

# Association Role Mining pada Moodle dengan menggunakan Algoritma Apriori : Studi Kasus Nilai UN IPA

Jeems Terri A.S.\*<sup>1</sup>, Nurul Hidayat<sup>2</sup>, Yulia W<sup>3</sup>

<sup>1</sup>Universitas Ciputra; <sup>2</sup>Universitas Jenderal Soedirman; <sup>3</sup>LPP Widyathama Parahita  
e-mail: \*jagustinus@student.ciputra.ac.id, <sup>2</sup>nurul@unsoed.ac.id, <sup>3</sup>yulia@joelmedia.co.id

## Abstrak

*Asa bisa karena biasa merupakan kearifan lokal yang mempunyai kekuatan besar. Tidak dapat dihindari bahwa setiap hendak menghadapi ujian akhir setiap sekolah akan memberikan tambahan pelajaran di luar jam-jam pelajaran yang sudah ditetapkan. Seringkali pemberian jam tambahan ini tidak efektif karena tidak secara signifikan menunjukkan perubahan perolehan nilai UN siswa, hal ini dapat dengan mudah diamati dari perolehan nilai rata-rata UN. Ada keistimewaan Flipped Learning yang sebenarnya bisa menjadi solusi pemberian materi tambahan di sekolah. Pada Flipped learning siswa diminta mengerjakan soal yang sudah disediakan. Siswa dapat mengerjakan berkali-kali dan sebanyak banyaknya tanpa menambah beban guru untuk mengoreksi hasil pengerjaan siswa. Hanya saja terdapat kekurangan karena kontrol waktu pengerjaan soal secara mandiri ada pada masing-masing siswa, maka akan ada siswa yang mengerjakan waktu sangat cepat atau sangat lambat. Pada penelitian kali ini di kelas 9 dengan jumlah siswa 44 siswa dengan Moodle sebagai media Flipped Learning, kami bermaksud untuk mencari faktor-faktor apa sajakah yang menjadi indikator keberhasilan siswa menghadapi UN jika dilihat dari aktifitas siswa pada pembelajaran online. ARM sudah banyak digunakan untuk melihat keterkaitan antar item-item yang dibeli oleh konsumen. Oleh karena itu kami bermaksud mencari ARM pada pembelajaran online tryout ini dengan menerapkan algoritma prediktif apriori untuk menemukan keterkaitan antar atribut apakah yang berperan penting dalam menentukan keberhasilan siswa menghadapi ujian akhir.*

**Kata kunci**— Educational data Science, Flipped Learning, Moodle, Algoritma Predictive Apriori, Ujian Nasional, ARM (asosiasi rule mining)

## Abstract

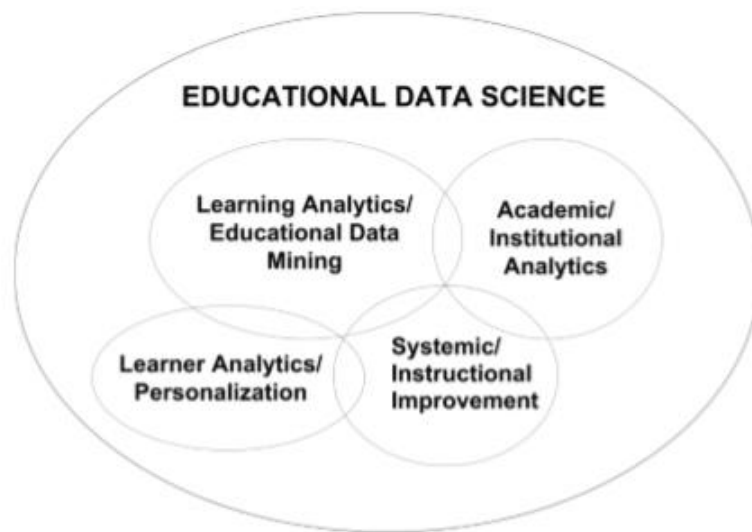
*“Asa bisa karena biasa” is a local wisdom that has great power. It is inevitable that every student will face the national exam where each school will provide additional lessons outside the assigned hours. Sometimes by giving additional lessons is not very effective because it doesn't significantly indicate changes in students' score, as we can observe from the average of national exam final scores. There is a feature in Flipped Learning that can be a solution for providing additional material for students. Students are provided by a mound of preparation exam and can work on those preparation exams as many times so teacher won't have any burden to teach all the material again in an additional lesson. However, the time students working on those preparation exams will vary for each student, some very quick or very slow. In this study, we gather the data from grade 9 with a total of 44 students with Moodle as a Flipped Learning platform. We intended to look at what factors in online learning can be an indicator of the student's success score in national final exam. Association Rule Mining algorithm is applied in this study to find the best set of result along with what kind of relationship and which attributes will contribute to students final score.*

