunya merupakan hasil kolaborasi dengan Al-Adwan AS tentang *self-regulated learning*. Pada tahun 2022, Chen L menerbitkan dua artikel. Sementara itu, Chen J meneliti tentang peran non-kognitif dan afektif faktor terhadap kesuksesan belajar siswa dan faktor yang mempengaruhi *student subjective well-being* yang berisiko secara akademik di sekolah menengah. Chen Y-H menerbitkan dua artikel pada tahun 2015 tentang faktor yang mempengaruhi siswa menggunakan portal website perpustakaan dan pada tahun 2022 tentang hubungan antara *school-level factors* dan perkembangan *art elective courses*. Yang terakhir, Dang MY menulis 2 artikel yang menyelidiki perbedaan gender pada pembelajaran selama pandemi covid-19, juga mengembangkan model berdasarkan faktor-faktor penting yang mempengaruhi *technology-supported learning*, khususnya *blended learning*.



Gambar 6. Most Relevant Authors

Most relevant affiliations


Grafik yang akan kita bahas berikutnya adalah grafik *most relevant affiliations* (lihat Gambar 7). *Most relevant affiliations* yang disajikan adalah sepuluh *affiliations* dari *authors* yang paling banyak meneliti/menulis tentang FSSO. Dilihat dari persebaran benua, terdapat empat *affiliations* yang berasal dari benua Asia dan masing-masing tiga *affiliations* dari benua Amerika dan benua Eropa. Tercatat ada 14 artikel yang ditulis oleh *authors* yang berasal dari University College Hospital, London. Berikutnya, penulis dari University of L'Aquila, Italia mempublikasikan 13 artikel dengan tema yang sesuai. Berikutnya, tiga *affiliations* mencatatkan *authors* yang menulis banyak artikel yang sama yaitu 12 artikel, yaitu Chulalongkorn University Thailand, Guangzhou Medical University China, dan Heidelberg University, Germany. Sebelas artikel ditulis oleh *authors* dari The Hong Kong Polytechnic University. Secara berurutan, author dari King Saud University, McGill University Quebec, dan University of California menerbitkan delapan artikel. Yang terakhir, author dari Northwestern University Feinberg School of Medicine menulis tujuh artikel.



Gambar 7. *Most Relevant Affiliations*

Corresponding author's countries

Berikut ini adalah bagan yang menunjukkan perbandingan banyak dokumen dari dua puluh negara asal para *corresponding author* (lihat Gambar 8). Batang berwarna biru muda menunjukkan banyaknya dokumen yang dihasilkan dari kolaborasi *intra-country* (SCP), sedangkan batang berwarna merah muda menunjukkan banyaknya dokumen yang dihasilkan dari kolaborasi *inter-country* (MCP). Kedua puluh negara yang dimaksud yaitu United States of America (USA), China, United Kingdom (UK), Australia, Kanada, Arab Saudi, Malaysia, Jerman, Indonesia, Korea, India, Iran, Afrika Selatan, Hong Kong, Jordan, New Zealand, Republik Ceko, Turki, dan Ethiopia. Sangat terlihat bahwa Amerika Serikat merupakan negara dengan dokumen terbanyak mengungguli negara-negara lain dengan total lebih dari 40 dokumen yang dihasilkan dari kolaborasi *intra-country*. Adapun untuk kolaborasi *inter-country* yang paling banyak menghasilkan dokumen terjadi di Saudi Arabia. Indonesia berada di urutan kesembilan dengan banyak dokumen hasil kolaborasi *intra-country* dan *inter-country* yang sama dengan Germany. Hal ini menunjukkan bahwa penelitian tentang FSSO termasuk topik yang banyak dibahas di negara-negara lain pula selain Indonesia.



Gambar 8. *Corresponding Author's Countries*

Documents

Berikut ini akan dibahas tentang sepuluh dokumen yang paling banyak disitasi (lihat Table 2). Tabel memuat judul dokumen, penulis, tahun terbitnya dokumen, total citation sejak dokumen terbit, dan *total citation per year*. Apabila dilihat secara keseluruhan, sembilan dokumen terbit sebelum tahun 2019 dan tiga diantaranya terbit pada tahun 2017. Hanya satu dokumen yang terbit pada tahun 2020 dan langsung menjadi dokumen yang paling banyak disitasi. Dokumen tersebut berjudul *“Exploring the critical challenges and factors influencing the E-learning system usage during COVID-19 pandemic”* yang ditulis oleh Almaiah et al. Artikel tersebut telah disitasi sebanyak 438 kali dengan 109,5 sitasi per tahun. Seperti yang kita ketahui bahwa tahun 2020 merupakan puncak COVID-19 pandemic dan sebagian besar pembelajaran dilaksanakan secara online, sehingga sangat mungkin bahwa artikel oleh Almaiah et al tersebut menjadi rujukan penelitian-penelitian lain yang membahas tentang tantangan dan faktor yang mempengaruhi sistem E-learning pada masa pandemi. Artikel dengan total citation terbanyak kedua yaitu artikel oleh Sverdlik et al pada tahun 2018 berjudul *“The PhD experience: A review of the factors influencing doctoral students’ completion, achievement, and well-being”*. Artikel tersebut memiliki total sitasi sebanyak 173 kali dengan 28,83 sitasi per tahun. Kedelapan artikel yang lain memiliki sitasi lebih dari 70. Hanya ada satu dokumen dengan *single-author*, berjudul *“The integration of information technology in higher education: a study of faculty’s attitude towards IT adoption in the teaching process”* yang ditulis oleh John pada tahun 2015. Dokumen tersebut memiliki 80 sitasi dengan 8,89 sitasi tiap tahunnya. Jika dilihat melalui judul

artikel secara keseluruhan, sebagian besar studi dilakukan pada jenjang perguruan tinggi dan melibatkan mahasiswa sebagai subjek penelitian.

Tabel 1. Sepuluh Dokumen Paling Banyak Disitasi


Judul	Penulis	Tahun	TS	TS/Tahun
<u><i>Exploring the critical challenges and factors influencing the E-learning system usage during COVID-19 pandemic</i></u>	Almaiah, M.A., Al-Khasawneh, A., Altunibat, A.	2020	438	109,50
<u><i>The PhD Experience: A Review of the Factors Influencing Doctoral Students' Completion, Achievement, and Well-Being</i></u>	Sverdlik, A., Hall, N.C., McAlpine, L., Hubbard, K.	2018	173	28,83
<u><i>A review of longitudinal community and hospital placements in medical education: BEME Guide No. 26</i></u>	Thistlethwaite J.E., Bartle E., Chong, A.A.L., Dick, M-L., King, D., Mahoney, S., Papinczak, T & Tucker, G.	2013	121	11,00
<u><i>The use of a mobile learning management system at an online university and its effect on learning satisfaction and achievement</i></u>	Shin, W. S., & Kang, M.	2015	117	13,00
<u><i>Discriminating factors between completers of and dropouts from online learning courses</i></u>	Youngju, L., Jaeho, C., Taehyun, K.	2012	110	10,00
<u><i>The science identity and entering a science occupation</i></u>	Stets, J. E., Brenner, P. S., Burke, P. J., & Serpe, R. T.	2017	95	13,57
<u><i>The integration of information technology in higher education: a study of faculty's attitude towards IT adoption in the teaching process</i></u>	John, S.P.	2015	80	8,89
<u><i>Student engagement in academic activities: a social support perspective</i></u>	Xerri, M.J., Radford, K. & Shacklock, K.	2017	80	13,33
<u><i>What factors determine academic achievement in high achieving undergraduate medical students? A qualitative study</i></u>	Abdulgani, H.M., Al-Drees, A.A., Khalil, M.S., Ahmad, F., Ponnampereuma, G.G., Amin, Z.	2014	75	7,50
<u><i>Barriers Effecting Successful Implementation of E-Learning in Saudi Arabian Universities</i></u>	Quadri, N.N., Muhammed, A., Sanober, S., Qureshi, M.R., Shah, A.	2017	74	10,57

TS: Total Sitasi

Words

Kita akan berpindah untuk membahas tentang kata kunci yang sering muncul terkait dengan FSSO. Unit analisis yang digunakan adalah *author keywords* di samping menggunakan *keyword plus*, untuk menambah konseptual struktur dari domain yang sedang diteliti (Oluwadele et al., 2023). Bibliometrix menyediakan beberapa penyajian data tentang kata kunci ini, diantaranya *stacked line chart*, *treemap*, *word cloud*, dan *trend topics*.

Berdasarkan Gambar 9, terlihat bahwa *“higher education”* menjadi kata kunci yang paling sering muncul, yaitu sebanyak 28 kali. Kata kunci berikutnya yaitu *“e-learning”* yang muncul sebanyak 18 kali, disusul oleh *“education”* yang muncul sebanyak 12 kali, sama dengan banyak munculnya kata *“students”*. Adapun kata kunci *“covid-19”* dan *“covid-19 pandemic”* apabila ditotal muncul sebanyak 16 kali. *“gender”* berada di urutan keenam muncul sebanyak 9 kali. kata kunci *“academic success”* terlihat muncul sebanyak 7 kali. Dua kata kunci sama-sama muncul sebanyak 6 kali, yaitu *“distance learning”* dan *“self-efficacy”*. Secara keseluruhan, beberapa kata kunci tersebut dapat dikelompokkan ke dalam kluster-kluster sesuai tema besarnya, seperti *“e-learning”* dengan *“distance learning”* sebagai metode pembelajaran, *“higher education”* dengan *“students”* dan *“academic success”*, *“gender”* dengan *“self-efficacy”* yang dimungkinkan menjadi FSSO.



Gambar 9. *Most Frequent Words*


Berikutnya adalah TreeMap (lihat Gambar 10). Penyajian bentuk ini menggambarkan visualisasi dari 50 kata kunci berdasarkan bobot masing-masing (dalam persen). Semakin besar ukuran kotak, semakin banyak kata kunci tersebut muncul pada database. Kata kunci “*high education*” mengisi 10% bagian dari lima puluh kata kunci yang ditampilkan pada TreeMap. Sepuluh *keywords* pertama yang paling banyak muncul sudah kami bahas pada Gambar 9, sehingga pada bagian ini kami akan fokus membahas kata kunci yang lain. “*student success*” dan “*university*” muncul sebanyak 6 kali, “*academic achievement*”, “*factors*”, “*influencing factors*”, “*medical education*”, “*mobile learning*”, “*motivation*”, “*online education*”, dan “*technology*” muncul sebanyak 5 kali. Berikutnya ada 11 kata kunci yang muncul sebanyak 4 kali, seperti “*nursing student*”, “*tam*”, “*teacher*”, “*resilience*”, “*satisfaction*”, dan “*success*”. Kata kunci yang lain muncul sebanyak 3 kali, diantaranya “*attitude*”, “*blended learning*”, “*m-learning*”, “*mooc*”, “*perceived usefulness*”, “*pedagogical issues*”, dan “*perceptions*”. Pada TreeMap ini, belum bisa dilihat keterkaitan antara kata kunci dan kluster yang terbentuk. Oleh karena itu, diperlukan pembahasan berikutnya yaitu *co-occurrence network*.



Gambar 10. TreeMap

Selain treemap, penyajian analisis tentang kata kunci yang lebih menarik dapat dilihat pada Gambar 11. Wordcloud menyusun kata kunci dalam bentuk yang diinginkan, dimana pada kali ini wordcloud berbentuk lingkaran. Wordcloud terdiri dari kata kunci yang memiliki ukuran dan warna yang bervariasi. Semakin besar dan tebal ukuran tulisan, menunjukkan semakin sering keyword tersebut muncul. Kata kunci yang paling sering muncul umumnya diletakkan di tengah, bertujuan untuk memusatkan perhatian pembaca. Wordcloud disusun agar penyampaian *most frequent words of text* dokumen menjadi lugas, simple, dan efektif (Heimerl et al., 2014; Lohmann et al., 2015). Melalui penyajian wordcloud pada Gambar 11, pembaca dapat langsung mengetahui bahwa “*higher education*”, “*e-learning*”, “*education*”, dan “*students*” merupakan *keywords* yang paling sering muncul dan relevan dengan tema FSSO.

Trend topics disajikan untuk mengetahui topik-topik yang trending pada rentang waktu antara tahun 2015 hingga 2023 (lihat Gambar 12). Rentang waktu dilihat dari titik pojok garis yang mewakili masing-masing *terms*, sedangkan lingkaran biru menandakan frekuensi munculnya *terms* tersebut pada tahun tertentu. Terlihat bahwa “*academic performance*” merupakan topik yang konsisten menjadi perhatian sejak tahun 2015 hingga tahun 2021. Pada tahun 2016, mulai muncul term “*e-learning*” dan masih dibahas hingga tahun 2022. Satu-satunya topik yang populer pada tahun 2017 adalah “*gender*” dan berlanjut hingga tahun 2021. Pada tahun 2018, muncul tiga topik yang signifikan yaitu “*e-learning*”, “*mobile learning*”, dan “*medical education*”. Diantara ketiga topik tersebut, “*e-learning*” menunjukkan frekuensi yang lebih tinggi dibanding dua *terms* yang lain. Lanjut pada tahun 2019, muncul dua *keywords* yang menjadi tren yaitu “*students*” dan “*self-efficacy*”. Bergeser ke tahun 2020, kata kunci populer bergeser pada “*education*” dan “*academic success*” yang telah muncul dari tahun 2018 dan “*university*” yang baru muncul pada tahun tersebut. Mulai pada tahun 2021, “*higher education*” menjadi kata kunci populer dengan frekuensi paling banyak diantara kata kunci lain selama tahun yang tercatat, bersama dengan “*online education*” dan “*academic performance*”. Kata kunci “*academic performance*” akhirnya menjadi topik populer setelah 7 tahun. Baru pada tahun 2022, *keywords* “*covid-19*”, “*covid-19 pandemic*”, dan “*distance learning*” menjadi kata kunci yang paling banyak dibahas para peneliti, dan akan berlanjut pada tahun ini (2023) dan ke depan.



Gambar 12. *Trend Topics*

Co-occurrence network

Salah satu hasil analisis bibliometrik yang penting adalah *co-occurrence network*. Pemetaan ini menjelaskan keterkaitan tema antar kata kunci. Setiap kata kunci diwakili oleh suatu lingkaran yang ukuran lingkaran tersebut tergantung pada frekuensi kata kunci itu muncul. Semakin banyak frekuensi keyword tersebut, semakin besar ukuran lingkaran dan labelnya. Adapun ketebalan garis menunjukkan keterkaitan antar kata kunci, baik dalam kluster yang sama maupun antar kluster. *Co-occurrence network* pada Gambar 13 menggambarkan tujuh kluster dan 54 *keywords* yang saling terkait. Berikut ini akan dijabarkan deskripsi masing-masing kluster dan keterkaitan antar kata kunci, sekaligus pembahasannya.

Berikut ini disajikan tabel daftar kata kunci yang dikelompokkan dalam tujuh kluster dari hasil *co-occurrence mapping* (lihat Tabel 2).

Tabel 2. Tujuh Kluster *Keywords* yang Berkaitan dengan FSSO

Kluster 1	Kluster 2	Kluster 3	Kluster 4	Kluster 5	Kluster 6	Kluster 7
<ul style="list-style-type: none"> • <i>academic performance</i> • <i>academic success</i> • <i>learning</i> • <i>motivation</i> • <i>nursing education</i> • <i>nursing students</i> • <i>students</i> 	<ul style="list-style-type: none"> • <i>covid-19</i> • <i>covid-19 pandemic</i> • <i>distance learning</i> • <i>influencing factor</i> • <i>mobile learning</i> • <i>university</i> 	<ul style="list-style-type: none"> • <i>academic achievement</i> • <i>gender</i> • <i>retention</i> • <i>self-efficacy</i> • <i>success</i> 	<ul style="list-style-type: none"> • <i>factors</i> • <i>online education</i> • <i>teachers</i> • <i>technology</i> 	<ul style="list-style-type: none"> • <i>e-learning</i> • <i>entrepreneurship</i> • <i>higher education</i> • <i>satisfaction</i> 	<ul style="list-style-type: none"> • <i>education</i> • <i>training</i> 	<ul style="list-style-type: none"> • <i>online learning</i> • <i>student success</i>


Thematic map

Thematic map disajikan dalam diagram strategis kepadatan dan sentralitas terhadap kata kunci (lihat Gambar 14). Kata kunci tersebar pada empat kuadran, dimana kuadran 1 merupakan *motor themes*, kuadran 2 merupakan *niche themes*, kuadran 3 merupakan *emerging or declining themes*, dan kuadran 4 merupakan *basic and transversal themes* (Giannakos et al., 2020). *Motor themes* menandakan bahwa kata kunci yang berada pada kuadran tersebut tergolong terpusat dan telah berkembang. Mereka memiliki sentralitas dan kepadatan yang tinggi. Dengan kata lain, tema-tema pada kuadran ini potensial untuk diteliti dan berkembang di masa depan. Kata kunci yang masuk pada kuadran 1 diantaranya adalah “*students*”, “*gender*”, dan “*self-efficacy*”. Terdapat pula kata kunci yang berada diantara kuadran 1 dan kuadran 2, yaitu “*research*”, “*residency*”, dan “*training*”. Kata kunci tersebut tergolong tema yang telah berkembang tetapi terisolasi, namun juga berpotensi untuk dikembangkan.

Adapun kata kunci yang secara keseluruhan berada di kuadran 2 terlihat lebih banyak dibandingkan kata kunci pada *motor themes*. Kata kunci tersebut dikelompokkan dalam empat kluster, kluster pertama terdiri dari “*mooc*”, “*self-regulated learning*”, dan “*engagement*”. Kluster kedua memuat kata kunci “*influencing factors*”, “*physical education*”, dan “*adolescents*”. Kata kunci “*academic success*”, “*entrepreneurial intentions*”, dan “*resilience*” masuk dalam kluster ketiga, dan yang keempat yaitu “*medical education*”, “*admissions*”, dan “*medical students*”. Keseluruhan kata kunci pada empat kluster tadi tergolong dalam *niche themes*, yang maksudnya adalah bahwa kata kunci tersebut terfokus pada satu tema dari suatu bidang/disiplin ilmu dan sedang berkembang pada tema bibliometrik yang dilakukan.

