

Aplikasi Inferensi Bayes pada *Data Mining* terutama *Pattern Recognition*

Trilaksono Aribowo (18209015)
Program Studi Sistem dan Teknologi Informasi
Sekolah Teknik Elektro dan Informatika
Institut Teknologi Bandung, Jl. Ganesha 10 Bandung 40132, Indonesia
18209015@std.stei.itb.ac.id

ABSTRAK

Makalah ini akan membahas tentang aplikasi dari salah satu teori statistika dalam sistem informasi. Teori statistika yang akan dibahas adalah teori inferensi Bayes, yang banyak diaplikasikan dalam *data mining* di bagian *pattern recognition*. Lebih lanjut lagi, akan dibahas mengenai algoritma klasifikasi, salah satu terapan *pattern recognition*, yang menggunakan teorema Bayes, yaitu *naive Bayes classifier*.

Kata kunci : *pattern recognition, naive Bayes classifier, inferensi Bayes.*

I. PENDAHULUAN

Data mining adalah salah satu cabang sains komputer dan intelegensia buatan yang merupakan sebuah proses pengambilan *pattern* (pola) data untuk kemudian diolah menjadi informasi yang bisa diambil dan digunakan oleh pengguna. *Data mining* banyak digunakan di bidang *marketing* untuk mengolah data yang ada menjadi informasi statistik untuk digunakan sebagai bagian dalam penentua keputusan.

Dalam mengubah data menjadi informasi yang dapat digunakan secara bebas, dilakukanlah sebuah proses yang bernama *pattern recognition*. Proses ini akan kemudian mengelompokkan data-data yang ada berdasarkan keunikan pola masing-masing data. Setelah itu, data yang sudah dikelompokkan tadi akan disajikan dalam bentuk informasi statistik.

Data mining sering digunakan untuk membantu dalam menganalisis sekelompok pengamatan tingkah laku. Dalam hal ini, *data mining* berguna untuk menemukan pola tersembunyi dalam serangkaian aksi. Hal ini biasanya diterapkan pada pembuatan intelegensia buatan untuk permainan seperti catur, *tic tac toe*, igo, dll. Selain itu, *data mining* biasanya digunakan juga dalam dunia bisnis, terutama bidang *marketing* untuk menentukan calon konsumen yang prospeknya lebih bagus.

Data mining juga sudah biasa diterapkan di bioinformatika dan studi genetika, terutama untuk menemukan dan memetakan pola hubungan rangkaian DNA manusia dengan penyakit tertentu. Dengan

menentukan hal tersebut, akan sangat membantu diagnosis, pencegahan, dan pengobatan penyakit tersebut.

II. DASAR TEORI

A. *Pattern Recognition*

Pattern recognition adalah memetakan atau memasangkan sebuah nilai keluaran (atau *label*) kepada sebuah nilai inputan (atau *instance*), berdasarkan algoritma tertentu. Tujuan dari *pattern recognition* adalah untuk mendapatkan hasil yang bisa dipertanggungjawabkan dari setiap nilai masukan dan untuk memasangkan masukan dengan keluaran secara kasar. Hal ini berkebalikan dengan *pattern matching*, yang mencari pola yang benar-benar sama dengan pola pengetes yang sudah ada sebelumnya di masukan.

Salah satu contoh *pattern recognition* adalah klasifikasi. Proses klasifikasi memasangkan setiap masukan dengan salah satu dari beberapa kelas yang ada. Contoh dari proses klasifikasi ini adalah *spam filtering* yang banyak tersedia di kotak masuk penyedia fasilitas surel, di mana setiap surel yang masuk akan diidentifikasi dan dikelompokkan ke dalam dua kelompok, yaitu *spam* dan *non-spam*, berdasarkan pada pola data yang ada di setiap surel masuk. Contoh lain adalah regresi, yang memasangkan sebuah nilai keluaran berupa bilangan riil pada setiap nilai masukannya. Selain itu, ada pula *sequence labeling*, yang memasangkan sebuah kelas pada sebuah sekuen masukan.