**Keywords**— Association Rule Mining, flipped learning, moodle, apriori algorithm

## 1. PENDAHULUAN

Di abad ke-21, ketika data ada di mana-mana di setiap sisi kehidupan, termasuk di dunia pendidikan, dengan kemajuan teknik komputasi, dimungkinkan untuk menyerap semua informasi melalui berbagai platform termasuk menggunakan MOODLE. Sebagai LMS. MOODLE memiliki kelebihan pada log data yang sangat kaya, dengan menerapkan pemambangan data dan pengolahannya, kita bisa mendapatkan banyak informasi yang berharga [1].

Penelitian kali ini kami berfokus pada domain EDS (educational Data Science). Aplikasi spesifik data sains (DS) di bidang Pendidikan dikenal sebagai *Educational Data Science* (EDS), bekerja dengan data yang dikumpulkan dari lingkungan pendidikan untuk menyelesaikan masalah pendidikan. Bidang baru EDS ini dibangun dari multidisiplin yaitu ilmu komputer, pendidikan, statistik dengan beberapa komunitas terkait (gambar 1).



Gambar 1 Komunitas educational Data Science [2]

Hal ini yang membentuk paradigma penelitian baru, yaitu :

1. Learning Analytics (LA) / Educational Data Mining (EDM)
2. Analisis Pembelajar / Personalisasi (LA/ P) dan educational Recommender System (ERS).
3. Akademik/ Analisis Institusional (AA), yang secara tradisional dikenal sebagai
4. Peningkatan Sistemik/ Instruksional (S/II), juga dikenal sebagai Pengambilan Keputusan

Beberapa hasil penulisan pada bidang domain ini adalah mengenai pengaruh sosial emosi pada pencapaian nilai [3]. Riset pada penambangan data menggunakan Moodle juga merupakan hal menarik lainnya baik pada clustering pembelajar [4], performa pembelajar [5], bahkan membuat penugasan berbasis MOODLE. Dalam penelitian kali ini, kita akan membahas bagaimana data science menunjukkan secara ilmiah bahwa flipped learning memainkan peran penting peningkatan perolehan nilai ujian akhir nasional baik secara umum atau khusus pada mata pelajaran IPA. Kami ingin memberikan gambaran bahwa penggunaan media pembelajaran online khususnya dengan metode Flipped Learning mampu menjadi solusi permasalahan pencapaian ketuntasan belajar (mastery learning). Pembelajaran personalisasi yang didukung oleh MOODLE [6] mempermudah pengajar untuk memperhatikan perkembangan siswa secara individu.

## 2. MINING ASSOCIATION RULES DENGAN ALGORITMA APRIORI

Analisis asosiasi berguna untuk menemukan hubungan menarik yang tersembunyi dalam kumpulan data besar [7]. Hubungan yang terbuka dapat direpresentasikan dalam bentuk aturan asosiasi atau set item. Association rule mining (ARM) telah digunakan dalam sistem manajemen pembelajaran untuk menemukan korelasi antara item untuk: mendiagnosis masalah pembelajaran dan menawarkan saran kepada siswa [8], mengoptimalkan konten materi berdasarkan minat siswa [9].

Aturan asosiasi adalah ekspresi implikasi dari bentuk  $X \rightarrow Y$ , di mana X dan Y adalah item yang terpisah, misal :  $X \cap Y = \emptyset$ . Kekuatan aturan asosiasi dapat diukur dalam hal dukungan dan kepercayaannya. Dukungan menentukan seberapa sering aturan berlaku untuk set data yang diberikan, sementara kepercayaan menentukan seberapa sering item dalam Y muncul dalam transaksi yang mengandung X. Definisi formal dari metrik ini adalah

$$\text{Support}, s(X \rightarrow Y) = \frac{\sigma(X \cup Y)}{N} \quad (1)$$

$$\text{Confidence}, c(X \rightarrow Y) = \frac{\sigma(X \cup Y)}{\sigma(X)} \quad (2)$$