Ada tiga kata kunci yang berada pada kuadran ketiga, atau tergolong dalam *emerging or declining themes*. Tiga kata kunci tersebut adalah “*art education*”, “*biomedical research*”, dan “*purchase intention*”. Berikutnya, terdapat empat kluster pada kuadran keempat sebagai *basic themes*. Kuadran ini memiliki sentralitas tinggi namun kepadatan yang rendah, yang artinya kata kunci yang termasuk dalam *basic themes* merupakan tema penting yang memberikan pemahaman yang baik terhadap tema bibliometrik yang dilakukan. Kata kunci tersebut diantaranya “*covid-19 pandemic*”, “*covid-19*”, “*success*”, “*teachers*”, “*higher education*”, “*university*”, “*academic performance*”, “*education*”, “*factors*”, “*technology*”, “*e-learning*”, dan “*distance learning*”. Oleh


karena tema tersebut termasuk tema dasar terhadap FSSO, terkadang tema-tema tadi tergolong kurang berkembang.



Gambar 14. *Thematic Map*

Thematic evolution

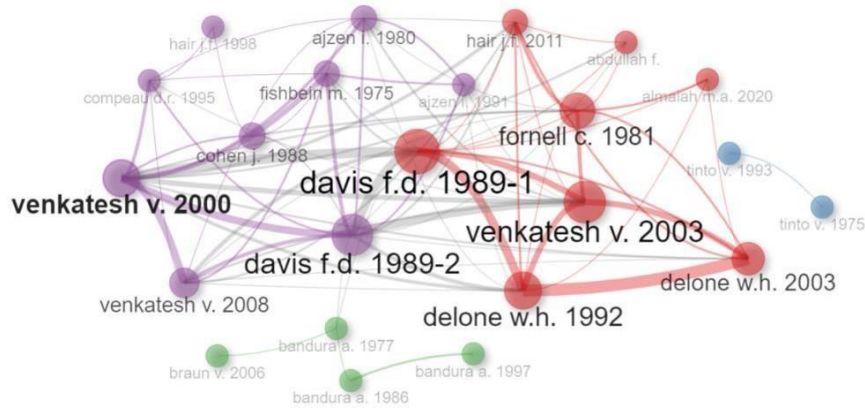
Thematic evolution digambarkan dengan diagram Sankey (lihat Gambar 15). Diagram ini menunjukkan keterkaitan tema pada rentang waktu yang lalu dan berkembang menjadi tema yang baru di rentang waktu berikutnya. Tiap tema disimbolkan dengan persegi panjang, dimana ukuran persegi panjang tersebut akan menjelaskan frekuensi munculnya tema tersebut. Evolusi antartema ditunjukkan dengan *shadow line*. Semakin jelas dan tebal garis yang tergambar, semakin kuat keterkaitan antara kedua tema. Timeline dibagi menjadi tiga bagian, yaitu tahun 2013 hingga 2016 as *time slice* 1, tahun 2017 hingga 2020 as *time slice* 2, dan tahun 2021 hingga 2023 as *time slice* 3. Apabila dilihat dari keseluruhan bagian *timeline*, *time slice* 2 memiliki tema yang lebih beragam dibanding *time slice* 1 dan 3. Tema yang berevolusi belum tentu berubah ke tema yang lain, seperti contohnya “*motivation*” pada *time slice* 1 masih relevan pada *time slice* 2. Adapun suatu tema dapat *shifting into parts of themes*, seperti “*education*” pada *time slice* 1 berevolusi ke dalam tema “*education*” dan “*gender*” pada *time slice* 2, dan kembali berevolusi menjadi tiga tema yaitu “*mobile learning*”, “*learning*”, dan “*academic achievement*”. Dari Gambar 15 kita juga mendapati bahwa “*higher education*” merupakan tema/topik yang konsisten dalam pembahasan tentang FSSO. Dari *time slice* 1, “*higher education*” berevolusi ke dalam dua tema yaitu “*e-learning*” dan “*higher education*”. Unikny, tema “*higher education*” pada *time slice* 3 rupanya merupakan hasil evolusidari empat tema pada *time slice* 2 yaitu “*influencing factors*”, “*education*”, “*e-learning*”, dan “*higher education*”. Temuan yang unik juga terlihat pada linkage antara kata kunci “*students*” pada *time slice* 1 dan *time slice* 2 berevolusi menjadi tema “*gender*” pada *time slice* 3. Tema “*distance learning*” mulai muncul pada rentang tahun 2017-2020 dan berkaitan dengan tema “*covid-19 pandemic*” pada *time slice* 3. Beberapa kata kunci/tema pada *time slice* 3 dapat dijadikan patokan sebagai tema yang masih berkembang ke depan.



Gambar 15. *Thematic Evolution*

Intellectual structure

Berikut ini disajikan *co-citation network* dari beberapa referensi di FSSO (lihat Gambar 16). Ukuran lingkaran merepresentasikan jumlah normalisasi kutipan yang diterima oleh artikel, sedangkan ketebalan garis yang menghubungkan lingkaran tersebut merepresentasikan kekuatan kutipan bersama. Adapun warna yang beragam menunjukkan kluster yang terkait dengan artikel tersebut. Setiap lingkaran diberi label nama penulis pertama dan tahun terbit dari artikel (Leung et al., 2017). Berdasarkan Gambar 16, diketahui bahwa *co-citation network* membentuk empat kluster.



Gambar 16. *Co-citation Network*

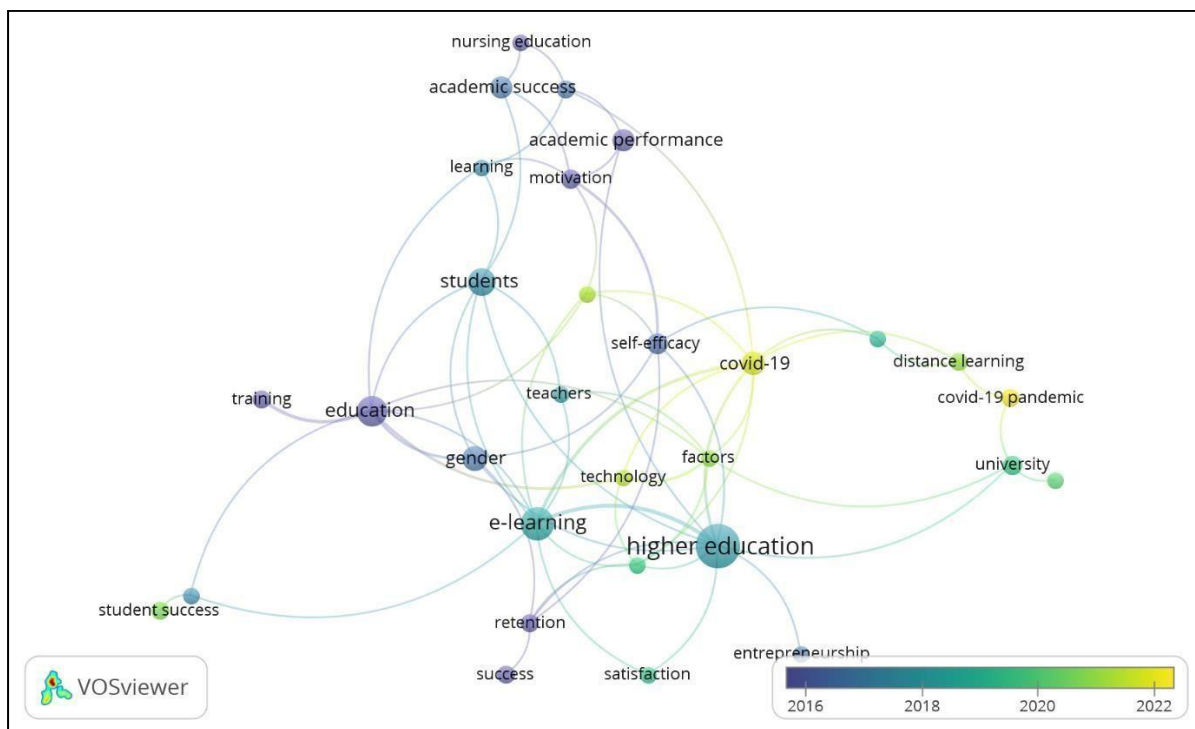
Social structure: Collaboration network

Collaboration network pada Gambar 17 menggambarkan keterkaitan antara penulis dalam menerbitkan artikel yang berkaitan dengan FSSO. Keterkaitan yang dimaksud yaitu sebagai *co- authors* di artikel yang terbit. Semakin besar ukuran lingkaran, semakin banyak kedua penulis yang terkait berkolaborasi pada artikel/dokumen yang diterbitkan. Warna yang beragam merepresentasikan hasil dokumen yang dihasilkan dari kolaborasi. Dari sembilan kolaborasi yang tergambar pada *collaboration network*, terdapat kolaborasi antar empat penulis, tiga penulis, dan dua penulis. Satu kolaborasi terjadi antara empat penulis, yaitu Adedokun BO, Ajayi IO, Adeniji- Solowue AT, dan Adegoke F. Terdapat dua kolaborasi dengan tiga penulis, yang pertama yaitu kolaborasi oleh Almaiah MA, Althunibat A, dan Al-Khasawneh A. Ketiga penulis tersebut melakukan kolaborasi yang lebih banyak dibandingkan kolaborasi yang lain, ditandai dengan ukuran lingkaran yang lebih besar dibandingkan lingkaran yang lain dan garis hubung yang lebih tebal. Kolaborasi oleh tiga penulis juga dilakukan oleh Yusop FD, Albelbisi NA, dan Al-Adwan AS. Tujuh kolaborasi lainnya

VOSViewer Result


VOSViewer menghasilkan tiga pemetaan yang berbeda, yaitu *network visualization*, *overlay visualization*, dan *density visualization*. *Network visualization* mencakup pemetaan yang serupa dengan *co-occurrence network* dan Bibliometrix dan telah dibahas pada bagian sebelumnya, sehingga pada bagian ini penulis hanya akan membahas tentang *overlay visualization* dan *density visualization*.

Overlay visualization memberikan gambaran tentang perkembangan kata kunci. Setiap *keywords* memiliki warna yang berbeda, dilihat dari legenda yang disediakan. Dari map ini, kita dapat mengetahui kapan suatu kata kunci ini mulai banyak digunakan dalam dunia penelitian. Kata kunci yang sudah lama muncul diberi warna ungu, sedangkan kata kunci yang tergolong baru dalam dunia penelitian FSSO diberi warna kuning. Berdasarkan Gambar 19, terdapat beberapa kata kunci yang baru pada topik FSSO, diantaranya “*covid-19*”, “*covid-19 pandemic*”, dan “*technology*”. Adapun kata kunci yang telah lama ada di literatur yaitu “*education*”, “*academic performance*”, “*retention*”, dan “*success*”.




Gambar 19. *Overlay Visualization*

Selain *overlay visualization*, VOSviewer memberikan hasil pemetaan *density visualization*. Pemetaan ini dapat disesuaikan unit analisisnya, apakah *item* atau *cluster density*. *Item density* (lihat Gambar 20) menyangkan warna kuning yang tingkat keterangannya menyesuaikan *occurrence* dari kata kunci tersebut muncul pada database. Semakin terang warna kuning, semakin tinggi *occurrence* dari kata kunci tersebut. Hasil pemetaan ini sesuai dengan *co-occurrence network*. Apabila pada *density visualization* ditunjukkan dengan warna kuning menyala, pada *co-occurrence network* ditunjukkan dengan ukuran huruf dan lingkaran.



Gambar 20. Density Visualization (Item Density)

Selain penyajian dengan *co-occurrence network*, VOSviewer memberikan alternatif penyajian *keywords* yang telah dikelompokkan ke dalam kluster. Pemetaan pada Gambar 21 menggunakan warna dasar hitam dengan label kata kunci berwarna putih. Setiap kata kunci memiliki warna masing-masing, dimana warna yang sama menunjukkan kluster yang sama. Semakin terang warna yang muncul, semakin tinggi *occurrence* dari kata kunci tersebut dibandingkan kata kunci lain dalam satu kluster.



Gambar 21. *Density Visualization (Cluster Density)*

Co-occurrence dari beberapa topik yang berkaitan dengan FSSO

Bagian berikut ini akan membahas hubungan yang lebih spesifik dengan kata kunci yang dipilih. VOSviewer menyediakan fitur yang memungkinkan kita memilih satu kata kunci dan melihat kaitannya dengan kata kunci-kata kunci lainnya. Kata kunci yang dipilih untuk dibahas lebih jauh pada bagian ini meliputi beberapa kata-kata kunci pada *basic themes* dan *motor themes*. Pada *basic themes* (lihat Gambar 14), kami tertarik untuk membahas lebih jauh kata-kata kunci "*higher education*", "*covid-19*", dan "*factors*". Kuadran *motor themes* menunjukkan bahwa "*gender*" dan "*self-efficacy*" menjadi dua kata kunci pada urutan kedua dan ketiga yang paling banyak muncul, secara berturut-turut. Meskipun "*students*" menjadi kata kunci dengan frekuensi terbanyak pada *motor themes*, kami memutuskan tidak membahas lebih lanjut kata kunci tersebut karena fokus studi kami lebih kepada mengeksplorasi faktor-faktor internal (seperti atribut mahasiswa) atau eksternal (seperti desain teknologi) yang berpotensi dalam mempengaruhi keberhasilan studi mahasiswa. Dengan kata lain, kami lebih memilih mengeksplorasi lebih jauh kata kunci "*factors*" pada kuadran *basic themes* untuk memperoleh pemahaman yang lebih mendalam pada "*students*" pada kuadran *motor themes*.

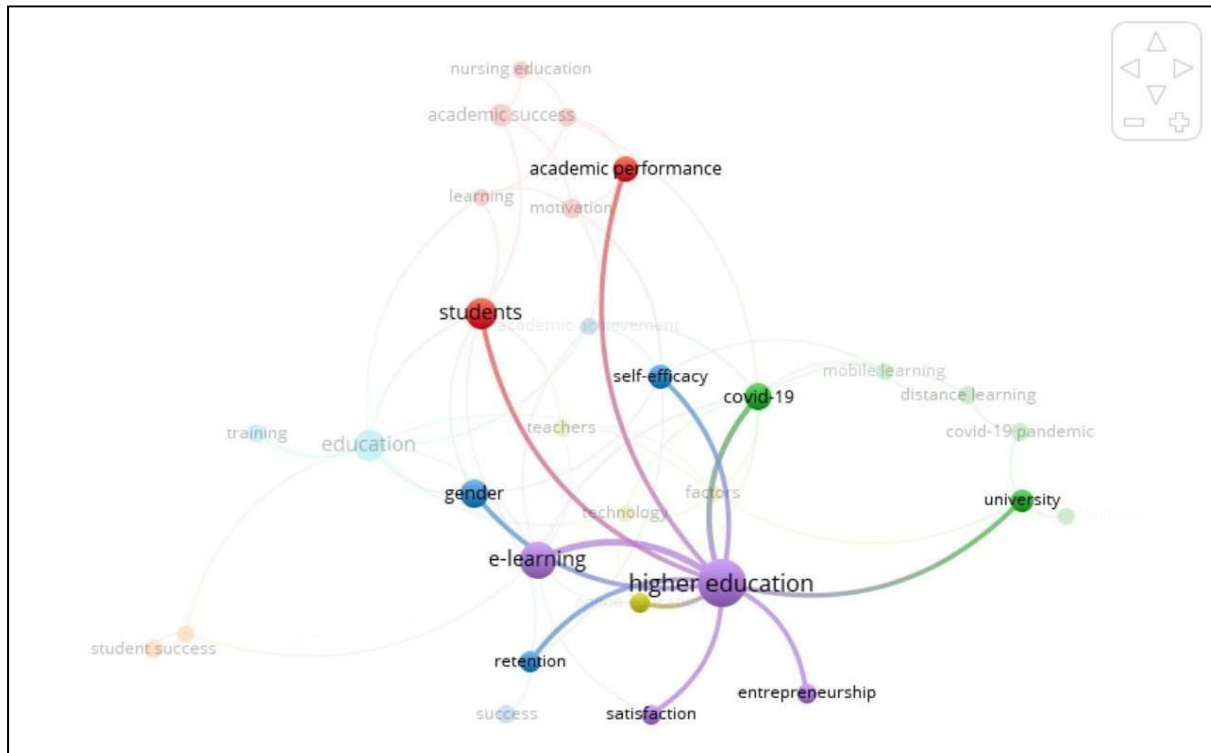
Topik-topik terkait kata kunci "*higher education*"

Berdasarkan Gambar 22, "*higher education*" berkaitan dengan beberapa kata kunci baik dalam satu kluster yang sama maupun lintas kluster, seperti "*academic performance*", "*students*", "*self-efficacy*", "*covid-19*", "*gender*", "*retention*", "*university*", "*satisfaction*", "*entrepreneurship*", dan "*e-learning*". Kata kunci yang muncul tersebut merupakan kata kunci yang memiliki keterkaitan tinggi dengan "*higher education*", sedangkan kata kunci dan garis yang tidak muncul menandakan kata kunci tersebut tidak relevan dengan kata kunci yang dipilih. Penelitian tentang FSSO banyak dilakukan pada jenjang *higher/tertiary education* dengan subjek penelitiannya yaitu *university students*. Pembelajaran online atau pembelajaran jarak jauh yang dilakukan adalah dengan *e-learning*. Kata kunci "*covid-19*" muncul pada topik ini, menandakan bahwa *e-learning* banyak digunakan sebagai alternatif pembelajaran saat masa pandemi.

Satisfaction, *entrepreneurship*, dan *e-learning* termasuk dalam satu kluster yang berkaitan dengan *higher education* (ditandai dengan warna ungu). Apabila ditelusuri lebih jauh, *satisfaction* merupakan salah satu *user success factors of e-learning* (Al-Fraihat et al., 2020). Kesuksesan *information system* dapat diketahui dari tingkat *user satisfaction* (Andrade et al., 2020). Selain itu, *students' satisfaction* terhadap kampus dan *online course* berkorelasi dengan *course completion in previous studies* (Amoozegar et al., 2017; Shaikh & Asif, 2022; Tello, 2007). Dengan kata lain, siswa yang memiliki *satisfaction* tinggi terhadap kampus (sistem) dan *course* yang diambil dalam pembelajaran online akan memiliki peluang lebih besar untuk menyelesaikan studi. Adapun kata kunci *entrepreneurship* rupanya berkaitan dengan penelitian tentang pembelajaran online/pembelajaran jarak jauh yang banyak dilakukan pada *entrepreneurship course/education*.