Pattern recognition dikelompokkan ke dalam dua kelompok berdasarkan prosedur studi yang digunakan untuk menghasilkan keluaran. *Supervised learning* adalah salah satu jenis *pattern recognition* yang mengasumsikan bahwa *training set*, yang terdiri dari beberapa *instance* yang sudah diberi *label* dengan keluaran yang benar, sudah tersedia. Kemudian dalam prosedur studi dibuat sebuah model untuk mencapai dua tujuan yang terkadang bertentangan, yaitu melakukan *pattern recognition* sebaik mungkin pada *training set* dan menggeneralisir data-data baru sebaik mungkin (yang terkadang berarti harus bekerja sesimpel mungkin). Di lain pihak, *unsupervised learning* mengasumsikan *training data* yang belum diberi *label* secara manual, dan berusaha menemukan sebuah pola pada *training data* untuk menentukan nilai keluaran

yang benar pada data *instance* baru. Pada *unsupervised learning* terkadang tidak ada *training data*, yang berarti data yang harus diberi *label* adalah *training data* itu sendiri. Belakangan ini juga sedang dikembangkan metode penggabungan keduanya, yaitu *semi-supervised learning*, yang menggunakan kombinasi dari data yang sudah dilabeli dan data yang belum dilabeli (biasanya sedikit data yang sudah dilabeli dan banyak yang belum dilabeli).

Secara umum, algoritma *pattern recognition* biasanya bersifat probabilistik, di mana dalam prosesnya digunakan inferensi statistikal untuk menentukan *label* terbaik untuk setiap *instance*. Tidak seperti algoritma lainnya, algoritma probabilistik juga mengeluarkan besaran nilai peluang suatu *instance* tertentu diberi *label* tertentu. Maka dari itu, terkadang algoritma probabilistik menghasilkan N *label* terbaik untuk suatu *instance* beserta peluangnya masing-masing alih-alih hanya mengeluarkan satu *label* terbaik saja. Pada makalah ini akan dibahas mengenai algoritma klasifikasi menggunakan *naive Bayes classifier*.

Secara umum, *supervised pattern recognition* dirumuskan secara matematis sebagai demikian

$$g : \mathcal{X} \rightarrow \mathcal{Y}$$

yang memetakan sekumpulan *instance*

$$\mathbf{x} \in \mathcal{X}$$

ke sekumpulan *label*

$$y \in \mathcal{Y}$$

bersama dengan *training data*

$$\mathbf{D} = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$$

yang diasumsikan sudah merepresentasikan contoh pemetaan yang akurat. Lalu dibuatlah sebuah fungsi

$$h : \mathcal{X} \rightarrow \mathcal{Y}$$

yang mendekati fungsi g.

Untuk *pattern recognizer* probabilistik, di mana harus dihasilkan nilai peluang suatu *instance* diberi *label* tertentu, dirumuskan secara matematis sebagai berikut

$$p(\text{label}|\mathbf{x}, \boldsymbol{\theta}) = f(\mathbf{x}; \boldsymbol{\theta})$$

di mana \mathbf{x} adalah variabel masukan, dan $\boldsymbol{\theta}$ adalah parameter dari fungsi f .

Pada pendekatan diskriminatif, nilai f sudah diestimasi dan bisa langsung digunakan dalam perhitungan. Namun, pada pendekatan generatif, peluang inverse

$$p(\mathbf{x}|\text{label})$$

yang diestimasi dan dimasukkan dalam perhitungan bersama dengan

$$p(\text{label}|\boldsymbol{\theta})$$

Menggunakan teorema Bayes sebagai berikut :

$$p(\text{label}|\mathbf{x}, \boldsymbol{\theta}) = \frac{p(\mathbf{x}|\text{label})p(\text{label}|\boldsymbol{\theta})}{\sum_{L \in \text{all labels}} p(\mathbf{x}|L)p(L|\boldsymbol{\theta})}$$

Persamaan di atas berlaku jika *label* yang ada bersifat diskrit. Jika *label* yang akan diberikan bersifat kontinu, maka persamaan di atas berubah menjadi :

$$p(\text{label}|\mathbf{x}, \boldsymbol{\theta}) = \frac{p(\mathbf{x}|\text{label})p(\text{label}|\boldsymbol{\theta})}{\int_{L \in \text{all labels}} p(\mathbf{x}|L)p(L|\boldsymbol{\theta})dL}$$