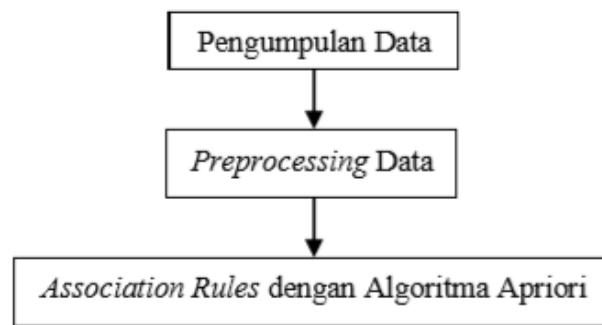
*support* adalah ukuran penting karena aturan yang memiliki dukungan sangat rendah dapat terjadi hanya secara kebetulan. Aturan *support* rendah juga cenderung tidak menarik dari perspektif kebutuhan. *Confidence* sering digunakan untuk menghilangkan aturan yang tidak menarik. *Support* memiliki properti yang diinginkan yang dapat dieksploitasi untuk penemuan aturan asosiasi yang efisien. *Confidence* mengukur keandalan kesimpulan yang dibuat oleh suatu aturan. Untuk aturan yang diberikan  $X \rightarrow Y$ , semakin tinggi *confidence*, semakin besar kemungkinan bagi Y untuk terkait dalam transaksi yang mengandung X. *Confidence* juga memberikan perkiraan probabilitas bersyarat dari Y yang diberikan X.

Ukuran *support* membantu mengurangi jumlah kandidat item yang dieksplorasi selama generasi itemset. Penggunaan *support* untuk pemangkasan item kandidat dipandu oleh Prinsip Apriori. "Jika sebuah itemset sering muncul, maka semua himpunan bagiannya juga harus sering muncul." [10]. Moodle memungkinkan guru untuk mengakses catatan terperinci aktivitas siswa, yang melacak materi dan sumber daya yang diakses oleh siswa dan mencatat setiap klik untuk tujuan navigasi. Log dapat difilter menurut kursus, peserta, hari atau jenis kegiatan. Untuk beberapa kegiatan seperti tes, analisis terperinci dari setiap respons juga tersedia. Guru dapat menggunakan log untuk menganalisis kinerja siswa, apa dan kapan mereka melakukan sesuatu, dan dengan demikian dapat digunakan untuk penggalian data.

Aplikasi Weka (Waikato Environment for Knowledge Analysis) dikembangkan oleh University of Waikato, Selandia Baru dapat digunakan untuk melakukan ARM. WEKA hadir dengan serangkaian algoritma penambangan data untuk preprocessing data, klasifikasi, regresi, pengelompokan, aturan asosiasi dan visualisasi. Dalam penelitian ini, kami menggunakan Weka dan menggunakan format representasi eksternal dataset ARFF. Hal ini memungkinkan menarik hubungan antara atribut dalam bentuk aturan asosiasi, yang mewakili korelasi erat antara *support* dan *confidence*. *Confidence* didefinisikan sebagai rasio jumlah pengamatan yang mengandung konsekuensi dan jumlah pengamatan yang mengandung anteseden. *Support* adalah rasio jumlah pengamatan yang mengandung anteseden dan konsekuensi dan jumlah total pengamatan dalam dataset [11]

### 3. METODE PENELITIAN

Pentingnya penelitian ini adalah dalam menyarankan cara menggunakan algoritma penambangan data untuk menentukan faktor pada latihan soal online yang merupakan bagian dari flipped learning dari *face to face learning*. Penelitian ini didasarkan pada 44 siswa kelas 9 SMP Kr. Dharma Mulya, Surabaya. Sekolah ini secara khusus menerapkan flipped learning sebagai metode untuk persiapan menghadapi Ujian Akhir. Adapun Proses yang dilakukan secara sederhana dapat dilihat pada gambar 2, dibawah ini :



Gambar 2 Urutan Proses Asosiasi Rule Mining

*Tools* WEKA digunakan untuk preprocessing dan analisis data. Di WEKA, kami menerapkan dua alat, algoritma Apriori dalam aturan asosiasi (ARM). Penelitian ini bertujuan untuk menyarankan penggunaan algoritma data mining dalam menentukan aktifitas-aktifitas pada pembelajaran flipped learning yang mampu memprediksi nilai Ujian Nasional. Berdasarkan urutan proses pada gambar 2, sebagai berikut :