Pada kluster lain (berwarna biru), kata kunci *retention*, *gender*, dan *self-efficacy* memiliki keterkaitan langsung dengan *higher education*. *Retention* merupakan proses siswa bertahan untuk melanjutkan kuliah dan menyelesaikan study program. Beberapa penelitian menemukan bahwa *students' success* yang diukur dari ketahanan, pembelajaran, atau *their completeness* rupanya lebih rendah saat dilakukan dalam *online courses* (Ferdousi, 2016; Hamann et al., 2021). Selain *retention*, banyak studi yang meneliti variabel gender sebagai salah satu variabel demografis siswa yang berpotensi mempengaruhi keberhasilan siswa dalam mengikuti pembelajaran online (Yu, 2021), meskipun hanya kecil pengaruhnya (Perkowski, 2013; Yawson & Yamoah, 2020). Kata kunci berikutnya adalah

self-efficacy. *Self-efficacy* dalam pembelajaran online merupakan keyakinan seseorang akan kemampuannya dalam menyelesaikan pembelajaran online, bertahan dalam studinya, dan mencapai tujuan yang dia tetapkan, yaitu mendapatkan hasil belajar yang baik (Bubou & Job, 2022).



Gambar 22. Topik-topik yang terkait dengan kata kunci “higher education”

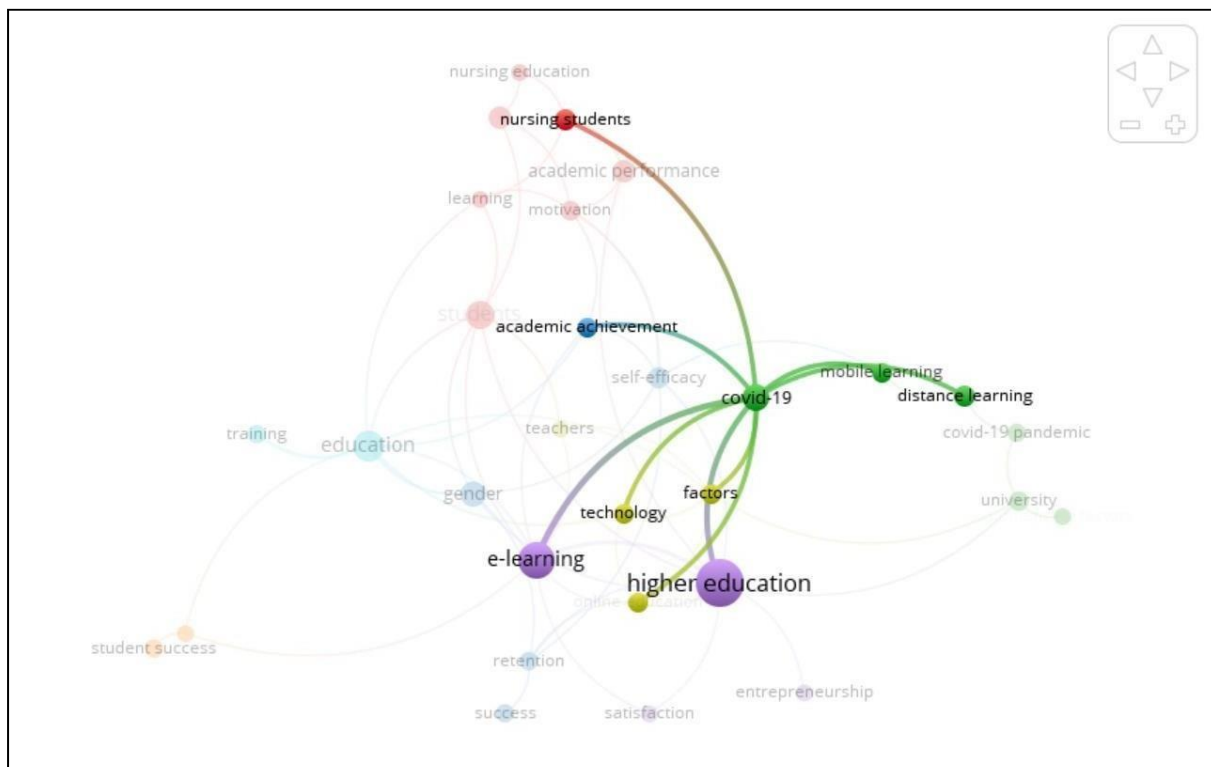
Topik-topik terkait kata kunci “*covid-19*”

Covid-19 merupakan salah satu keyword yang menjadi *motor themes* pada penelitian yang berkaitan dengan FSSO. Terdapat lima kluster yang berkaitan langsung dengan kata kunci “*covid-19*”, ditandai dengan warna hijau, ungu, kuning, biru, dan merah. Beberapa kata kunci yang tergolong satu kluster dengan kata kunci “*covid-19*” adalah “*mobile learning*” dan “*distance learning*”. Kedua kata kunci tersebut merupakan dua contoh bentuk pembelajaran dan sistem yang dikembangkan selama masa pandemi covid-19 berlangsung. Penelitian yang dilakukan berkaitan dengan e-learning selama dan pasca pandemi diantaranya studi oleh Almaiah et al. (2022), Almaiah et al. (2021), Voicu & Muntean (2023), Kumar et al. (2022), dan Gharaibeh & Gharaibeh (2020), sedangkan penelitian tentang *distance learning* selama dan pasca pandemi oleh Park et al. (2022), Amir et al. (2020), Churiyah et al. (2020), Oliveira & Greenidge (2020), Masha’al et al. (2020), Rizun & Strzelecki (2020), Afshan & Ahmed (2020), and F. Berger et al. (2021). Beberapa penelitian tersebut umumnya dilakukan pada *undergraduate* maupun *graduate student* di beberapa universitas baik dalam maupun luar negeri.

Berikutnya yaitu kluster ungu, yang terdiri dari kata kunci “*e-learning*” dan “*higher education*”. Sejalan dengan kluster sebelumnya, penelitian tentang FSSO yang dilakukan selama masa pandemi covid-19 sangat terkait dengan level *higher education*. Hal ini terlihat dari database bibliometrik yang dianalisis bahwa secara umum, penelitian terdahulu menggunakan mahasiswa dan kampus sebagai subjek penelitiannya. Higher education telah membangun sistem e-learning secara luas sehingga pembelajaran dilakukan melalui sistem tersebut. Dengan begitu, penelitian terkait e-learning telah banyak dilakukan terutama keberhasilan e-learning yang dilakukan pada *higher education* selama masa pandemi covid-19 (Sugandini et al., 2022), faktor yang mempengaruhi e-learning pada masa

pandemi covid-19 (Adzovie & Jibril, 2022), tantangan yang dihadapi mahasiswa dalam mengikuti e-learning selama masa pandemi covid-19, dan sebagainya.

Kata kunci *“academic achievement”* memiliki hubungan langsung dengan *“covid-19”*. Seperti yang kita ketahui bersama bahwa pandemi mengakibatkan pergeseran pelaksanaan pembelajaran yang mulanya tatap muka menjadi online/melalui e-learning. Oleh karena itu, banyak penelitian menyoroti adakah perbedaan *academic achievement* siswa setelah mengikuti e-learning, faktor yang memengaruhi *academic achievement* siswa selama mengikuti e-learning (Park et al., 2022), keterkaitan *academic achievement* terhadap variabel lain yang mempengaruhi kesiapan siswa dalam mengikuti e-learning (Yavuzalp & Bahcivan, 2021), dampak yang potensial dari penutupan sekolah selama pandemi covid-19 terhadap *academic achievement* siswa (Kuhfeld et al., 2020), *motivational factors* yang mempengaruhi *academic success* siswa, dan penelitian yang lainnya. Selain menggunakan istilah *academic achievement*, beberapa peneliti menggunakan padanan yang lain seperti *academic performance* dan *academic success*.



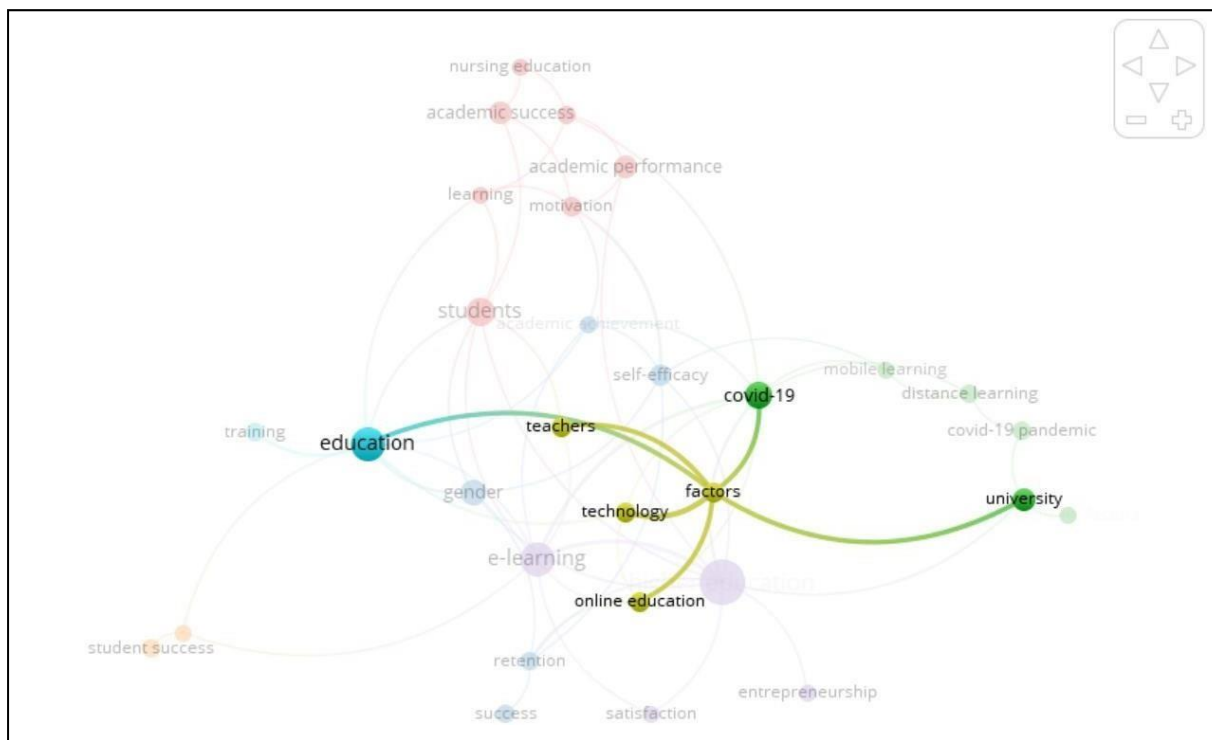
Gambar 23. Topik-topik yang terkait dengan kata kunci *“covid-19”*

Topik-topik terkait kata kunci *“factors”*

Kata kunci terakhir pada *basic themes* yang kami eksplorasi lebih lanjut dalam kaitannya dengan kata-kata kunci lainnya di dalam kluster yang sama atau berbeda yaitu *“factors”*. Gambar 24 secara jelas menunjukkan bahwa kata-kata kunci yang berkaitan dengan kata kunci *“factors”* dapat dikelompokkan menjadi tiga kluster yang ditandai dengan warna kuning (yang terdiri atas kata kunci *“factors”*, *“technology”*, *“teachers”*, dan *“online education”*), hijau (yang terdiri atas kata kunci *“university”* dan *“covid-19”*), dan biru (terdiri hanya kata kunci *“education”*). Adanya keterkaitan antara *“factors”* dengan *“university”* dan *“education”* mengindikasikan bahwa perguruan tinggi atau universitas berkontribusi dalam menentukan keberhasilan belajar mahasiswa melalui kualitas pendidikan yang mereka selenggarakan. Adanya keterkaitan antara kualitas pendidikan yang universitas sediakan untuk mahasiswa mereka yang dibarengi adanya keterkaitan antara *“factors”*

dengan “*teachers*”, “*education*”, dan “*online education*” memperkuat indikasi bahwa keberhasilan belajar mahasiswa dalam pembelajaran jarak jauh sangat tidak terlepas dari pengaruh dari seberapa baik pendidikan yang universitas fasilitasi (Prabowo et al., 2022). Oleh karena itu, universitas perlu menyediakan pengembangan profesional untuk para instruktur, menyelenggarakan pelatihan bagi para pengajar, dan memberikan dukungan teknis terhadap perkembangan konten yang sesuai dengan kebutuhan pengajaran (Kebritchi et al., 2017; Martin, 2021).

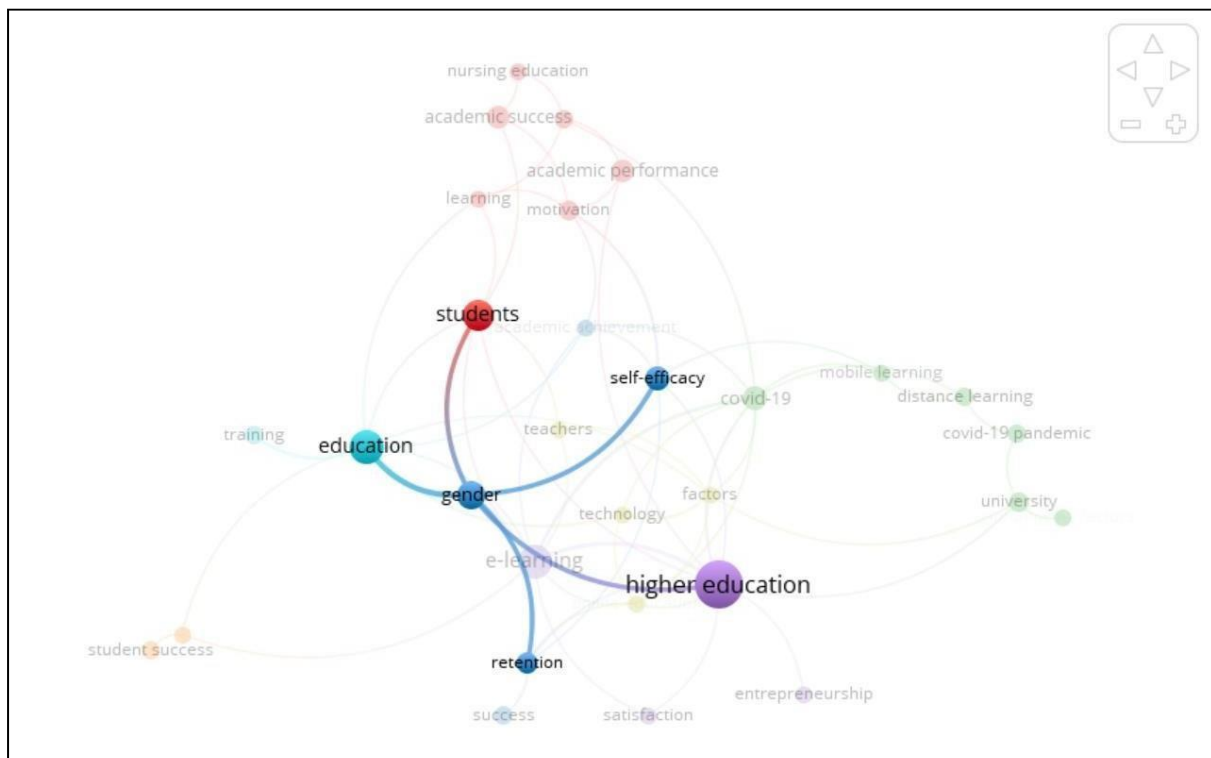
Dalam pendidikan jarak jauh yang kemungkinan besar didukung melalui pembelajaran secara daring, pendidik sebagai fasilitator memiliki tanggung jawab yang krusial dalam memastikan bahwa pembelajaran yang mereka fasilitasi tidak kalah kualitasnya bila dibandingkan pembelajaran secara luring. Tanggung jawab tersebut tidak jauh dari kompetensi yang seharusnya pendidik kuasai, terlebih ketika pendidik dihadapkan dengan lingkungan pembelajaran secara daring yang erat kaitannya dengan penggunaan teknologi, yaitu *technological pedagogical content knowledge* (TPACK). TPACK membawa konsekuensi bahwa dalam penyelenggaraan pendidikan jarak jauh atau pembelajaran secara daring, pendidik perlu menciptakan pembelajaran dengan menerapkan suatu metode, strategi, atau model pembelajaran tertentu yang diintegrasikan dengan penggunaan teknologi yang mendukung mahasiswa untuk dapat mempelajari suatu konten secara konstruktif dan efektif (Kauffman, 2015). Pemilihan dan pengintegrasian teknologi, termasuk LMS yang umumnya digunakan dalam mode pembelajaran jarak jauh atau daring, merupakan hal yang esensial sekaligus menjadi suatu tantangan tersendiri untuk pendidik (terlebih ketika pandemi covid-19) dan pendidikan tinggi yang menyelenggarakan pendidikan jarak jauh. Penelitian oleh Almarashdeh et al. (2018) menyimpulkan bahwa kualitas sistem LMS yang dikembangkan universitas menjadi salah satu efek signifikan yang terkuat terhadap *students’ satisfaction*, yang mana *students’ satisfaction* merupakan salah satu aspek yang mempengaruhi keberhasilan belajar siswa secara online/*distance learning* (York et al., 2015).



Gambar 24. Topik-topik yang terkait dengan kata kunci “*factors*”

Topik-topik terkait kata kunci “gender”

Atribut pertama yang memiliki pengaruh terhadap sejauh mana mahasiswa berhasil dalam belajar mereka, dimana pembelajaran tersebut difasilitasi melalui pendidikan jarak jauh atau pembelajaran secara daring yaitu “gender”. Kata kunci “gender” telah menjadi kata kunci pada kuadran *motor themes* yang mengindikasikan bahwa isu gender ini terus berkembang dan penting untuk dikaji lebih lanjut dalam praktik pendidikan jarak jauh dan pembelajaran secara daring. Gambar 25 menunjukkan keterkaitan antara kata kunci “gender” dengan kata kunci lain yang membentuk empat kluster yang mengindikasikan bahwa isu gender masih benar-benar menjadi topik penting di tengah pendidikan jarak jauh bagi mahasiswa pendidikan tinggi (Cho et al., 2022). Secara lebih spesifik, isu gender ini menyangkut efikasi diri dan retensi. Temuan ini mengindikasikan bahwa adanya perbedaan efikasi-diri – seberapa yakin seorang mahasiswa terhadap pengetahuan dan kompetensi yang dimilikinya untuk dapat berhasil menyelesaikan suatu tugas atau mencapai tujuan tertentu – dan retensi dalam memahami atau mengikuti pembelajaran pada mahasiswa yang mengikuti pendidikan jarak jauh atau pembelajaran daring dipengaruhi oleh adanya perbedaan gender. Mengingat kata kunci “education” berkaitan dengan “gender” dan “gender” berkaitan dengan “self-efficacy” dan “retention”, pendidikan jarak jauh atau pembelajaran daring yang diselenggarakan oleh institusi pendidikan tinggi diharapkan dapat mengakomodasi setiap mahasiswa terlepas dari gender mereka untuk memiliki efikasi-diri dan retensi yang memadai. Ketika dua hal ini dapat terakomodasi, setiap mahasiswa, terlepas dari gender mereka, diharapkan dapat memiliki kesempatan yang lebih besar untuk dapat berhasil dalam pendidikan mereka.