Nilai $\boldsymbol{\theta}$ biasanya didapatkan menggunakan estimasi *maximum a posteriori* (MAP). Dengan cara ini, bisa didapat nilai terbaik untuk memenuhi dua tujuan, melakukan *pattern recognition* sebaik mungkin pada *training data* dan menemukan model tersimpel. Berarti, cara ini menggabungkan estimasi kesamaan maksimal dengan prosedur regularisasi untuk mendapatkan model yang lebih simpel.

B. Naive Bayes Classifier

Naive Bayes classifier adalah suatu *classifier* probabilistik simpel yang berdasarkan pada teorema Bayes pada umumnya, inferensi Bayes khususnya dengan asumsi independensi yang kuat (*naive*). Dalam prosesnya, *naive Bayes classifier* mengasumsikan bahwa ada atau tidak adanya suatu fitur pada suatu kelas tidak berhubungan dengan ada atau tidaknya fitur lain di kelas yang sama. Sebagai contoh, suatu buah bisa dikatakan apel jika berwarna merah, bundar, dan berdiameter sekitar 5 cm. *Naive Bayes classifier* mengasumsikan bahwa masing-masing fitur tersebut punya peranan dan bagiannya masing-masing dalam menentukan peluang bahwa suatu buah tadi memang benar-benar apel.

Naive Bayes classifier bisa menjadi sangat efisien jika dilakukan berdasarkan *supervised learning*. Biasanya, parameter fungsi f di *naive Bayes classifier* diestimasi berdasarkan kesamaan maksimal, yang berarti seseorang bisa membuat *naive Bayes model* tanpa memercayai peluang Bayes atau menggunakan metode Bayes apapun.

Model peluang untuk sebuah *classifier* adalah model kondisional. Karena itu, *naive Bayes probabilistic model* dapat dirumuskan sebagai berikut

$$p(C|F_1, \dots, F_n)$$

di mana C adalah peubah kelas yang dependen yang akan berisi salah satu kelas dari berbagai kelas, dan F_1 sampai F_n adalah peubah fitur atau ciri-ciri dari masukan.

Masalah muncul jika nilai n terlalu besar atau ada

beberapa fitur yang memiliki nilai sangat besar. Karena itu, dengan menggunakan teorema Bayes, kita dapat mengubah persamaan matematis di atas menjadi

$$p(C|F_1, \dots, F_n) = \frac{p(C) p(F_1, \dots, F_n|C)}{p(F_1, \dots, F_n)}$$

yang jika ditulis secara sederhana adalah

$$\begin{aligned} & \text{peluang suatu masukan diberi label } C \\ &= \frac{\text{peluang pemilihan label} \times \text{kesamaan}}{\text{bukti}} \end{aligned}$$

Karena nilai F_i selalu diberikan dan dependen terhadap nilai C , maka penyebut pada persamaan di atas akan selalu konstan. Karenanya, yang bisa kita lakukan hanyalah memanipulasi pembilangnya sesuai dengan *joint probability model* sebagai berikut

$$\begin{aligned} p(C, F_1, \dots, F_n) &= p(C) p(F_1, \dots, F_n|C) \\ &= p(C) p(F_1|C) p(F_2, \dots, F_n|C, F_1) \\ &= p(C) p(F_1|C) p(F_2|C, F_1) p(F_3, \dots, F_n|C, F_1, F_2) \\ &= p(C) p(F_1|C) p(F_2|C, F_1) p(F_3|C, F_1, F_2) p(F_4, \dots, F_n|C, F_1, F_2, F_3) \\ &= p(C) p(F_1|C) p(F_2|C, F_1) p(F_3|C, F_1, F_2) \dots p(F_n|C, F_1, F_2, F_3, \dots, F_{n-1}). \end{aligned}$$