1. Metode Flipped yang dilakukan adalah, guru memberikan materi pelajaran pada *face to face learning* sedangkan pada flipped berikutnya guru memberikan latihan soal persiapan UN pada aplikasi Moodle. Saat pegayaan materi pelajaran secara tatap muka, guru membahas materi-materi yang tidak dikuasai oleh siswa (guru tidak memberi pengayaan dengan membahas semua soal melainkan menekankan pada materi-materi yang tidak dikuasai siswa).
2. Guru memberikan 10 (enam) paket soal persiapan ujian nasional berbasis komputer (UNBK) untuk dikerjakan diluar pertemuan tatap muka. Pada gambar 3, materi yang dibahas khusus pada tatap muka adalah memiliki tanda X merah.

Tabel 1 Contoh hasil pengerjaan siswa pada Moodle

Surname	First name	State	Started on	Completed	Time taken	Grade/100	Q. 1 /2	Q. 2 /2
Angraeni	Jessica	Finished	27 March 2019 2:09 PM	27 March 2019 3:16 PM	1 hour 7 mins	54	0	2
Gail Helena Margono	Abi	Finished	27 March 2019 3:54 PM	27 March 2019 5:00 PM	1 hour 5 mins	92	2	2
Sanjaya Yunanto	Sony	Finished	27 March 2019 4:01 PM	27 March 2019 6:01 PM	2 hours	85	2	2

3. *Data Preprocessing*, langkah pertama preprocessing data adalah pemilihan data. kami telah mengambil sejumlah data hasil pengerjaan quiz siswa (tryout persiapan unbk) dari log 44 siswa kelas 9 (table 1)
4. Langkah selanjutnya setelah preprocessing data adalah akuisisi data. Prasyarat utama untuk akuisisi data adalah pembuatan file log Moodle yang berisi semua informasi yang diperlukan, seperti pada tabel 2, berikut :

Tabel 2 Contoh File log Moodle yang di gunakan

student_id	n_time	n_attempt	n_avg_tyout	n_final_score
X1	894	14	76	70
X2	648	16	73	72,5
X3	384	7	52	40
X4	324	8	65	72,5
X5	240	2	34	37,5
X6	264	8	67	85
X7	354	6	53	60
X8	414	9	72	75
X9	288	5	62	70
X10	542	11	74	87,5

5. Selanjutnya dilakukan diskritisasi data. Pada proses ini data numerik perlu didiskritisasi. Dalam proses ini nilai-nilai numerik dibagi menjadi kelas-kelas kategorikal, seperti pada tabel 3 berikut:

Tabel 3 Contoh Hasil Kelas Kategorikal

student_id	n_time	n_attempt	n_avg_tyout	n_final_score
X1	High	High	High	Passed
X2	Medium	High	High	Passed
X3	Low	Medium	Medium	Failed
X4	Low	Medium	High	Passed
X5	Low	Low	Low	Failed
X6	Low	Medium	High	Passed
X7	Low	Low	Medium	Passed
X8	Low	Medium	High	Passed
X9	Low	Low	Medium	Passed
X10	Medium	Medium	High	Passed

6. Langkah terakhir adalah transformasi data. Setelah diskritisasi, data perlu ditransformasikan ke dalam format yang dibutuhkan oleh algoritma data mining. Dalam studi kasus kali ini, dari log Moodle diekspor sebagai file CSV, yang dapat diimpor di WEKA dan diekspor sebagai Format File Attribute Relation. File ARFF adalah file teks ASCII yang menjelaskan daftar instance dari sekumpulan atribut. File ARFF dapat dilihat pada gambar 3

```
@relation moodle_log-weka.filters.supervised.attribute.Disc
e-Rfirst-last-precision6

@attribute dent_id {X1,X2,X3,X4,X5,X6,X7,X8,X9,X10,X11,X12,
14,X15,X16,X17,X18,X19,X20,X21,X22,X23,X24,X25,X26,X27,X28,
30,X31,X32,X33,X34,X35,X36,X37,X38,X39,X40,X41,X42,X43,X44}
@attribute n_time {High,Medium,Low}
@attribute n_attempt {High,Medium,Low}
@attribute n_avg_tyout {High,Medium,Low}
@attribute n_final_score {Passed,Failed}

@data
X1,High,High,High,Passed
X2,Medium,High,High,Passed
X3,Low,Medium,Medium,Failed
X4,Low,Medium,High,Passed
X5,Low,Low,Low,Failed
X6,Low,Medium,High,Passed
X7,Low,Low,Medium,Passed
X8,Low,Medium,High,Passed
X9,Low,Low,Medium,Passed
X10,Medium,Medium,High,Passed
X11,Low,Medium,Medium,Passed
X12,Low,Low,Medium,Passed
```