Gambar 25. Topik-topik yang terkait dengan kata kunci “gender”

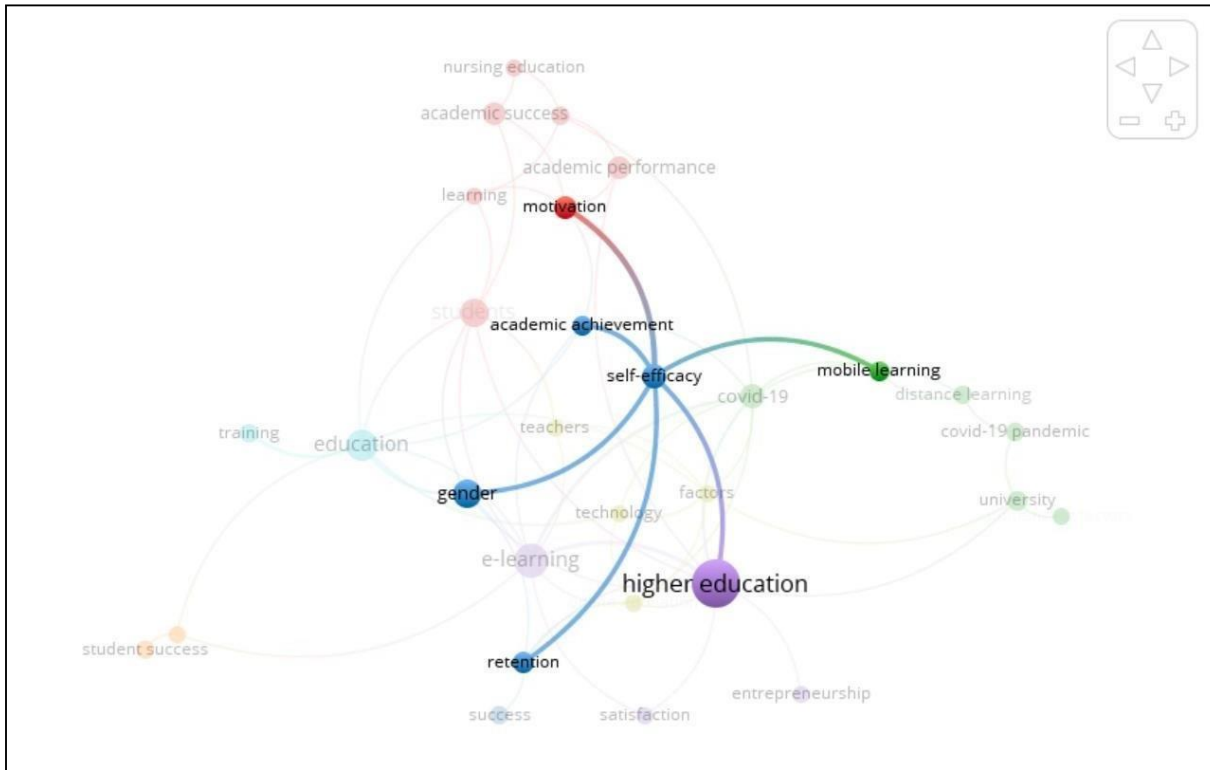
Topik-topik terkait kata kunci “self-efficacy”

Kata kunci terakhir pada kuadran *motor themes* yang menjadi fokus dalam studi ini yaitu “self-efficacy”. Pada Gambar 26, dapat dilihat bahwa *self-efficacy* membentuk keterkaitan dengan kata-kata kunci pada empat kluster; kluster biru meliputi “gender”, “retention”, dan “academic

achievement”, kluster ungu meliputi *“higher education”*, kluster hijau meliputi *“mobile learning”*, dan kluster merah meliputi *“motivation”*. Keterkaitan antara efikasi-diri dengan gender telah dijelaskan pada bagian sebelumnya yang juga menunjukkan bahwa kedua isu ini saling berkaitan satu sama lain. Selanjutnya, meskipun pada bagian sebelumnya (lihat Gambar 25) menunjukkan bahwa efikasi-diri dan retensi tidak terhubung secara langsung, Gambar 26 ternyata menunjukkan bahwa dua hal tersebut saling berkaitan secara langsung, dan hubungan tersebut dieksplorasi oleh sejumlah studi terdahulu. Studi-studi terkait pendidikan jarak jauh atau pembelajaran secara daring juga telah menunjukkan adanya hubungan antara efikasi-diri dan prestasi akademik (Li, 2020; Masrun & Rusdinal, 2022). Hubungan ini menunjukkan bahwa keyakinan mahasiswa terhadap kemampuannya untuk dapat mencapai tujuan tertentu melalui pembelajaran yang dirancang secara online atau pendidikan jarak jauh dapat meningkatkan kesuksesan akademiknya.

Kluster selanjutnya menunjukkan adanya keterkaitan antara *self-efficacy* dengan *mobile learning* (lihat Gambar 26). Keterkaitan antara kedua hal tersebut menunjukkan secara implisit bahwa *self-efficacy* mahasiswa ketika mereka terlibat dalam pendidikan jarak jauh atau pembelajaran secara daring mungkin tidak terlepas dari bagaimana kualitas teknologi yang digunakan dalam pembelajaran. Penggunaan teknologi mobile yang sesuai, berkualitas, dan mudah untuk digunakan mungkin dapat meningkatkan efikasi-diri mahasiswa, terlebih ketika secara umum pendidikan yang disediakan oleh institusi pendidikan tinggi juga mendukung untuk itu. Hal sebaliknya juga dapat berlaku, dimana efikasi-diri dapat menjadi salah satu faktor eksternal yang mempengaruhi penerimaan seseorang terhadap teknologi (Huang, 2023), seperti *internet of things* (IoT) (Alzahrani, 2023), e-learning (Al-Adwan, 2020; Al-Rahmi et al., 2018; Mokhtar et al., 2018; Nguyen et al., 2022; Sholikhah & Sutirman, 2020), and *learning management system* (LMS) (Buabeng-Andoh & Baah, 2020; Fathema et al., 2015).

Dalam studi ini kami juga telah menemukan bahwa studi-studi terdahulu telah mengeksplorasi keterkaitan antara efikasi-diri dan motivasi karena ternyata keduanya ada hubungan (Abdolrezapour et al., 2023). Motivasi yang mahasiswa miliki dapat mendorong mereka untuk memiliki efikasi-diri yang baik, dan sebaliknya efikasi-diri yang baik yang dimiliki oleh mahasiswa dapat mendorong mereka untuk berusaha mencapai suatu keberhasilan dalam belajar secara daring atau dalam pendidikan jarak jauh. Studi terdahulu menunjukkan bahwa motivasi and efikasi-diri merupakan prediktor *students’ satisfaction* dalam mengikuti pembelajaran jarak jauh (Amoozegar et al., 2017; Younas et al., 2022). Hal ini secara implisit menegaskan bahwa untuk meningkatkan kepuasan mahasiswa terhadap pendidikan jarak jauh atau pembelajaran daring yang diselenggarakan oleh institusi pendidikan tinggi, salah satu langkah penting yang perlu mereka lakukan yaitu menyelenggarakan pendidikan atau pembelajaran yang dapat meningkatkan motivasi dan efikasi-dirimahasiswa. Peningkatan motivasi dan efikasi-diri ini lagi-lagi ketika dihubungkan dengan konteks pendidikan jarak jauh atau pembelajaran daring tidak terlepas dari pemilihan teknologi yang sesuai, strategi pembelajaran, dan cara pengorganisasian konten pembelajaran.



Gambar 26. Topik-topik yang terkait dengan kata kunci “self-efficacy”

B. Studi Data Mining

Hasil analisis statistik deskriptif disajikan pada Tabel 3 yang berisikan informasi rata-rata, standar deviasi, dan proporsi mahasiswa berdasarkan data demographics dan academic data. Sejak tahun 2018 sampai dengan 2022, tercatat sebesar 74% mahasiswa berhasil menyelesaikan studinya dan 26% sisanya dinyatakan tidak berhasil dengan rata-rata GPA sebesar 2.95. Mahasiswa ini rata-rata berusia 34 tahun dan sebagian besar berjenis kelamin perempuan. Sebagian besar dari mereka berasal dari wilayah Indonesia bagian barat (79%) dengan status belum menikah (55%) dan berprofesi sebagai guru (69%). Rata-rata upah minimum pekerjaan di daerah mereka bekerja kurang dari Rp 2.000.000.

Table 3. Descriptive Statistic

Category	Feature	Mean (SD) or Proportions
Demographics	Age	34 (8.65)
	Gender	Perempuan: 74% Laki-Laki: 26%
	Marital	Sudah: 45% Belum: 55%
	Employ	Lain-Lain: 4% Guru ASN: 7% Guru Yayasan: 38% Guru Honor: 24% Tidak Diketahui: 1% Bukan Guru: 26%

Category	Feature	Mean (SD) or Proportions
Academic Data	Region	IDN-Barat: 79% IDN-Timur: 2% IDN-Tengah: 19%
	Min_Wage	16692812 (549774)
	GPA	2.95 (0.41)
	Masa Studi	≤ 10 Semester: 74% > 10 Semester: 26%

Untuk mengevaluasi model prediksi, diestimasi terlebih dahulu confusion matriks. Confusion matrix merupakan gambaran situasi terkini dalam dataset dan jumlah prediksi yang benar/salah dari model. Tabel 2 menunjukkan matriks kebingungan tersebut. Kinerja model dihitung berdasarkan jumlah pengamatan yang terklasifikasi dengan benar dan yang terklasifikasi dengan salah. Baris menunjukkan jumlah sebenarnya dari sampel-sampel dalam set pengujian, sedangkan kolom mewakili perkiraan dari model. Pada Tabel 2, true positive (TP) dan true negative (TN) menunjukkan jumlah pengamatan yang terklasifikasi dengan benar. False positive (FP) menunjukkan jumlah pengamatan yang diprediksi sebagai 1 (positif) padahal seharusnya dalam kelas 0 (negatif). False negative (FN) menunjukkan jumlah pengamatan yang diprediksi sebagai 0 (negatif) padahal seharusnya dalam kelas 1 (positif).

Tabel 4. Confusion Matrix of the RF Algorithm

		Predicted		Sum
		Not Success	Success	
Actual	Not Success	10.7%	15.2%	10334
	Success	8.5%	65.6%	29485
	Sum	7642	32177	39819

Tabel 4 menunjukkan matriks kebingungan untuk algoritma RF. Dalam matriks kebingungan dengan dimensi 2 × 2, diagonal utama menunjukkan persentase instansi yang diprediksi dengan benar, dan elemen-elemen matriks selain diagonal utama menunjukkan persentase kesalahan prediksi. Tabel 4 menunjukkan bahwa 65.6% dari mereka yang masa studi sebenarnya kurang dari atau sama dengan 10 semester (sukses) dan 10.7% dari mereka lebih dari 10 semester (tidak sukses) berhasil diprediksi dengan benar.

Tabel 5. Confusion Matrix of the NN Algorithm

		Predicted		Sum
		Not Success	Success	
Actual	Not Success	8.8%	17.1%	10334
	Success	6.8%	67.3%	29485
	Sum	6217	33602	39819

Tabel 5 menunjukkan matriks kebingungan untuk algoritma NN. Berdasarkan Tabel 5 diperoleh informasi bahwa 67.3% dari mereka yang masa studi sebenarnya kurang dari atau sama dengan 10

semester (sukses) dan 8.8% dari mereka lebih dari 10 semester (tidak sukses) berhasil diprediksi dengan benar.

Tabel 6. Confusion Matrix of the LR Algorithm

		Predicted		
		Not Success	Success	Sum
Actual	Not Success	7.8%	18.2%	10334
	Success	5.9%	68.2%	29485
	Sum	5444	34375	39819

Tabel 6 menunjukkan matriks kebingungan untuk algoritma LR. Berdasarkan Tabel 6 diperoleh informasi bahwa 68.2%% dari mereka yang masa studi sebenarnya kurang dari atau sama dengan 10 semester (sukses) dan 7.8% dari mereka lebih dari 10 semester (tidak sukses) berhasil diprediksi dengan benar.

Tabel 7. Confusion Matrix of the NB Algorithm

		Predicted		
		Not Success	Success	Sum
Actual	Not Success	22.2%	3.7%	10334
	Success	32.4%	41.6%	29485
	Sum	21758	18061	39819

Tabel 7 menunjukkan matriks kebingungan untuk algoritma NB. Berdasarkan Tabel 7 diperoleh informasi bahwa 41.6%% dari mereka yang masa studi sebenarnya kurang dari atau sama dengan 10 semester (sukses) dan 22.2% dari mereka lebih dari 10 semester (tidak sukses) berhasil diprediksi dengan benar.

Tabel 8. Confusion Matrix of the kNN Algorithm

		Predicted		
		Not Success	Success	Sum
Actual	Not Success	10.8%	15.2%	10334
	Success	9.2%	64.9%	29485
	Sum	7950	31869	39819

Tabel 8 menunjukkan matriks kebingungan untuk algoritma kNN. Berdasarkan Tabel 8 diperoleh informasi bahwa 64.9% dari mereka yang masa studi sebenarnya kurang dari atau sama dengan 10 semester (sukses) dan 10.8% dari mereka lebih dari 10 semester (tidak sukses) berhasil diprediksi dengan benar.

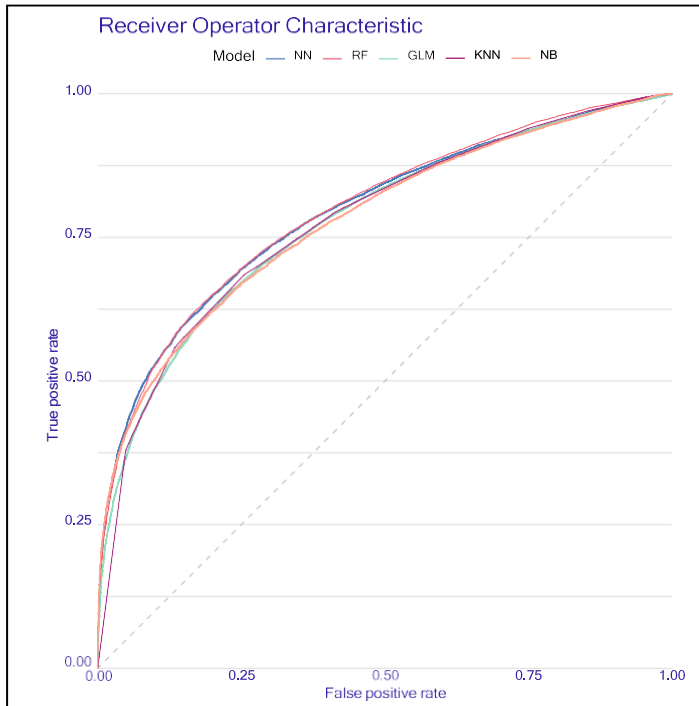
Receiver Operating Characteristics (ROC)

Perbandingan kinerja antara model yang diusulkan berdasarkan metrik AUC, CA, F1, precision, dan recall disajikan pada Tabel 9. Semua model yang diusulkan memiliki akurasi lebih dari 75% atau berada dalam kategori tinggi, kecuali model NB. Hal ini dapat diartikan bahwa terdapat korelasi yang tinggi antara data prediksi dengan data yang sebenarnya pada semua model yang diusulkan (kecuali NB). Secara spesifik, model RF mencapai hasil terbaik dibanding model lainnya jika ditinjau dari metrik precision dengan persentase masing-masing sebesar 76,3% dan 81,1% pada data yang tidak terlihat (test). Hal ini dapat diartikan bahwa model RF memiliki kemampuan memprediksi mahasiswa yang berhasil menyelesaikan studinya secara efektif dengan kesalahan prediksi jenis I (false positive) yang rendah. Disisi lain, model NN mencapai hasil terbaik dibanding model lainnya jika ditinjau dari metrik recall dengan persentase masing-masing sebesar 84,9% dan 90,9% pada data yang tidak terlihat (test). Hal ini dapat diartikan bahwa model NN secara komparatif efektif dalam memprediksi kemungkinan mahasiswa berhasil menyelesaikan studinya dengan kesalahan jenis II (false negative) yang rendah. Secara keseluruhan, model RF dan Nmemiliki nilai yang hampir sama (tidak berbeda secara signifikan) jika ditinjau dari metrik CA, F1, precision, dan recall, sehingga dapat dikatakan kedua model tersebut memiliki kinerja terbaik dalam memprediksi status studi mahasiswa dibanding model lainnya.

Tabel 9. AUC, CA, F1, Precision, and Recall Value of the Model

Model	AUC	CA	F1	Precision	Recall
Random Forest	0.795	0.763	0.847	0.811	0.886
Neural Network	0.793	0.761	0.849	0.797	0.909
Logistic Regression	0.779	0.760	0.850	0.790	0.921
Naïve Bayes	0.780	0.638	0.697	0.918	0.562
kNN	0.778	0.757	0.843	0.809	0.880

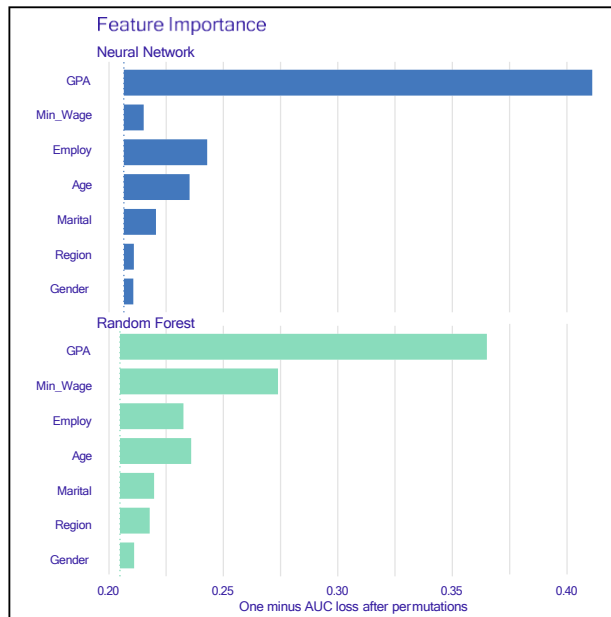
Metrik AUC-ROC digunakan untuk evaluasi lebih lanjut kinerja algoritma pembelajaran ML khususnya pada kasus data tidak seimbang. Tabel 9 menunjukkan bahwa model RF dan NN memiliki nilai AUC yang hampir sama (tidak berbeda secara signifikan) dan tertinggi dibanding model lainnya, dengan persentase masing-masing sebesar 79,5% dan 79,3%. Hasil yang sama juga ditunjukkan pada Gambar 1. Hal ini dapat diartikan bahwa model RF dan NN merupakan model dengan kinerja terbaik berdasarkan metrik AUC dalam memprediksi status studi mahasiswa dibanding model lainnya.



Gambar 1. AUC-ROC

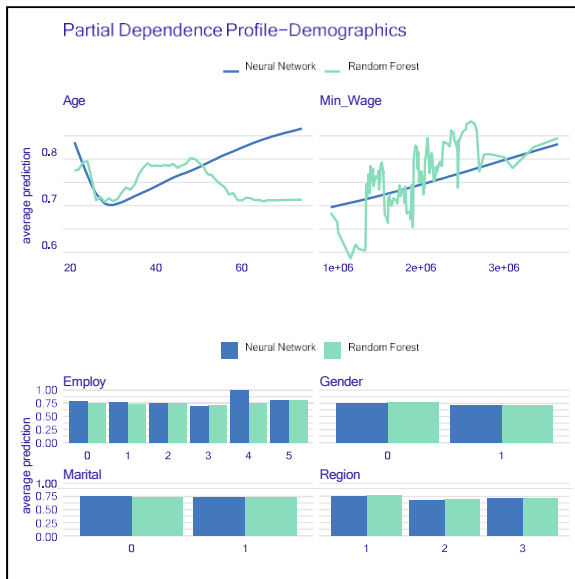
Model Explanation

Untuk menjelaskan model yang penting, dievaluasi dahulu Variable Importance. Variable importance merupakan ukuran sejauh mana variabel tertentu berkontribusi terhadap prediksi variabel dependen. Gambar 2 menunjukkan variable importance pada model terbaik, yakni RF dan NN. Pada model RF, variabel demographics seperti gender, marital status, dan region tampaknya memiliki kontribusi yang tidak begitu besar dalam menjelaskan status studi mahasiswa. Sementara variabel demografi seperti age, employment, dan minimum wage serta academic data seperti GPA tampaknya menjadi variabel terpenting dalam menjelaskan status studi mahasiswa. Keempat variabel tersebut memiliki kontribusi yang lebih besar dibanding tiga variabel lainnya. Pada model NN, variabel demographics seperti gender dan region juga menjadi variabel dengan kontribusi yang tidak begitu besar dalam menjelaskan keberhasilan studi mahasiswa, ditambah dengan variabel minimum wage yang pada model RF justru menjadi variabel terpenting. Variabel demographics seperti age dan employment serta variabel academic data seperti GPA tampaknya konsisten menjadi variabel terpenting pada model NN dalam menjelaskan status studi mahasiswa. Selain variabel tersebut, variabel marital status yang sebelumnya memiliki kontribusi yang tidak begitu besar pada model RF justru menjadi variabel terpenting dalam menjelaskan status studi mahasiswa. Secara keseluruhan, semua variabel prediktor (demographics dan academic data) yang digunakan dalam model RF dan NN memiliki kontribusi (tidak ada variabel dengan nilai RMSE negatif) dengan besaran yang berbeda-beda dalam menjelaskan status studi mahasiswa.



Gambar 2. Variable Importance

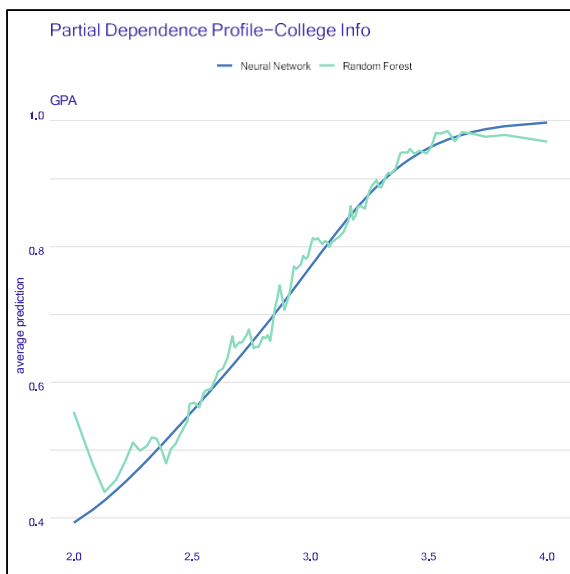
Partial dependence digunakan untuk menghitung ketergantungan prediksi akhir pada variabel tertentu. Ada 2 set variabel yang diperiksa, yakni informasi demographics dan academic data. Informasi demographics ini berkaitan dengan atribut-atribut unik pada mahasiswa seperti gender, age, marital status, employment, region, minimum wage. Plot dependence keenam variabel demographics disajikan pada Gambar 3. Dapat diamati bahwa model RF dan NN memprediksi peluang keberhasilan yang tinggi bagi mahasiswa yang berjenis kelamin perempuan, belum menikah, dan belum memiliki pekerjaan tetap untuk menyelesaikan studinya kurang dari atau sama dengan 10 semester. Selain itu, mahasiswa yang berasal dari region dengan minimum wage lebih Rp 3.000.000 juga menunjukkan peluang keberhasilan yang tinggi untuk menyelesaikan studinya. Namun, model RF dan NN memiliki prediksi yang berbeda dari segi age. Model RF memprediksi peluang keberhasilan yang tinggi bagi mahasiswa yang berusia 30-50 tahun untuk menyelesaikan studinya, sementara mereka yang berusia lebih dari 50 tahun peluangnya lebih rendah. Lain halnya dengan model NN yang memprediksi mahasiswa dengan usia lebih dari 50 tahun justru memiliki peluang yang lebih tinggi untuk menyelesaikan studinya kurang dari atau sama dengan 10 semester.



Gambar 3. Partial Dependence Profile for Demographics Information

C.

Selanjutnya, academic data yang berkaitan dengan nilai akademik mahasiswa sebelumnya (GPA). Plot dependence dari variabel GPA disajikan pada Gambar 4. Dapat diamati bahwa model RF dan NN memprediksi peluang keberhasilan yang tinggi pada mahasiswa yang memiliki GPA lebih dari 3.0 untuk menyelesaikan studinya kurang dari atau sama dengan 10 semester.



Gambar 4. Partial Dependence Profile for Academic Data

D. Pembahasan

Penelitian ini mengusulkan model baru untuk memprediksi status studi mahasiswa DI negara berkembang seperti Indonesia berdasarkan algoritma DM, mengambil data demografi, nilai GPA, dan masa studi mahasiswa sebagai sumber data. Kinerja dari algoritma RF, NN, LR, NB, dan kNN dihitung dan dibandingkan untuk memprediksi status studi mahasiswa. Dalam membandingkan kinerja algoritma, dua parameter digunakan. Parameter pertama, prediksi status studi mahasiswa berdasarkan informasi demographics dan nilai GPA sebelumnya. Parameter yang sama juga dilakukan oleh Yağcı (2022) dalam memprediksi nilai ujian akhir mahasiswa. Parameter kedua, perbandingan indikator kinerja algoritma ML berdasarkan metrik AUC, CA, F1, recall, dan precision. Parameter ini dilakukan khususnya pada dataset yang tidak seimbang (Biecek & Burzykowski, 2021). Selain membandingkan kinerja algoritma ML, penelitian ini juga menghasilkan variabel-variabel penting yang berkontribusi dalam memprediksi status studi mahasiswa.

Hasil penelitian ini menunjukkan bahwa model yang diusulkan mencapai akurasi klasifikasi sebesar 60-76%. RF, NN, LR, dan kNN merupakan algoritma dengan tingkat akurasi klasifikasi yang sangat tinggi yang dapat digunakan untuk memprediksi status studi mahasiswa, sementara NB memiliki akurasi klasifikasi yang rendah. Hasil penelitian ini sejalan dengan hasil penelitian sebelumnya yang menunjukkan bahwa algoritma RF, NN, LR, NB, dan kNN memiliki akurasi klasifikasi yang sangat tinggi dalam memprediksi kinerja akademik dan status studi mahasiswa (Musso et al., 2020; Yağcı, 2022). Hasil yang sama juga ditemukan Alturki et al. (2022) dalam penelitiannya yang menunjukkan bahwa LR, RF, kNN, dan NB memiliki akurasi yang sangat tinggi dalam memprediksi kinerja akademik mahasiswa program doktor. Selain itu, Waheed et al. (2020) juga dalam penelitiannya menemukan kinerja algoritma LR, NN, dan RF dengan akurasi tertinggi dalam mengidentifikasi mahasiswa dengan risiko tinggi gagal akademik berdasarkan karakteristik demografis mereka.

Salah satu temuan penting dari penelitian ini adalah algoritma RF dan NN memiliki akurasi klasifikasi dan AUC tertinggi dibanding tiga algoritma lainnya yang diusulkan (seperti LR, kNN, dan NB). Berdasarkan temuan ini, dapat dikatakan bahwa algoritma RF dan NN memiliki hasil yang lebih akurat dalam memprediksi status studi mahasiswa dengan menggunakan algoritma pembelajaran mesin. Hasil penelitian ini sejalan dengan hasil penelitian sebelumnya yang juga menunjukkan kinerja algoritma RF dan NN sebagai yang terbaik dibanding algoritma LR, kNN, dan NB dalam memprediksi nilai ujian akhir mahasiswa hanya dengan menggunakan tiga atribut academic data (nilai ujian tengah semester, data Jurusan dan data Fakultas), bahkan hasil keduanya sangat mirip (Yağcı, 2022). Sassirekha & Vijayalakshmi (2022) juga menemukan kinerja algoritma RF sebagai yang terbaik dengan akurasi mencapai 90% dalam memprediksi perkembangan kemajuan akademik mahasiswa dibanding algoritma LR, kNN, dan NB. Xu et al. (2019) dalam penelitiannya justru menemukan akurasi tertinggi pada algoritma NN dibanding RF dalam memprediksi kinerja akademik mahasiswa sarjana, dengan selisih akurasi yang tidak jauh berbeda.

Selain menemukan model yang dapat memprediksi status studi mahasiswa secara akurat, hasil penelitian ini juga berhasil mengidentifikasi variabel-variabel yang memberikan peningkatan terbesar dalam kinerja model. Variabel-variabel ini diidentifikasi menggunakan algoritma RF dan NN sebagai model dengan kinerja terbaik. Berdasarkan hasil ini, dapat dikatakan bahwa variabel demographics (gender, age, marital status, employment, region, dan minimum wage) dan academic data (GPA) merupakan prediktor penting yang dapat

digunakan untuk memprediksi status studi mahasiswa. Hasil penelitian ini sejalan dengan hasil penelitian sebelumnya yang menunjukkan bahwa informasi demografis seperti pendapatan, usia, pekerjaan, tempat tinggal (Costa-Mendes et al., 2021; Cruz-Jesus et al., 2020), dan prestasi akademik sebelumnya (Hoffait & Schyns, 2017) merupakan variabel penting yang dapat digunakan untuk memprediksi nilai prestasi akademik dan status studi mahasiswa. Selain itu, hasil penelitian ini juga berhasil mengidentifikasi variabel terpenting dalam memprediksi status studi mahasiswa, yakni capaian akademik sebelumnya (GPA). Hasil ini sejalan dengan temuan Yağcı (2022) dan Hannaford et al. (2021) yang menunjukkan bahwa capaian akademik mahasiswa sebelumnya memiliki kontribusi paling penting dalam memprediksi status studi mahasiswa.

Secara keseluruhan, model RF dan NN sebagai terbaik yang diusulkan dalam penelitian ini mampu memprediksi status studi mahasiswa dengan akurasi 76%. Berdasarkan hasil ini, dapat dikatakan bahwa status studi mahasiswa dapat diprediksi dengan model ini di masa depan. Dengan memprediksi status studi mahasiswa di masa depan, mahasiswa dapat meninjau kembali metode kerja mereka dan meningkatkan kinerja akademiknya (Yağcı, 2022). Hal yang sama juga dilakukan Bernacki et al. (2020) dengan model peringatan dininya yang berhasil mengidentifikasi 75% siswa yang gagal mendapatkan nilai B atau yang lebih baik yang dibutuhkan untuk melanjutkan ke kursus berikutnya secara benar. Burgos et al. (2018), membangun model prediksi menggunakan catatan mahasiswa di PT dan berhasil menurunkan tingkat kegagalan akademik sebesar 14% dari tahun sebelumnya. Selain itu, empat variabel terpenting yang berhasil diidentifikasi dapat bermanfaat bagi pembuat kebijakan dan pemangku kepentingan lainnya untuk mengidentifikasi target intervensi yang tepat dan paling hemat biaya (Wang et al., 2023).

C. Publikasi

Dari penelitian ini, dipublikasikan dua artikel, dengan progsr sebagai berikut.

No.	Judul Artikel	Perkembangan	Nama Jurnal
1.	<i>Factors influencing the Success of students' trough online learning distance education: A bibliometric analysis of Scopus database in the last 10 years</i>	<i>Submitted (International Journal of Interactive Mobile Technologies (IJIM))</i>	Jurnal internasional terindeks Scopus
2.	<i>Predicting Students' Status: Educational data mining in Open University</i>	<i>Submitted (Big Data Mining and Analytics)</i>	Jurnal internasional terindeks Scopus

BAB V

PENUTUP

A. Kesimpulan

1. Studi Bibliometri

Hasil analisis bibliometrik dilakukan terhadap *sources*, *authors*, *documents*, dan kata-kata kunci yang berkaitan dengan faktor yang mempengaruhi keberhasilan belajar siswa dalam mengikuti pembelajaran online/pembelajaran jarak jauh, berikut juga *co-occurrence network* dan *social structure* untuk *author keywords*. *Higher education*, *covid-19*, dan *factors* menjadi tema dasar/*basic themes*, sedangkan *gender* dan *self-efficacy* menjadi *motor themes* yang berpotensi untuk diteliti di masa depan. Hasil analisis bibliometrik dapat memberikan wawasan baru mengenai faktor-faktor yang mempengaruhi kinerja belajar siswa dalam pembelajaran online atau pembelajaran jarak jauh, serta menambah permasalahan menarik yang belum pernah dieksplorasi sebelumnya.

2. Studi Data Mining

Penelitian ini memberikan kontribusi pada perkembangan penelitian saat ini yang fokus memanfaatkan informasi demografi dan nilai IPK yang tercatat dalam database perguruan tinggi untuk memprediksi status studi mahasiswa di negara berkembang seperti Indonesia. Dari sisi metodologi, penelitian ini berkontribusi memberikan tambahan wawasan dalam memprediksi status studi mahasiswa dengan memanfaatkan pendekatan machine learning seperti random forest (RF), neural network (NN), logistic regression (LR), naïve bayes (NB), dan k-nearest neighbour (kNN). Dari sisi hasil, penelitian ini berkontribusi melengkapi literatur sebelumnya yang lebih berfokus pada perbandingan akurasi model machine learning dan kurang menyoroti faktor-faktor kunci berdasarkan informasi demografi dan nilai IPK mahasiswa yang nantinya dapat digunakan sebagai bahan intervensi untuk menangani mahasiswa yang berpotensi gagal menyelesaikan studinya. Hasil penelitian ini menunjukkan bahwa model RF dan NN memiliki akurasi klasifikasi dan nilai AUC tertinggi (CA: 76% dan AUC: 79%) dibanding model lainnya seperti LR, NB, dan kNN dalam memprediksi status studi mahasiswa. Model NB menjadi yang terendah dengan akurasi klasifikasi sebesar 64% dan AUC sebesar 78%. Model RF dan NN berhasil mengidentifikasi satu variabel terpenting dalam memprediksi status studi mahasiswa bersama dengan enam variabel penting lainnya, yakni nilai IPK mahasiswa. Sebagai kesimpulan, model RF dan NN yang diusulkan dalam penelitian ini dapat digunakan untuk memprediksi status studi mahasiswa dengan akurasi tinggi dan variabel terpenting yang berhasil diidentifikasi dapat digunakan para pembuat kebijakan dan pemangku kepentingan lainnya sebagai bahan intervensi untuk menangani mahasiswa yang berpotensi gagal menyelesaikan studinya di masa depan.

B. Rekomendasi

Memperhatikan literature review pada hasil bibliometri, faktor-faktor yang mempengaruhi keberhasilan studi mahasiswa belajar di perguruan tinggi perlu dieksplorasi lebih lanjut. Eksplorasi dapat dilakukan melalui penelitian-penelitian yang relevan. Terkait dengan hasil penelitian tentang prediksi dengan machine learning, ternyata kinerja mahasiswa dalam setiap semesternya sangat mempengaruhi keberhasilan mahasiswa. Hasil ini perlu diimplikasikan pada kebijakan perguruan tinggi untuk mengoptimalkan capaian belajar dan ketepatan kinerja mahasiswa di tiap semester.