Gambar 3 Data Attributes relationship File Format (ARFF) yang sudah di convert dari excel file.

```
opti... Apriori
=====

Minimum support: 0.3 (13 instances)
Minimum metric <confidence>: 0.9
Number of cycles performed: 14

Generated sets of large itemsets:

Size of set of large itemsets L(1): 7

Large Itemsets L(1):
n_time=Medium 15
n_time=Low 27
n_attempt=Medium 25
n_attempt=Low 14
n_avg_tyout=High 23
n_avg_tyout=Medium 17
n_final_score=Passed 36

Size of set of large itemsets L(2): 7

Large Itemsets L(2):
n_time=Medium n_final_score=Passed 14
n_time=Low n_attempt=Medium 14
n_time=Low n_final_score=Passed 20
```

Gambar 4 Contoh Algoritma Apriori pada WEKA

Gambar 4, diatas menunjukkan penggunaan algoritma apriori untuk mencari hasil terbaik dengan minimal *support* = 0.3 dan *minimum confidence* = 0.9

```

n_attempt
n_avg_tyout
n_final_score
=== Associator model (full training set) ===

PredictiveApriori
=====

Best rules found:

1. n_avg_tyout=High 23 ==> n_final_score=Passed 23    acc:(0.9946)
2. n_attempt=High 5 ==> n_final_score=Passed 5    acc:(0.97876)
3. n_time=Low n_avg_tyout=Low 4 ==> n_attempt=Low 4    acc:(0.9714)
4. n_time=Low n_attempt=Low n_avg_tyout=Low 4 ==> n_final_score=Failed 4    acc:(0.9714)
5. n_time=Medium 15 ==> n_final_score=Passed 14    acc:(0.95069)
6. n_time=High 2 ==> n_avg_tyout=High n_final_score=Passed 2    acc:(0.93622)
7. n_time=Low n_attempt=Medium n_final_score=Failed 2 ==> n_avg_tyout=Medium 2    acc:(0.93622)
8. n_attempt=Medium 25 ==> n_final_score=Passed 22    acc:(0.82096)
9. n_time=Low n_attempt=Low n_avg_tyout=Medium 7 ==> n_final_score=Passed 6    acc:(0.80271)
10. n_time=Low n_attempt=Low n_final_score=Passed 7 ==> n_avg_tyout=Medium 6    acc:(0.80271)

```

Gambar 5 Contoh Algoritma Predictive Apriori

Beberapa algoritma aturan asosiasi dapat digunakan di Weka, pada Studi kasus ini kami menggunakan algoritma Predictive Apriori dan Apriori. Predictive Apriori adalah versi perbaikan dari algoritma Apriori, yang memaksimalkan kemungkinan membuat prediksi yang akurat dan menyelesaikan masalah keseimbangan antara support dan confidence.

#### 4. HASIL DAN PEMBAHASAN

Setelah algoritma Apriori dieksekusi, kami memperoleh hasil, yang didasarkan pada ukuran set item. Tabel 4 menjelaskan hasil yang diperoleh dengan set item: 7, hasilnya menunjukkan bahwa jumlah waktu pengerjaan medium sebanyak 15 siswa, yang pengerjaan waktu nya rendah ada 27 siswa. Jumlah siswa yang diprediksi lulus sejumlah 36 siswa.

Tabel 4 hasil  $s = 0,3$   $c = 0,9$  pada item

Size of set of large itemsets L(1): 7					
No.	List of Attributes	Min Support	Confidence	Result	
1	n_time	0,3	0,9	n_time=Medium	15
				n_time=Low	27
2	n_attempt			n_attempt=Medium	25
				n_attempt=Low	14
3	n_avg_tyout			n_avg_tyout=High	23
				n_avg_tyout=Medium	17
4	n_final_score			n_final_score=Passed	36

Pada tabel 5 dengan jumlah set item : 7; jika waktu yang di sediakan untuk mengerjakan soal tergolong medium maka 14 siswa dinyatakan mampu berhasil pada ujian akhir. Atau jika nilai tryout yang diperoleh medium maka siswa akan berhasil pada ujian akhir sebanyak 13 siswa.'

Tabel 5 Hasil dengan item lain

Size of set of large itemsets L(2): 7					
No.	List of Attributes	Min Support	Confidence	Result	
1	n_time	0,3	0,9	n_time=Medium n_final_score=Passed	14
2	n_attempt			n_time=Low n_attempt=Medium	14
3	n_avg_tyout			n_time=Low n_final_score=Passed	20
4	n_final_score			n_attempt=Medium n_avg_tyout=High	17
				n_attempt=Medium n_final_score=Passed	22
				n_avg_tyout=High n_final_score=Passed	23
				n_avg_tyout=Medium n_final_score=Passed	13

Pada tabel 6 dengan jumlah set item : 1, didapatkan bahwa jika jumlah pengerjaan medium, dengan nilai rata-rata tinggi maka 17 siswa dinyatakan berhasil pada Ujian Akhir

Tabel 6 Hasil dengan jumlah set item = 1

Size of set of large itemsets L(3): 1					
No.	List of Attributes	Min Support	Confidence	Result	
1	n_time	0,3	0,9	n_attempt=Medium n_avg_tyout=High n_final_score=Passed	17
2	n_attempt				
3	n_avg_tryout				
4	n_final_score				

Pada Tabel 7, analisis yang dilakukan pada Weka untuk menghasilkan aturan asosiasi dengan akurasi prediktif dapat dilihat pada tabel 7. Kami menjalankan algoritma Predictive Apriori dan membuat aturan dengan prediksi tertinggi. Mungkin terdapat beberapa aturan yang tidak menarik. Aturan yang relevan dengan tujuan pendidikan biasanya menunjukkan hubungan yang diharapkan atau yang sesuai. Aturan-aturan ini bisa sangat berguna bagi guru ketika membuat keputusan tentang kegiatan dan identifikasi siswa dengan masalah belajar.

Tabel 7 Nilai Akurasi Prediktif dari rule terbaik

No	Best Rule Found	Predictive Accuracy
1	n_avg_tyout=High 23 ==> n_final_score=Passed 23	0.9946
2	n_attempt=High 5 ==> n_final_score=Passed 5	0.98549



3	n_time=Low n_avg_tyout=Low 4 ==> n_attempt=Low 4	0.9714
4	n_time=Low n_attempt=Low n_avg_tyout=Low 4 ==> n_final_score=Failed 4	0.9714
5	n_time=Medium 15 ==> n_final_score=Passed 14	0.95069
6	n_time=High 2 ==> n_avg_tyout=High n_final_score=Passed 2	0.93622
7	n_time=Low n_attempt=Medium n_final_score=Failed 2 ==> n_avg_tyout=Medium 2	0.93622
8	n_attempt=Medium 25 ==> n_final_score=Passed 22	0.82096