DAFTAR PUSTAKA

- APA. (2018). *Socioeconomic status*. <https://www.apa.org/topics/socioeconomic-status>
- Ariani, N. K. D., Sumarjaya, I. W., & Oka, T. B. (2013). Analisis faktor-faktor yang memengaruhi waktu kelulusan mahasiswa dengan menggunakan metode gompit (Studi kasus: Mahasiswa Fakultas MIPA Universitas Udayana). *E-Jurnal Matematika*, 2(3), 40–45. <https://doi.org/10.24843/MTK.2013.v02.i03.p047>
- Barrington, K. (2022). *A quick guide to U.S. public and private school options*. <https://www.publicschoolreview.com/blog/a-quick-guide-to-us-public-and-private-school-options>
- Bofah, A., & Hannula, M. (2017). Home resources as a measure of socio-economic status in Ghana. *Large-scale Assessment in Education*, 5(1), 1–15. <https://doi.org/10.1186/s40536-017-0039-5>
- Carpenter, M. (2016). The human rights of intersex people: addressing harmful practices and rhetoric of change. *Reproductive Health Matters*, 24(47), 74–84. <https://doi.org/10.1016/j.rhm.2016.06.003>
- Cherry, K. (2020). *Theories: Gender schema theory and roles in culture*. <https://www.verywellmind.com/what-is-gender-schema-theory-2795205>
- Choleris, E., Galea, L. A., Sohrabji, F., & Frick, K. M. (2018). Sex differences in the brain: Implications for behavioral and biomedical research. *Neuroscience & Biobehavioral Reviews*, 85(1), 126–145. <https://doi.org/10.1016/j.neubiorev.2017.07.005>
- DeGerolamo, A. (2020). *Key differences between public and private K-12 schools*. <https://www.niche.com/blog/key-differences-between-public-and-private-k-12-schools/>
- Dudley-Marling, C., & Baker, D. (2012). The effects of market-based school reforms on students with disabilities. *Disability Studies Quarterly*, 32(2). <https://doi.org/10.18061/dsq.v32i2.3187>
- Friedman, M. (1995). The role of government in education. In R. A. Solo (Ed.), *Economics and the public interest*. Rutgers University Press.
- Gudono, G. (2011). *Analisis data multivariat* (1st ed.). BPFE Yogyakarta.
- Grossberg, B. (2019). *5 major differences between public and private schools*. <https://www.thoughtco.com/major-differences-between-public-and-private-2773898>
- Hair, J. F., William, C. B., Barry, J. B., & Rolph, E. A. (1998). *Multivariate data analysis* (5th ed.). Prentice-Hall.
- Hoffmann, R. (2008). *Socioeconomic differences in old age mortality*. Springer.
- Johnson, R. A., & Wichern, D. W. (2014). *Applied multivariate statistical analysis*. Pearson Education.
- Jones, T. (2018). Intersex studies: A systematic review of international health literature. *SAGE Open*, 1–22. <https://doi.org/10.1177/2158244017745577>
- Lazarides, R., & Lauermaun, F. (2019). Gendered paths into STEM-related and language-related careers: Girls' and boys' motivational beliefs and career plans in math and

- language arts. *Frontiers in Psychology*, *10*(1243), 1–17.
<https://doi.org/10.3389/feduc.2019.00060>
- Makarove, E., Aeschlimann, B., & Herzog, W. (2019). The gender gap in stem fields: The impact of the gender stereotype of math and science on secondary students' career aspirations. *Frontiers in Education*, *4*(60), 1–11.
<https://doi.org/10.3389/feduc.2019.00060>
- Marthalina, M. (2018). Analisis kualitas pelayanan akademik dan kepuasan mahasiswa di IPDN kampus Jakarta. *Jurnal Manajemen Sumber Daya Manusia*, *5*(1), 1–18.
- Miles, J. (2020). *The importance of sex and gender reporting*.
<https://www.elsevier.com/connect/editors-update/the-importance-of-sex-and-gender-reporting>
- Newman, T. (2018). *Sex and gender: What is the difference?*
<https://www.medicalnewstoday.com/articles/232363>
- Peters, S. A. E., & Norton, R. (2018). Sex and gender reporting in global health: New editorial policies. *BMJ Global Health*, *3*(1), 1–3. <http://dx.doi.org/10.1136/bmjgh-2018-001038>
- Rahmi, I., & Yozza, H. (2020). Analisis kausal masa studi mahasiswa Program Studi Matematika Universitas Andalas dengan menggunakan metode CART. *Jurnal Matematika Sains dan Teknologi*, *21*(1), 22–34.
<https://doi.org/10.33830/jmst.v21i1.697.2020>
- Redjeki, S., Pamungkas, A., & Al-Fatah, H. (2011). Clustering terhadap indeks prestasi mahasiswa STMIK AKAKOM menggunakan K-means. *Prosiding Seminar Nasional Riset Teknologi Informasi* (pp. 41–48). Yogyakarta.
<http://eprints.akakom.ac.id/id/eprint/3579>
- Richardson, J. (1986). *Handbook of theory and research for the sociology*. Greenwood.
- Romadhona, A., Suprapedi, S., & Himawan, H. (2017). Prediksi kelulusan mahasiswa tepat waktu berdasarkan usia, jenis kelamin, dan indeks prestasi menggunakan algoritma decision tree. *Jurnal Teknologi Informasi*, *13*(1), 69–83.
- Samekto, D., Syafrudie, H. A., & Sutrisno, S. (2014). Kecenderungan lama studi dan prestasi belajar mahasiswa jalur reguler dan non-reguler Program Studi Pendidikan Teknik Bangunan. *Teknologi dan Kejuruan: Jurnal Teknologi, Kejuruan dan Pengajarannya*, *37*(2), 153–166. <http://dx.doi.org/10.17977/tk.v37i2.4432>
- United Nations. (2015). *Fact sheet: Intersex*: https://unfe.org/system/unfe-65-Intersex_Factsheet_ENGLISH.pdf
- WHO. (2002). *Integrating gender perspectives in the work of WHO*. WHO.
- Xin, J., Zhang, Y., Tang, Y., & Yang, Y. (2019). Brain differences between men and women: evidence from deep learning. *Frontiers in Neuroscience*, *13*(185), 1–10.
<https://doi.org/10.3389/fnins.2019.00185>
- Alturki, S., Cohausz, L., & Stuckenschmidt, H. (2022). Predicting Master's students' academic performance: An empirical study in Germany. *Smart Learning Environments*, *9*(1), 38.
<https://doi.org/10.1186/s40561-022-00220-y>

- Batool, S., Rashid, J., Nisar, M. W., Kim, J., Kwon, H.-Y., & Hussain, A. (2023). Educational data mining to predict students' academic performance: A survey study. *Education and Information Technologies, 28*(1), 905–971. <https://doi.org/10.1007/s10639-022-11152-y>
- Beaulac, C., & Rosenthal, J. S. (2019). Predicting University Students' Academic Success and Major Using Random Forests. *Research in Higher Education, 60*(7), 1048–1064. <https://doi.org/10.1007/s11162-019-09546-y>
- Bernacki, M. L., Chavez, M. M., & Uesbeck, P. M. (2020). Predicting achievement and providing support before STEM majors begin to fail. *Computers & Education, 158*, 103999. <https://doi.org/10.1016/j.compedu.2020.103999>
- Biecek, P. (2018). DALEX: Explainers for Complex Predictive Models in R. *Journal of Machine Learning Research, 19*.
- Biecek, P., & Burzykowski, T. (2021). *Explanatory model analysis: Explore, explain, and examine predictive models* (1st ed.). CRC Press.
- Boehmke, B., & Greenwell, B. M. (2019). *Hands-on machine learning with R*. CRC Press.
- Burgos, C., Campanario, M. L., Peña, D. D. L., Lara, J. A., Lizcano, D., & Martínez, M. A. (2018). Data mining for modeling students' performance: A tutoring action plan to prevent academic dropout. *Computers & Electrical Engineering, 66*, 541–556. <https://doi.org/10.1016/j.compeleceng.2017.03.005>
- Colak Oz, H., Güven, Ç., & Nápoles, G. (2023). School dropout prediction and feature importance exploration in Malawi using household panel data: Machine learning approach. *Journal of Computational Social Science, 6*(1), 245–287. <https://doi.org/10.1007/s42001-022-00195-3>
- Costa-Mendes, R., Oliveira, T., Castelli, M., & Cruz-Jesus, F. (2021). A machine learning approximation of the 2015 Portuguese high school student grades: A hybrid approach. *Education and Information Technologies, 26*(2), 1527–1547. <https://doi.org/10.1007/s10639-020-10316-y>
- Cruz-Jesus, F., Castelli, M., Oliveira, T., Mendes, R., Nunes, C., Sa-Velho, M., & Rosa-Louro, A. (2020). Using artificial intelligence methods to assess academic achievement in public high schools of a European Union country. *Heliyon, 6*(6), e04081. <https://doi.org/10.1016/j.heliyon.2020.e04081>
- Delen, D. (2010). A comparative analysis of machine learning techniques for student retention management. *Decision Support Systems, 49*(4), 498–506. <https://doi.org/10.1016/j.dss.2010.06.003>
- Fernandes, E., Holanda, M., Victorino, M., Borges, V., Carvalho, R., & Erven, G. V. (2019). Educational data mining: Predictive analysis of academic performance of public school students in the capital of Brazil. *Journal of Business Research, 94*, 335–343. <https://doi.org/10.1016/j.jbusres.2018.02.012>
- Hannaford, L., Cheng, X., & Kunes-Connell, M. (2021). Predicting nursing baccalaureate program graduates using machine learning models: A quantitative research study. *Nurse Education Today, 99*, 104784. <https://doi.org/10.1016/j.nedt.2021.104784>
- Hoffait, A.-S., & Schyns, M. (2017). Early detection of university students with potential difficulties. *Decision Support Systems, 101*, 1–11. <https://doi.org/10.1016/j.dss.2017.05.003>

- Huang, S., & Fang, N. (2013). Predicting student academic performance in an engineering dynamics course: A comparison of four types of predictive mathematical models. *Computers & Education*, *61*, 133–145. <https://doi.org/10.1016/j.compedu.2012.08.015>
- Jeno, L. M., Danielsen, A. G., & Raaheim, A. (2018). A prospective investigation of students' academic achievement and dropout in higher education: A Self-Determination Theory approach. *Educational Psychology*, *38*(9), 1163–1184. <https://doi.org/10.1080/01443410.2018.1502412>
- Kim, S., Choi, E., Jun, Y.-K., & Lee, S. (2023). Student Dropout Prediction for University with High Precision and Recall. *Applied Sciences*, *13*(10), 6275. <https://doi.org/10.3390/app13106275>
- Kuhn, M. (2008). Building Predictive Models in R Using the **caret** Package. *Journal of Statistical Software*, *28*(5). <https://doi.org/10.18637/jss.v028.i05>
- Mohd Khairy, A., Adam, A., & Yaakub, M. R. (2018). Data Analytics in Malaysian Education System: Revealing The Success of Sijil Pelajaran Malaysia From Ujian Aptitud Sekolah Rendah. *Asia-Pacific Journal of Information Technology & Multimedia*, *07*(02), 29–45. <https://doi.org/10.17576/apjitm-2018-0702-03>
- Moore, D. A., Dev, A. S., & Goncharova, E. Y. (2018). Overconfidence Across Cultures. *Collabra: Psychology*, *4*(1), 36. <https://doi.org/10.1525/collabra.153>
- Musso, M. F., Hernández, C. F. R., & Cascallar, E. C. (2020). Predicting key educational outcomes in academic trajectories: A machine-learning approach. *Higher Education*, *80*(5), 875–894. <https://doi.org/10.1007/s10734-020-00520-7>
- Nandeshwar, A., Menzies, T., & Nelson, A. (2011). Learning patterns of university student retention. *Expert Systems with Applications*, *38*(12), 14984–14996. <https://doi.org/10.1016/j.eswa.2011.05.048>
- Rebai, S., Ben Yahia, F., & Essid, H. (2020). A graphically based machine learning approach to predict secondary schools performance in Tunisia. *Socio-Economic Planning Sciences*, *70*, 100724. <https://doi.org/10.1016/j.seps.2019.06.009>
- Roslan, M. H. B., & Chen, C. J. (2023). Predicting students' performance in English and Mathematics using data mining techniques. *Education and Information Technologies*, *28*(2), 1427–1453. <https://doi.org/10.1007/s10639-022-11259-2>
- Rotem, N., Yair, G., & Shustak, E. (2021). Dropping out of master's degrees: Objective predictors and subjective reasons. *Higher Education Research & Development*, *40*(5), 1070–1084. <https://doi.org/10.1080/07294360.2020.1799951>
- Sarra, A., Fontanella, L., & Di Zio, S. (2019). Identifying Students at Risk of Academic Failure Within the Educational Data Mining Framework. *Social Indicators Research*, *146*(1–2), 41–60. <https://doi.org/10.1007/s11205-018-1901-8>
- Sassirekha, M. S., & Vijayalakshmi, S. (2022). Predicting the academic progression in student's standpoint using machine learning. *Automatika*, *63*(4), 605–617. <https://doi.org/10.1080/00051144.2022.2060652>
- Vandamme, J. -P., Meskens, N., & Superby, J. -F. (2007). Predicting Academic Performance by Data Mining Methods. *Education Economics*, *15*(4), 405–419. <https://doi.org/10.1080/09645290701409939>

- Waheed, H., Hassan, S.-U., Aljohani, N. R., Hardman, J., Alelyani, S., & Nawaz, R. (2020). Predicting academic performance of students from VLE big data using deep learning models. *Computers in Human Behavior, 104*, 106189. <https://doi.org/10.1016/j.chb.2019.106189>
- Wang, F., King, R. B., & Leung, S. O. (2023). Why do East Asian students do so well in mathematics? A machine learning study. *International Journal of Science and Mathematics Education, 21*(3), 691–711. <https://doi.org/10.1007/s10763-022-10262-w>
- William Revelle. (2023). *psych: Procedures for Psychological, Psychometric, and Personality Research*. Northwestern University. <https://CRAN.R-project.org/package=psych>
- Xu, X., Wang, J., Peng, H., & Wu, R. (2019). Prediction of academic performance associated with internet usage behaviors using machine learning algorithms. *Computers in Human Behavior, 98*, 166–173. <https://doi.org/10.1016/j.chb.2019.04.015>
- Yağcı, M. (2022). Educational data mining: Prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments, 9*(1), 11. <https://doi.org/10.1186/s40561-022-00192-z>
- APA. (2018). *Socioeconomic status*. <https://www.apa.org/topics/socioeconomic-status>
- Ariani, N. K. D., Sumarjaya, I. W., & Oka, T. B. (2013). Analisis faktor-faktor yang memengaruhi waktu kelulusan mahasiswa dengan menggunakan metode gompit (Studi kasus: Mahasiswa Fakultas MIPA Universitas Udayana). *E-Jurnal Matematika, 2*(3), 40–45. <https://doi.org/10.24843/MTK.2013.v02.i03.p047>
- Barrington, K. (2022). *A quick guide to U.S. public and private school options*. <https://www.publicschoolreview.com/blog/a-quick-guide-to-us-public-and-private-school-options>
- Bofah, A., & Hannula, M. (2017). Home resources as a measure of socio-economic status in Ghana. *Large-scale Assessment in Education, 5*(1), 1–15. <https://doi.org/10.1186/s40536-017-0039-5>
- Carpenter, M. (2016). The human rights of intersex people: addressing harmful practices and rhetoric of change. *Reproductive Health Matters, 24*(47), 74–84. <https://doi.org/10.1016/j.rhm.2016.06.003>
- Cherry, K. (2020). *Theories: Gender schema theory and roles in culture*. <https://www.verywellmind.com/what-is-gender-schema-theory-2795205>
- Choleris, E., Galea, L. A., Sohrabji, F., & Frick, K. M. (2018). Sex differences in the brain: Implications for behavioral and biomedical research. *Neuroscience & Biobehavioral Reviews, 85*(1), 126–145. <https://doi.org/10.1016/j.neubiorev.2017.07.005>
- DeGerolamo, A. (2020). *Key differences between public and private K-12 schools*. <https://www.niche.com/blog/key-differences-between-public-and-private-k-12-schools/>
- Dudley-Marling, C., & Baker, D. (2012). The effects of market-based school reforms on students with disabilities. *Disability Studies Quarterly, 32*(2). <https://doi.org/10.18061/dsq.v32i2.3187>
- Friedman, M. (1995). The role of government in education. In R. A. Solo (Ed.), *Economics and the public interest*. Rutgers University Press.
- Gudono, G. (2011). *Analisis data multivariat* (1st ed.). BPFY Yogyakarta.

- Grossberg, B. (2019). *5 major differences between public and private schools*.
<https://www.thoughtco.com/major-differences-between-public-and-private-2773898>
- Hair, J. F., William, C. B., Barry, J. B., & Rolph, E. A. (1998). *Multivariate data analysis* (5th ed.). Prentice-Hall.
- Hoffmann, R. (2008). *Socioeconomic differences in old age mortality*. Springer.
- Johnson, R. A., & Wichern, D. W. (2014). *Applied multivariate statistical analysis*. Pearson Education.
- Jones, T. (2018). Intersex studies: A systematic review of international health literature. *SAGE Open*, 1–22. <https://doi.org/10.1177/2158244017745577>
- Lazarides, R., & Lauermann, F. (2019). Gendered paths into STEM-related and language-related careers: Girls' and boys' motivational beliefs and career plans in math and language arts. *Frontiers in Psychology*, 10(1243), 1–17.
<https://doi.org/10.3389/feduc.2019.00060>
- Makarove, E., Aeschlimann, B., & Herzog, W. (2019). The gender gap in stem fields: The impact of the gender stereotype of math and science on secondary students' career aspirations. *Frontiers in Education*, 4(60), 1–11.
<https://doi.org/10.3389/feduc.2019.00060>
- Marthalina, M. (2018). Analisis kualitas pelayanan akademik dan kepuasan mahasiswa di IPDN kampus Jakarta. *Jurnal Manajemen Sumber Daya Manusia*, 5(1), 1–18.
- Miles, J. (2020). *The importance of sex and gender reporting*.
<https://www.elsevier.com/connect/editors-update/the-importance-of-sex-and-gender-reporting>
- Newman, T. (2018). *Sex and gender: What is the difference?*
<https://www.medicalnewstoday.com/articles/232363>
- Peters, S. A. E., & Norton, R. (2018). Sex and gender reporting in global health: New editorial policies. *BMJ Global Health*, 3(1), 1–3. <http://dx.doi.org/10.1136/bmjgh-2018-001038>
- Rahmi, I., & Yozza, H. (2020). Analisis kausal masa studi mahasiswa Program Studi Matematika Universitas Andalas dengan menggunakan metode CART. *Jurnal Matematika Sains dan Teknologi*, 21(1), 22–34.
<https://doi.org/10.33830/jmst.v21i1.697.2020>
- Redjeki, S., Pamungkas, A., & Al-Fatah, H. (2011). Clustering terhadap indeks prestasi mahasiswa STMIK AKAKOM menggunakan K-means. *Prosiding Seminar Nasional Riset Teknologi Informasi* (pp. 41–48). Yogyakarta.
<http://eprints.akakom.ac.id/id/eprint/3579>
- Richardson, J. (1986). *Handbook of theory and research for the sociology*. Greenwood.
- Romadhona, A., Suprapedi, S., & Himawan, H. (2017). Prediksi kelulusan mahasiswa tepat waktu berdasarkan usia, jenis kelamin, dan indeks prestasi menggunakan algoritma decision tree. *Jurnal Teknologi Informasi*, 13(1), 69–83.
- Samekto, D., Syafrudie, H. A., & Sutrisno, S. (2014). Kecenderungan lama studi dan prestasi belajar mahasiswa jalur reguler dan non-reguler Program Studi Pendidikan Teknik Bangunan. *Teknologi dan Kejuruan: Jurnal Teknologi, Kejuruan dan Pengajarannya*, 37(2), 153–166. <http://dx.doi.org/10.17977/tk.v37i2.4432>