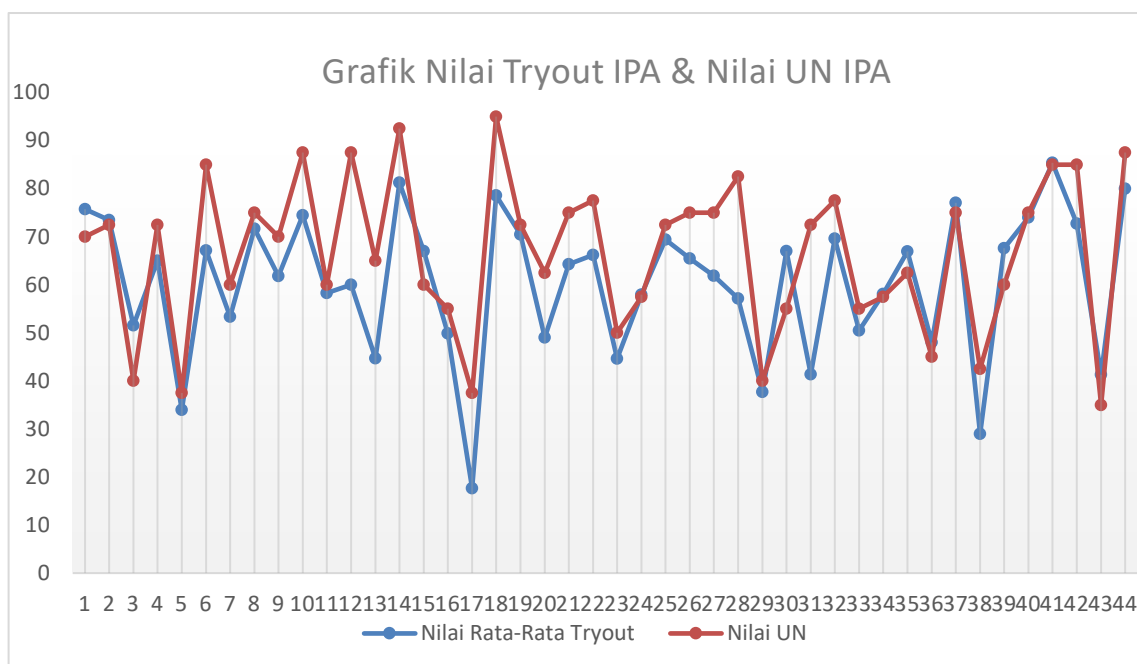
Untuk melengkapi domain EDS, yang juga melibatkan hasil statistika, kami mencari korelasi antara nilai Tryout (Flipped Learning) yang dilakukan guru dengan nilai UNBK 2019 yang diperoleh oleh siswa dengan menerapkan koefisien korelasi antara dua variabel yang masing-masing mempunyai skala pengukuran interval maka digunakan korelasi product moment yang dikembangkan oleh Karl Pearson (persamaan 3).

$$r_{xy} = \frac{N \sum xy - (\sum x)(\sum y)}{\sqrt{[N \sum x^2 - (\sum x)^2][N \sum y^2 - (\sum y)^2]}} \quad (3)$$

$$r_{xy} = \frac{(44 \cdot 185383,2) - (2658 \cdot 2954)}{\sqrt{[44 \cdot 170181 - (2658)^2][44 \cdot 206569 - (2933)^2]}} \quad (4)$$

$$r_{xy} = 0,796116 \quad (5)$$

Dari hasil perhitungan korelasi dengan product moment Karl Pearson didapatkan hasil korelasi sebesar : **0,796116**, yang menunjukkan bahwa korelasi antara perolehan nilai Tryout dengan Nilai UNBK siswa. Dalam Grafik pada gambar 10 dapat dilihat grafik dimana terdapat korelasi signifikan antara perolehan nilai tryout flipped learning dengan perolehan nilai UN 2019.



Gambar 6 Korelasai antara nilai Flipped Learning dengan nilai UN

## 5. KESIMPULAN

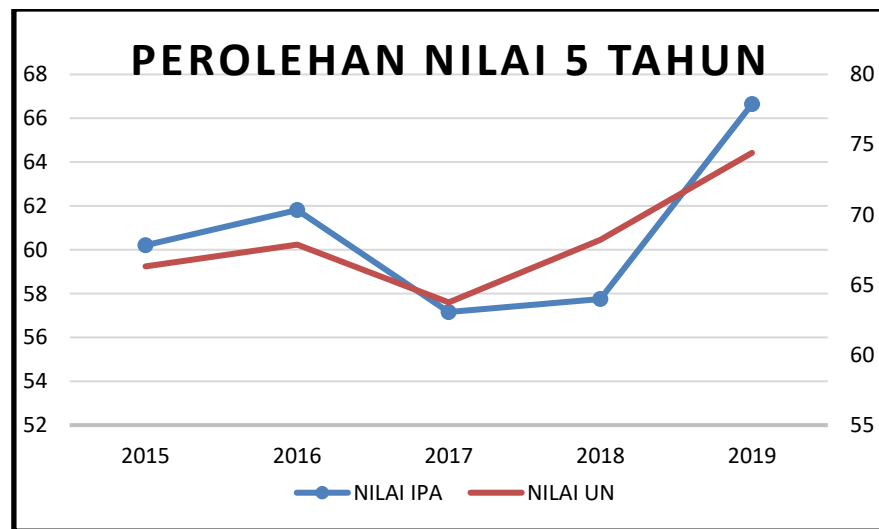
Tujuan dari penelitian ini adalah mencari aturan terbaik untuk memprediksi berhasil/tidak siswa pada Ujian Nasional berdasarkan aktifitas pengerjaan latihan soal/tryout pada *flipped learning*. Pada studi kasus ini kami mendapatkan hasil asosiasi aturan yang menunjukkan bahwa jika selama latihan soal flipped learning perolehan rata-rata nilai tinggi, maka dengan tingkat akurasi 0,99440 siswa mampu lulus pada ujian akhir. Jika jumlah pengerjaan latihan soal medium, tetapi nilai latihan tinggi maka siswa akan lulus pada ujian akhir. Tidak semua siswa yang membutuhkan waktu pengerjaan tiap latihan soal medium akan dapat lulus pada ujian akhir.