- United Nations. (2015). *Fact sheet: Intersex*: https://unfe.org/system/unfe-65-Intersex_Factsheet_ENGLISH.pdf
- WHO. (2002). *Integrating gender perspectives in the work of WHO*. WHO.
- Xin, J., Zhang, Y., Tang, Y., & Yang, Y. (2019). Brain differences between men and women: evidence from deep learning. *Frontiers in Neuroscience*, *13*(185), 1–10. <https://doi.org/10.3389/fnins.2019.00185>
- Abdolrezapour, P., Ganjeh, S. J., & Ghanbari, N. (2023). Self-efficacy and resilience as predictors of students' academic motivation in online education. *PLOS ONE*, *18*(5), e0285984. <https://doi.org/10.1371/journal.pone.0285984>
- Adzovie, D. E., & Jibril, A. B. (2022). Assessment of the effects of Covid-19 pandemic on the prospects of e-learning in higher learning institutions: The mediating role of academic innovativeness and technological growth. *Cogent Education*, *9*(1), 2041222. <https://doi.org/10.1080/2331186X.2022.2041222>
- Afkar, R., & Yarrow, N. (2021). *Rewrite the future: How Indonesia's education system can overcome the losses from the COVID-19 pandemic and raise learning outcomes for all* (163674). World Bank. <https://doi.org/10.1596/36327>
- Afshan, G., & Ahmed, A. (2020). Distance learning is here to stay: Shall we reorganize ourselves for the post-covid-19 world? *Anaesthesia, Pain & Intensive Care*, *24*(5). <https://doi.org/10.35975/apic.v24i5.1353>
- Al-Adwan, A. S. (2020). Investigating the drivers and barriers to MOOCs adoption: The perspective of TAM. *Education and Information Technologies*, *25*(6), 5771–5795. <https://doi.org/10.1007/s10639-020-10250-z>
- Al-Fraihat, D., Joy, M., Masa'deh, R., & Sinclair, J. (2020). Evaluating E-learning systems success: An empirical study. *Computers in Human Behavior*, *102*, 67–86. <https://doi.org/10.1016/j.chb.2019.08.004>
- Ally, M. (2004). Foundations of educational theory for online learning. In A. T & E. F, *Theory and practice of online learning* (pp. 3–31). Athabasca University.
- Almaiah, M. A., Al-Khasawneh, A., Althunibat, A., & Almomani, O. (2021). Exploring the main determinants of mobile learning application usage during COVID-19 pandemic in Jordanian universities. In I. Arpaci, M. Al-Emran, M. A. Al-Sharafi, & G. Marques (Eds.), *Emerging Technologies During the Era of COVID-19 Pandemic* (Vol. 348, pp. 275–290). Springer International Publishing. https://doi.org/10.1007/978-3-030-67716-9_17
- Almaiah, M. A., Ayouni, S., Hajjej, F., Lutfi, A., Almomani, O., & Awad, A. B. (2022). Smart mobile learning success model for higher educational institutions in the context of the COVID-19 pandemic. *Electronics*, *11*(8), 1278. <https://doi.org/10.3390/electronics11081278>
- Almarashdeh, I., Alsmadi, M. K., Jaradat, G., Althunibat, A., Albahussain, S. A., Qawqzeh, Y., Badawi, U. A., & Farag, T. (2018). Looking inside and outside the system: Examining the factors influencing distance learners satisfaction in learning management system. *Journal of Computer Science*, *14*(4), 453–465. <https://doi.org/10.3844/jcssp.2018.453.465>
- Al-Rahmi, W. M., Alias, N., Othman, M. S., Alzahrani, A. I., Alfarraj, O., Saged, A. A., & Abdul Rahman, N. S. (2018). Use of E-Learning by university students in Malaysian higher educational institutions: A case in Universiti Teknologi Malaysia. *IEEE Access*, *6*, 14268–14276. <https://doi.org/10.1109/ACCESS.2018.2802325>

- AlRyalat, S. A. S., Malkawi, L. W., & Momani, S. M. (2019). Comparing bibliometric analysis using PubMed, scopus, and web of science databases. *Journal of Visualized Experiments*, 152, 58494. <https://doi.org/10.3791/58494>
- Alsrehan, H. S. (2019). Factors influencing education and E-learning technology in UAE universities as a predictor of community satisfaction. *2019 International Arab Conference on Information Technology (ACIT)*, 150–158. <https://doi.org/10.1109/ACIT47987.2019.8991014>
- Alzahrani, A. (2023). Analysis of the technology acceptance model (TAM) in understanding faculty's behavioral intention to use internet of things (IoT). *IJERI: International Journal of Educational Research and Innovation*, 19, 153–169. <https://doi.org/10.46661/ijeri.7461>
- Amir, L. R., Tanti, I., Maharani, D. A., Wimardhani, Y. S., Julia, V., Sulijaya, B., & Puspitawati, R. (2020). Student perspective of classroom and distance learning during COVID-19 pandemic in the undergraduate dental study program Universitas Indonesia. *BMC Medical Education*, 20(1), 392. <https://doi.org/10.1186/s12909-020-02312-0>
- Amoozegar, A., Daud, S. M., Mahmud, R., & Jalil, H. A. (2017). *Exploring learner to institutional factors and learner characteristics as a success factor in distance learning*. 4(6).
- Andrade, M. S., Miller, R. M., Kunz, M. B., & Ratliff, J. M. (2020). Online learning in schools of business: The impact of quality assurance measures. *Journal of Education for Business*, 95(1), 37–44. <https://doi.org/10.1080/08832323.2019.1596871>
- Aria, M., & Cuccurullo, C. (2017). bibliometrix: An R-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4), 959–975. <https://doi.org/10.1016/j.joi.2017.08.007>
- Arruda, H., Silva, E. R., Lessa, M., Proença Jr., D., & Bartholo, R. (2022). VOSviewer and Bibliometrix. *Journal of the Medical Library Association*, 110(3), 392–395. <https://doi.org/10.5195/jmla.2022.1434>
- Berger, F., Schreiner, C., Hagleitner, W., Jesacher-Rößler, L., Roßnagl, S., & Kraler, C. (2021). Predicting coping with self-regulated distance learning in times of COVID-19: Evidence from a longitudinal study. *Frontiers in Psychology*, 12, 701255. <https://doi.org/10.3389/fpsyg.2021.701255>
- Berger, J. M., & Baker, C. M. (2014). Bibliometrics: An Overview. *Rajiv Gandhi University of Health Sciences Journal of Pharmaceutical Sciences*, 4(3), 81–92. <https://doi.org/10.5530/rjps.2014.3.2>
- Buabeng-Andoh, C., & Baah, C. (2020). Pre-service teachers' intention to use learning management system: An integration of UTAUT and TAM. *Interactive Technology and Smart Education*, 17(4), 455–474. <https://doi.org/10.1108/ITSE-02-2020-0028>
- Bubou, G. M., & Job, G. C. (2022). Individual innovativeness, self-efficacy and e-learning readiness of students of Yenagoa study centre, National Open University of Nigeria. *Journal of Research in Innovative Teaching & Learning*, 15(1), 2–22. <https://doi.org/10.1108/JRIT-12-2019-0079>
- Cho, M.-H., Lim, S., Lim, J., & Kim, O. (2022). Does gender matter in online courses? A view through the lens of the community of inquiry. *Australasian Journal of Educational Technology*, 38(6), 169–184. <https://doi.org/10.14742/ajet.7194>
- Choudhri, A. F., Siddiqui, A., Khan, N. R., & Cohen, H. L. (2015). Understanding bibliometric parameters and analysis. *RadioGraphics*, 35(3), 736–746. <https://doi.org/10.1148/rg.2015140036>
- Churiyah, M., Sholikhah, S., Filianti, F., & Sakdiyyah, D. A. (2020). Indonesia education readiness conducting distance learning in COVID-19 pandemic situation. *International Journal of Multicultural and Multireligious Understanding*, 7(6), 491. <https://doi.org/10.18415/ijmmu.v7i6.1833>

- Culajara, C. J., Culajara, J. P. M., Portos, O., & Villapando, M. K. (2022). Bridging instructional gaps through recognizing the factors and students' experiences in distance learning. *International Journal of Theory and Application in Elementary and Secondary School Education*, 4(2), 152–167. <https://doi.org/10.31098/ijtaese.v4i2.1025>
- Ellegaard, O. (2018). The application of bibliometric analysis: Disciplinary and user aspects. *Scientometrics*, 116(1), 181–202. <https://doi.org/10.1007/s11192-018-2765-z>
- Fathema, N., Shannon, D., & Ross, M. (2015). Expanding the technology acceptance model (TAM) to examine faculty use of learning management systems (LMSs) In higher education institutions. *MERLOT Journal of Online Learning and Teaching*, 11(2), 210–232.
- Ferdousi, B. (2016). *Addressing student retention and persistence issue in online classes*. ASEE North Central Section Conference, Central Michigan University. https://asee-ncs.org/wp-content/uploads/2021/12/proceedings/2016/faculty_regular_papers/2016_ASEE_NCS_paper_49.pdf
- Gharaibeh, M. K., & Gharaibeh, N. K. (2020). An empirical study on factors influencing the intention to use mobile learning. *Advances in Science, Technology and Engineering Systems Journal*, 5(5), 1261–1265. <https://doi.org/10.25046/aj0505151>
- Giannakos, M., Papamitsiou, Z., Markopoulos, P., Read, J., & Hourcade, J. P. (2020). Mapping child–computer interaction research through co-word analysis. *International Journal of Child-Computer Interaction*, 23–24, 100165. <https://doi.org/10.1016/j.ijcci.2020.100165>
- Hamann, K., Glazier, R. A., Wilson, B. M., & Pollock, P. H. (2021). Online teaching, student success, and retention in political science courses. *European Political Science*, 20(3), 427–439. <https://doi.org/10.1057/s41304-020-00282-x>
- Heimerl, F., Lohmann, S., Lange, S., & Ertl, T. (2014). Word cloud explorer: Text analytics based on word clouds. *2014 47th Hawaii International Conference on System Sciences*, 1833–1842. <https://doi.org/10.1109/HICSS.2014.231>
- Huang, T. (2023). Factors affecting students' online courses learning behaviors. *Education and Information Technologies*. <https://doi.org/10.1007/s10639-023-11882-7>
- Julius, R., Abd Halim, M. S., Abdul Hadi, N., Alias, A. N., Mohd Khalid, M. H., Mahfodz, Z., & Ramli, F. F. (2021). Bibliometric analysis of research in mathematics education using scopus database. *Eurasia Journal of Mathematics, Science and Technology Education*, 17(12), 1–12. <https://doi.org/10.29333/ejmste/11329>
- Kauffman, H. (2015). A review of predictive factors of student success in and satisfaction with online learning. *Research in Learning Technology*, 23. <https://doi.org/10.3402/rlt.v23.26507>
- Kebritchi, M., Lipschuetz, A., & Santiago, L. (2017). Issues and challenges for teaching successful online courses in higher education: A literature review. *Journal of Educational Technology Systems*, 46(1), 4–29. <https://doi.org/10.1177/0047239516661713>
- Kuhfeld, M., Soland, J., Tarasawa, B., Johnson, A., Ruzek, E., & Liu, J. (2020). Projecting the potential impact of COVID-19 school closures on academic achievement. *Educational Researcher*, 49(8), 549–565. <https://doi.org/10.3102/0013189X20965918>
- Kumar, J. A., Osman, S., Sanmugam, M., & Rasappan, R. (2022). Mobile learning acceptance post pandemic: A behavioural shift among engineering undergraduates. *Sustainability*, 14(6), 3197. <https://doi.org/10.3390/su14063197>

- Leung, X. Y., Sun, J., & Bai, B. (2017). Bibliometrics of social media research: A co-citation and co-word analysis. *International Journal of Hospitality Management*, 66, 35–45. <https://doi.org/10.1016/j.ijhm.2017.06.012>
- Li, D. (2020). A review of self-efficacy of learners through online learning. *Journal of Humanities and Education Development*, 2(6), 526–533. <https://doi.org/10.22161/jhed.2.6.17>
- Lohmann, S., Heimerl, F., Bopp, F., Burch, M., & Ertl, T. (2015). Concentri cloud: Word cloud visualization for multiple text documents. *2015 19th International Conference on Information Visualisation*, 114–120. <https://doi.org/10.1109/iv.2015.30>
- Martin, A. M. (2021). Instructor qualities and student success in higher education online courses. *Journal of Digital Learning in Teacher Education*, 37(1), 65–80. <https://doi.org/10.1080/21532974.2020.1815106>
- Masha'al, D., Rababa, M., & Shahrour, G. (2020). Distance learning–related stress among undergraduate nursing students during the COVID-19 pandemic. *Journal of Nursing Education*, 59(12), 666–674. <https://doi.org/10.3928/01484834-20201118-03>
- Masrun, M., & Rusdinal, R. (2022). Self-efficacy, learning motivation, learning environment and its effect on online learning outcomes. *Jurnal Kependidikan Penelitian Inovasi Pembelajaran*, 6(2), 143–151. <https://doi.org/10.21831/jk.v6i2.49445>
- Merigó, J. M., & Yang, J.-B. (2017). A bibliometric analysis of operations research and management science. *Omega*, 73, 37–48. <https://doi.org/10.1016/j.omega.2016.12.004>
- Mokhtar, S. A., Katan, H., & Hidayat-ur-Rehman, I. (2018). Instructors' behavioural intention to use learning management system: An integrated TAM perspective. *TEM Journal*, 7(3), 513–525. <https://doi.org/10.18421/TEM73-07>
- Moral-Muñoz, J. A., Herrera-Viedma, E., Santisteban-Espejo, A., & Cobo, M. J. (2020). Software tools for conducting bibliometric analysis in science: An up-to-date review. *El Profesional de La Información*, 29(1). <https://doi.org/10.3145/epi.2020.ene.03>
- Nguyen, V. K. L., Le, T. M. H., Duong, T. N. M., Nguyen, T. S., Le, T. T. H., & Nguyen, T. T. H. (2022). Assessing student's adoption of E-Learning: An integration of TAM and TPB framework. *Journal of Information Technology Education: Research*, 21, 297–335. <https://doi.org/10.28945/5000>
- Oliveira, S. M., & Greenidge, N. (2020). Information seeking behavior of distance learners: What has changed in twenty years? *Journal of Library & Information Services in Distance Learning*, 14(1), 2–27. <https://doi.org/10.1080/1533290X.2020.1791301>
- Oluwadele, D., Singh, Y., & Adeliyi, T. T. (2023). E-learning performance evaluation in medical education—A bibliometric and visualization analysis. *Healthcare*, 11(2), 232. <https://doi.org/10.3390/healthcare11020232>
- Pacheco, A. Q. (2009). Issues for effective distance learning: A challenge in online education. *Revista de Lenguas Modernas*, 11, 345–362.
- Park, K., Moon, S., & Oh, J. (2022). Predictors of academic achievement in distance learning for nursing students. *Nurse Education Today*, 108, 105162. <https://doi.org/10.1016/j.nedt.2021.105162>
- Perkowski, J. (2013). The role of gender in distance learning: A meta-analytic review of gender differences in academic performance and self-efficacy in distance learning. *Journal of Educational Technology Systems*, 41(3), 267–278. <https://doi.org/10.2190/ET.41.3.e>

- Prabowo, H., Ikhsan, R. B., & Yuniarty, Y. (2022). Student performance in online learning higher education: A preliminary research. *Frontiers in Education*, 7, 916721. <https://doi.org/10.3389/educ.2022.916721>
- Rizun, M., & Strzelecki, A. (2020). Students' acceptance of the COVID-19 impact on shifting higher education to distance learning in Poland. *International Journal of Environmental Research and Public Health*, 17(18), 6468. <https://doi.org/10.3390/ijerph17186468>
- Salas-Pilco, S. Z., Yang, Y., & Zhang, Z. (2022). Student engagement in online learning in Latin American higher education during the COVID-19 pandemic: A systematic review. *British Journal of Educational Technology*, 53(3), 593–619. <https://doi.org/10.1111/bjet.13190>
- Sayaf, A. M., Alamri, M. M., Alqahtani, M. A., & Alrahmi, W. M. (2022). Factors influencing university students' adoption of digital learning technology in teaching and learning. *Sustainability*, 14(1), 493. <https://doi.org/10.3390/su14010493>
- Schmitt, J. (2015). *Can't disrupt this: Elsevier and the 25.2 billion dollar a year academic publishing business*. <https://medium.com/@jasonschmitt/can-t-disrupt-this-elsevier-and-the-25-2-billion-dollar-a-year-academic-publishing-business-aa3b9618d40a#wj6o9bzas>
- Setyowati, L. (2020). Pengenalan bibliometric mapping sebagai bentuk pengembangan layanan research support services perguruan tinggi. *JPUA: Jurnal Perpustakaan Universitas Airlangga: Media Informasi dan Komunikasi Kepustakawanan*, 10(1), 1. <https://doi.org/10.20473/jpua.v10i1.2020.1-9>
- Shaikh, U. U., & Asif, Z. (2022). Persistence and dropout in higher online education: Review and categorization of factors. *Frontiers in Psychology*, 13, 902070. <https://doi.org/10.3389/fpsyg.2022.902070>
- Shi, G., Li, J., & Yang, J. (2023). A study on the influencing factors of university students' online persistent learning supported by intelligent technology in the post-pandemic era: An empirical study with PLS-SEM. *Interactive Learning Environments*, 1–23. <https://doi.org/10.1080/10494820.2023.2205901>
- Sholikah, M., & Sutirman, S. (2020). How technology acceptance model (TAM) factors of electronic learning influence education service quality through students' satisfaction. *TEM Journal*, 9(3), 1221–1226. <https://doi.org/10.18421/TEM93-50>
- Sugandini, D., Garaika, & Istanto, Y. (2022). E-Learning system success adoption in Indonesia higher education. *Academic Journal of Interdisciplinary Studies*, 11(1), 149. <https://doi.org/10.36941/ajis-2022-0013>
- Tello, S. F. (2007). An analysis of student persistence in online education. *International Journal of Information and Communication Technology Education*, 3(3), 47–62.
- Timotheou, S., Miliou, O., Dimitriadis, Y., Sobrino, S. V., Giannoutsou, N., Cachia, R., Monés, A. M., & Ioannou, A. (2023). Impacts of digital technologies on education and factors influencing schools' digital capacity and transformation: A literature review. *Education and Information Technologies*, 28(6), 6695–6726. <https://doi.org/10.1007/s10639-022-11431-8>
- van Eck, N. J., & Waltman, L. (2010). Software survey: VOSviewer, a computer program for bibliometric mapping. *Scientometrics*, 84(2), 523–538. <https://doi.org/10.1007/s11192-009-0146-3>
- Voicu, M.-C., & Muntean, M. (2023). Factors that influence mobile learning among university students in Romania. *Electronics*, 12(4), 938. <https://doi.org/10.3390/electronics12040938>

Yavuzalp, N., & Bahcivan, E. (2021). A structural equation modeling analysis of relationships among university students' readiness for e-learning, self-regulation skills, satisfaction, and academic achievement. *Research and Practice in Technology Enhanced Learning*, 16(1), 15. <https://doi.org/10.1186/s41039-021-00162-y>

Yawson, D. E., & Yamoah, F. A. (2020). Understanding satisfaction essentials of E-learning in higher education: A multi-generational cohort perspective. *Heliyon*, 6(11), e05519. <https://doi.org/10.1016/j.heliyon.2020.e05519>

York, T. T., Gibson, C., & Rankin, S. (2015). Defining and measuring academic success. *Practical Assessment, Research & Evaluation*, 20(5), 1–20.