Pada kesempatan kali ini kami juga bermaksud menyampaikan bahwa ada hal positif dalam penerapan Flipped Learning sehingga sekolah/ Perguruan tinggi tidak perlu ragu untuk menerapkannya karena korelasi dengan nilai sebesar 0,796116 antara nilai rata-rata pada latihan flipped learning dengan perolehan nilai ujian akhir. Hasil ini dapat menjadi acuan positif bagi guru untuk memperhatikan nilai rata-rata perolehan siswa, atau banyaknya latihan soal yang dikerjakan dan pengerjaan dengan waktu yang tidak terlalu cepat dapat membantu guru memprediksi keberhasilan siswa pada ujian akhir.

## 6. SARAN dan PENELITIAN LANJUTAN

Penelitian pada studi kasus ini masih menggunakan data sederhana, pada penelitian selanjutnya dapat membuat relasi yang lebih kompleks antar aktifitas online terkait persiapan ujian akhir siswa. Berdasarkan perolehan nilai UN selama 5 tahun terakhir, sekolah mendapat peningkatan yang signifikan (gambar 8). Dapat dilakukan studi lebih lanjut apakah penggunaan flipped learning pada mapel UN selama 1 semester yang berhasil meningkatkan perolehan nilai UN sekolah. Pada penelitian ini juga dapat dikembangkan untuk *early warning* pada keberhasilan/kegagalan siswa sehingga sekolah,

guru dan orang tua dapat dengan lebih akurat melakukan cara-cara pendampingan dan pemberian *treatment* pada siswa.



Gambar 7 Perolehan Nilai UN pada sekolah studi kasus

#### DAFTAR PUSTAKA

- [1] M. L. Gogan. 2014. *Aspect Concerning the use of MOODLE platform : Case Study.* in *International Conference Interdisciplinarity in Engeering.* Romania.
- [2] S. V. Cristobal Romero. 2017. *Educational Data Science in Massive Open Online Courses,* Wiley *Interdisciplinary Reviews: Data Mining and Knowledge Discover.* Cordoba.
- [3] M.-C. Liu. 2017. *The use of data science for education: The case of social-emotional learning,* in *Smart Learning Environment, volume 4,* p. 1. SpringerOpen.
- [4] A. Bovo. 2013 . *Analysis of students clustering results based on Moodle log data,* in *6th International Conference on Educational Data Mining - EDM 2013,* pp. 306-307. Tennessee, United States.
- [5] I. Dimopoulos. 2013. *Using Learning Analytics in Moodle for assessing students' performance,* in *2nd Moodle Research Conference ;* pg. 40. Sousse, Tunisia.
- [6] C. Limongelli, "Configuration of Personalized e-Learning Courses in Moodle," in *EUROCON 2007 The International Conference on "Computer as a Tool" ,* Warsaw, 2007.
- [7] I. T. a. S. A. R. C. Agarwal, Mining Association Rules between Sets of Items in Large Databases.
- [8] G. J. Hwang. 2003. *A computer-assisted approach to diagnosing student learning problems in science courses,* *Journal of Information Science and Engineering,* vol : 19(2), page : 229-248
- [9] A. A. Ramli. 2005. *Web usage mining using apriori algorithm: UUM learning care portal case,* *International Conference on Knowledge Management,* Malaysia.

- [10] D. Tank. 2014. *Improved Apriori Algorithm for Mining Association Rules*, *researchgate.net.*.
- [11] Goran Avlijaš. 2016. *A Guide For Association Rule Mining In Moodle Course Management System*, In International Scientific Conference On Ict And E-Business Related Research, Serbia.
- [12] P. Barg. 2014. *From Teaching, Learning to Assessment: MOODLE experience at B'School in India*, Symbiosis Institute of Management Studies Annual Research Conference (SIMSARC13). *Procedia Economics and Finance*, vol : 11, page : 857 – 865