Younas, M., Noor, U., Zhou, X., Menhas, R., & Qingyu, X. (2022). COVID-19, students' satisfaction about e-learning and academic achievement: Mediating analysis of online influencing factors. *Frontiers in Psychology*, 13, 948061. <https://doi.org/10.3389/fpsyg.2022.948061>

Yu, Z. (2021). The effects of gender, educational level, and personality on online learning outcomes during the COVID-19 pandemic. *International Journal of Educational Technology in Higher Education*, 18(1), 14. <https://doi.org/10.1186/s41239-021-00252-3>

LAMPIRAN-LAMPIRAN

1. Data

Contoh Masukan data

NO	NAMA MA	UMUR	PROVINSI	UMP	KODE JENI	KODE STA	KODE STA	MRA	MRI	MASA STU	KODE PRO	KODE STA	IPK DP	SKS DP	STATUS KE	KODE UPB	NAMA UPBJJ
1			47	PAPUA BA	1870000	0	0	5	20141	20211	15	50 DL	2,32	144	Alumni	10	UPBJJ-UT SORONG
2			46	PAPUA BA	1870000	0	0	1	20141	20162	6	73 DL	3,09	148	Alumni	10	UPBJJ-UT SORONG
3			55	ACEH	1750000	0	1	1	20141	20152	4	57 DL	2,3	146	Alumni	11	UPBJJ-UT BANDA ACEH
4			46	ACEH	1750000	1	0	4	20141	20162	6	110 DL	2,58	145	Alumni	11	UPBJJ-UT BANDA ACEH
5			39	ACEH	1750000	0	0	1	20141	20172	8	110 DL	2	145	Alumni	11	UPBJJ-UT BANDA ACEH
6			53	ACEH	1750000	0	0	2	20141	20192	12	120 DL	2,31	145	Alumni	11	UPBJJ-UT BANDA ACEH
7			44	ACEH	1750000	1	1	5	20141	20211	15	71 DL	2,35	148	Alumni	11	UPBJJ-UT BANDA ACEH
8			47	ACEH	1750000	1	0	2	20141	20202	14	83 DL	2,59	144	Alumni	11	UPBJJ-UT BANDA ACEH
9			36	ACEH	1750000	0	0	4	20141	20171	7	120 DL	2,62	143	Alumni	11	UPBJJ-UT BANDA ACEH
10			35	ACEH	1750000	0	0	4	20141	20162	6	110 DL	2,02	145	Alumni	11	UPBJJ-UT BANDA ACEH
11			37	ACEH	1750000	0	0	3	20141	20212	16	110 DL	2,88	145	Alumni	11	UPBJJ-UT BANDA ACEH
12			59	ACEH	1750000	0	0	2	20141	20182	10	120 DL	2,4	145	Alumni	11	UPBJJ-UT BANDA ACEH
13			49	ACEH	1750000	0	0	3	20141	20181	9	120 DL	2,37	145	Alumni	11	UPBJJ-UT BANDA ACEH
14			38	ACEH	1750000	1	0	4	20141	20162	6	110 DL	2,74	145	Alumni	11	UPBJJ-UT BANDA ACEH
15			39	ACEH	1750000	0	0	3	20141	20181	9	115 DL	2,47	145	Alumni	11	UPBJJ-UT BANDA ACEH
16			42	ACEH	1750000	1	1	5	20141	20161	5	38 DL	2,63	145	Alumni	11	UPBJJ-UT BANDA ACEH
17			40	ACEH	1750000	1	0	1	20141	20201	13	115 DL	2,29	145	Alumni	11	UPBJJ-UT BANDA ACEH
18			38	ACEH	1750000	1	0	1	20141	20221	17	110 DL	2,71	145	Alumni	11	UPBJJ-UT BANDA ACEH
19			46	ACEH	1750000	1	0	2	20141	20191	11	311 DL	2,17	145	Alumni	11	UPBJJ-UT BANDA ACEH
20			51	ACEH	1750000	1	1	2	20141	20211	15	71 DL	2,29	145	Alumni	11	UPBJJ-UT BANDA ACEH
21			41	ACEH	1750000	0	0	4	20141	20152	4	120 DL	2,61	143	Alumni	11	UPBJJ-UT BANDA ACEH
22			37	ACEH	1750000	0	0	3	20141	20181	9	115 DL	2,2	145	Alumni	11	UPBJJ-UT BANDA ACEH
23			43	ACEH	1750000	0	0	3	20141	20201	13	115 DL	2,23	145	Alumni	11	UPBJJ-UT BANDA ACEH
24			37	ACEH	1750000	0	0	4	20141	20172	8	115 DL	2,36	145	Alumni	11	UPBJJ-UT BANDA ACEH
25			56	ACEH	1750000	0	0	3	20141	20171	7	120 DL	2,44	145	Alumni	11	UPBJJ-UT BANDA ACEH
26			38	ACEH	1750000	0	0	3	20141	20192	12	115 DL	2,06	145	Alumni	11	UPBJJ-UT BANDA ACEH

2. Contoh Sintaks Analisis dengan R

```

library(dplyr)
library(caret)
library(psych)
library(DALEX)
library(shapper)
library(patchwork)
#Panggil Data
data <- read.csv("Data UT cleaned - rev.csv", sep = ";")
#Bersihkan Data Masa Studi < 7 Semeseter
data_ok <- filter(data, data[,11] > 7)

#Bersihkan Data MRI
table(data_ok$MRI)
mri <- c('20172', '20196', '20222')
data_ok <- filter(data_ok, !(data_ok[,10] %in% mri))
is.numeric(data_ok$IPK)
data_ok$IPK <- as.numeric(gsub(",", ".", data_ok$IPK.DP))

#Tambahkan Variabel Status
data_ok$STATUS <- factor(ifelse(data_ok[,11] <= 10, 1, 0))

#Pembagian Provinsi Asal
#Indonesia Barat
ind_barat <- c('ACEH', 'SUMATERA UTARA', 'SUMATERA BARAT', 'RIAU',
'KEPULAUAN RIAU',

```

```

'BANGKA BELITUNG', 'JAMBI', 'BENGKULU', 'SUMATERA SELATAN',
'LAMPUNG',
'BANTEN', 'DKI JAKARTA', 'JAWA BARAT', 'JAWA TENGAH', 'DAERAH
ISTIMEWA YOGYAKARTA',
'JAWA TIMUR', 'KALIMANTAN BARAT', 'KALIMANTAN TENGAH')

#Indonesia Timur
ind_timur <- c('MALUKU', 'MALUKU UTARA', 'PAPUA', 'PAPUA BARAT DAYA')

#Indonesia Tengah
ind_tengah <- c('KALIMANTAN TIMUR', 'KALIMANTAN SELATAN', 'KALIMANTAN
UTARA', 'GORONTALO',
'SULAWESI BARAT', 'SULAWESI SELATAN', 'SULAWESI TENGAH',
'SULAWESI TENGGARA',
'SULAWESI UTARA', 'BALI', 'NUSA TENGGARA BARAT', 'NUSA
TENGGARA TIMUR')

data_ok$DAERAH_ASAL <- factor(ifelse(data_ok[,4] %in% ind_barat, 1,
ifelse(data_ok[,4] %in% ind_timur, 2,
ifelse(data_ok[,4] %in% ind_tengah, 3,
NA))))

#Memilih Variabel yang Dianalisis
data_ok <- data_ok[,c(3,5:8,19, 21, 20)]

#Mengubah Nama Kolom/Variabel
colnames(data_ok) <- c('Age', 'Min_Wage', 'Gender', 'Marital',
'Employ', 'GPA', 'Region', 'Status')

#Menset Variabel Data Ketagori Sebagai Faktor
data_ok$Employ <- factor(data_ok$Employ)
data_ok$Region <- factor(data_ok$Region)
data_ok$Gender <- factor(data_ok$Gender)
data_ok$Status <- factor(data_ok$Status)
data_ok$Marital <- factor(data_ok$Marital)

#Statistik Deskriptif
psych::describe(data_ok)
table.jk <- table(data_ok$JK)
round(prop.table(table.jk)*100,0)

table.sk <- table(data_ok$SK)
round(prop.table(table.sk)*100,0)

table.sg <- table(data_ok$SG)
round(prop.table(table.sg)*100,0)

table.daerah <- table(data_ok$DAERAH)
round(prop.table(table.daerah)*100,0)

```

```

table.status <- table(data_ok$STATUS)
round(prop.table(table.status)*100,0)

#Membuat Partisi Data Menjadi 70% Train dan 30% Test
set.seed(123)
indeks <- createDataPartition(data_ok[,8], p = 0.7, list = F)
train <- data_ok[indeks,]
test <- data_ok[-indeks,]

#Analisis dengan Machine Learning (ML)
#Membuat Cross-Validation 10-Fold dengan Pengulangan 3X
control <- trainControl(method="repeatedcv", number = 10,
                        repeats = 3, savePredictions=TRUE)

#Mendefinisikan Model ML
mod_glm <- train(Status ~ ., data = train,
                method = 'glm',
                preProc=c("center", "scale"),
                family = "binomial",
                metric="Accuracy",
                trControl = control)

mod_rf <- train(Status ~ ., data = train,
               method = 'rf',
               preProc=c("center", "scale"),
               metric="Accuracy",
               trControl = control)

mod_nb <- train(Status ~ ., data = train,
               method='nb',
               preProc=c("center", "scale"),
               metric="Accuracy",
               trControl = control)

mod_knn <- train(Status ~ ., data = train,
               method='knn',
               preProc=c("center", "scale"),
               metric="Accuracy",
               trControl = control)

mod_nnet <- train(Status ~ ., data = train,
                method='nnet',
                preProc=c("center", "scale"),
                metric="Accuracy",
                trControl = control)

results <- resamples(list(GLM = mod_glm, NN = mod_nnet,
                        KNN = mod_knn, RF = mod_rf, NB = mod_nb))

```

```

#Menampilkan Confusion-Matrix Model GLM
predic_glm <- predict(mod_glm, newdata=test)
t(confusionMatrix(predic_glm, test$STATUS)$table)
t(round(prop.table(confusionMatrix(predic_glm, test$STATUS)$table)*100,1))

#Menampilkan Confusion-Matrix Model RF
predic_rf <- predict(mod_rf, newdata=test)
t(confusionMatrix(predic_rf, test$STATUS)$table)
t(round(prop.table(confusionMatrix(predic_rf, test$STATUS)$table)*100,1))

#Menampilkan Confusion-Matrix Model NB
predic_nb <- predict(mod_nb, newdata=test)
t(confusionMatrix(predic_nb, test$STATUS)$table)
t(round(prop.table(confusionMatrix(predic_nb, test$STATUS)$table)*100,1))

#Menampilkan Confusion-Matrix Model KNN
predic_knn <- predict(mod_knn, newdata=test)
t(confusionMatrix(predic_knn, test$STATUS)$table)
t(round(prop.table(confusionMatrix(predic_knn, test$STATUS)$table)*100,1))

#Menampilkan Confusion-Matrix Model NN
predic_nnet <- predict(mod_nnet, newdata=test)
t(confusionMatrix(predic_nnet, test$STATUS)$table)
t(round(prop.table(confusionMatrix(predic_nnet, test$STATUS)$table)*100,1))

#Membuat Fungsi Prediksi
p_fun <- function(object, newdata){
  predict(object, newdata = newdata, type="prob")[,2]
}

#Mengkonversi Variabel Dependen sebagai numeric binary vector
yTest <- as.numeric(as.character(test$Status))

#Membuat Objek Explainer setiap Model ML
explainer_glm <- explain(mod_glm, label = "GLM",
  data = test, y = yTest,
  predict_function = p_fun,
  verbose = FALSE)

explainer_rf <- explain(mod_rf, label = "Random Forest",
  data = test[,-8], y = yTest,
  predict_function = p_fun,
  verbose = FALSE)

explainer_nb <- explain(mod_nb, label = "NB",
  data = test, y = yTest,
  predict_function = p_fun,

```

```

        verbose = FALSE)

explainer_knn <- explain(mod_knn, label = "KNN",
                        data = test, y = yTest,
                        predict_function = p_fun,
                        verbose = FALSE)

explainer_nnet <- explain(mod_nnet, label = "Neural Network",
                        data = test[,-8], y = yTest,
                        predict_function = p_fun,
                        verbose = FALSE)

# Calculate model performance and residuals
#Menghitung Kinerja dan Residual setiap Model ML
mp_glm <- model_performance(explainer_glm)
mp_rf <- model_performance(explainer_rf)
mp_nb <- model_performance(explainer_nb)
mp_knn <- model_performance(explainer_knn)
mp_nnet <- model_performance(explainer_nnet)

#Membuat Tabel Evaluasi Model
eval_rf <- round(cbind(mp_rf[[2]][[5]], mp_rf[[2]][[4]], mp_rf[[2]][[3]],
                      mp_rf[[2]][[2]], mp_rf[[2]][[1]]),3)
eval_nnet <- round(cbind(mp_nnet[[2]][[5]], mp_nnet[[2]][[4]], mp_nnet[[2]][[3]],
                      mp_nnet[[2]][[2]], mp_nnet[[2]][[1]]),3)
eval_glm <- round(cbind(mp_glm[[2]][[5]], mp_glm[[2]][[4]], mp_glm[[2]][[3]],
                      mp_glm[[2]][[2]], mp_glm[[2]][[1]]),3)
eval_nb <- round(cbind(mp_nb[[2]][[5]], mp_nb[[2]][[4]], mp_nb[[2]][[3]],
                      mp_nb[[2]][[2]], mp_nb[[2]][[1]]),3)
eval_knn <- round(cbind(mp_knn[[2]][[5]], mp_knn[[2]][[4]], mp_knn[[2]][[3]],
                      mp_knn[[2]][[2]], mp_knn[[2]][[1]]),3)

nama_mod <- c('Random Forest', 'Neural Network',
             'Logistic Regression', 'Naïve Bayes',
             'kNN')

nama_eval <- c('AUC', 'CA', 'F1', 'Precision', 'Recall')

eval_gab <- rbind(eval_rf, eval_nnet, eval_glm, eval_nb, eval_knn)

eval_gab <- cbind(Model = nama_mod, eval_gab)
colnames(eval_gab) <- c('Model', 'AUC', 'CA', 'F1', 'Precision', 'Recall')

#Membuat Plot ROC
plot(mp_rf, mp_nnet,
     mp_glm, mp_knn,
     mp_nb,
     geom = "roc")

```



```

#Simpan Plot ROC sebagai File PDF
pdf('AUC-ROC.pdf')
plot(mp_rf, mp_nnet,
      mp_glm, mp_knn,
      mp_nb,
      geom = "roc")
dev.off()

#Membuat Plot Variabel Importance untuk Model ML Terbaik
vip_rf <- model_parts(explainer = explainer_rf, B = 50,
                     N = NULL)
vip_nnet <- model_parts(explainer = explainer_nnet, B = 50,
                       N = NULL)
pa <- plot(vip_rf, show_boxplots = FALSE) + ggtitle("Feature Importance", "")
pb <- plot(vip_nnet, show_boxplots = FALSE) + ggtitle(" ", "")
(pa+pb)
plot(vip_rf, vip_nnet) + ggtitle("Feature Importance", "")

#Simpan Plot Variabel Importance sebagai File PDF
pdf('Feature Importance-RFNN.pdf')
plot(vip_rf, vip_nnet, show_boxplots = FALSE) + ggtitle("Feature Importance", "")
dev.off()

#Membuat Plot Partial Dependence untuk Model ML Terbaik
mp_rf1 <- model_profile(explainer_rf,
                      type = "partial",
                      variables = c('GPA'))

mp_rf2 <- model_profile(explainer_rf,
                      type = "partial",
                      variables = c('Min_Wage',
                                    'Age'))

mp_nnet1 <- model_profile(explainer_nnet,
                        type = "partial",
                        variables = c('GPA'))

mp_nnet2 <- model_profile(explainer_nnet,
                        type = "partial",
                        variables = c('Min_Wage',
                                    'Age'))

vr_rf1 <- model_profile(explainer_rf,
                      type = "partial",
                      variables = c('Gender',
                                    'Marital',
                                    'Employ',
                                    'Region'))

```

```

vr_nnet1 <- model_profile(explainer_nnet,
  type = "partial",
  variables = c('Gender',
    'Marital',
    'Employ',
    'Region'))

p1 <- plot(mp_rf2, mp_nnet2) + ggtitle("Partial Dependence Profile-Demographics", "")

p2 <- plot(vr_rf1, vr_nnet1) + ggtitle(" ", "")

p3 <- plot(mp_rf1, mp_nnet1) + ggtitle("Partial Dependence Profile-College Info", "")

(p1 / p2)

#Simpan Plot Partial Dependence sebagai File PDF
plot(vr_rf1)
pdf('PDP-RFNN-Demographics.pdf')
(p1 / p2)
dev.off()

pdf('PDP-RFNN-College.pdf')
p3
dev.off()

```