Sekarang asumsikan setiap F_i independen secara kondisional terhadap F_j dan $i \neq j$. Ini berarti

$$p(F_i|C, F_j) = p(F_i|C)$$

karena itu, persamaan tadi bisa ditulis ulang sebagai

$$\begin{aligned} p(C, F_1, \dots, F_n) &= p(C) p(F_1|C) p(F_2|C) p(F_3|C) \dots \\ &= p(C) \prod_{i=1}^n p(F_i|C). \end{aligned}$$

Hal ini berarti, kita dapat menulis ulang persamaan awal tadi sebagai berikut

$$p(C|F_1, \dots, F_n) = \frac{1}{Z} p(C) \prod_{i=1}^n p(F_i|C)$$

di mana Z adalah faktor konstan yang bergantung pada bukti atau fitur apa yang sedang diperiksa. Dari situ dapat dilihat peluang suatu masukan termasuk pada kelas C tertentu untuk dijadikan sebagai masukan dalam proses penentuan keputusan di kelas manakah sebenarnya masukan tadi berasal.

Semua parameter model dapat diketahui menggunakan estimasi kesamaan maksimal. Jika data yang ada bersifat kontinu, maka diasumsikan bahwa data terdistribusi normal dan parameter model adalah rataan dan variansi dengan

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i$$

dan

$$\sigma^2 = \frac{1}{(N-1)} \sum_{i=1}^N (x_i - \mu)^2$$

C. Inferensi Bayes

Inferensi Bayes adalah semacam inferensi statistikal di mana beberapa bukti atau pengamatan digunakan untuk menghitung peluang bahwa sebuah hipotesis itu benar atau memperbarui nilai peluangnya yang sudah dihitung sebelumnya. Sesuai dengan namanya, inferensi Bayes menggunakan teorema Bayes dalam perhitungannya.

Pada penggunaannya, inferensi Bayes dilakukan dengan cara melihat kesamaan pada hipotesis untuk menentukan hipotesis tersebut termasuk ke kelas mana dengan bukti atau fitur yang ada. Hasilnya bisa didapat dengan melihat kesamaan hipotesis dengan kecocokan bukti yang ada dengan hipotesis.

Inferensi Bayes menggunakan sebagian aspek metode ilmiah, di mana pada inferensi Bayes terdapat proses pengumpulan barang bukti yang bisa konsisten atau tidak dengan hipotesisnya. Seiring dengan bertambahnya barang bukti yang ada, tingkat kepercayaan pada suatu hipotesis bisa berubah. Dengan bukti yang cukup, tingkat kepercayaan pada suatu hipotesis bisa sangat tinggi atau sangat rendah. Karenanya, inferensi Bayes bisa digunakan untuk membedakan dua hipotesis yang saling bertentangan. Hipotesis dengan peluang yang sangat tinggi harus kita terima, sedangkan yang sangat rendah harus kita tolak.

Pada inferensi Bayes, kita harus menentukan tingkat kepercayaan pada suatu hipotesis menggunakan estimasi numerik sebelum terdapat bukti apapun. Setelah didapatkan bukti baru, dilakukan lagi pencarian tingkat kepercayaan hipotesis tersebut menggunakan estimasi numerik, dan begitu selanjutnya tiap ditemukan bukti baru.

Setiap didapatkan data baru, dengan menggunakan teorema Bayes, peluang bahwa suatu hipotesis itu benar berubah sesuai dengan

$$P(H|E) = \frac{P(E|H) P(H)}{P(E)}$$

di mana :

- H adalah hipotesis yang diperiksa
- E adalah bukti atau data yang didapat dari pengamatan
- $P(H)$ adalah peluang hipotesis itu benar sebelum didapatkan bukti baru
- $P(E|H)$ adalah fungsi kesamaan atau peluang

- bahwa akan didapat bukti E jika H benar
- $P(E)$ adalah peluang marginal, peluang kita akan mendapat bukti E, tidak tergantung pada hipotesis yang kita periksa
- $P(H | E)$ adalah peluang hipotesis H benar setelah kita mendapatkan bukti E

Faktor $P(E | H)/P(E)$ menunjukkan pengaruh ditemukannya bukti E terhadap tingkat kepercayaan pada hipotesis H. Tentu saja kita mengasumsikan bahwa H itu benar, tapi ketika H tidak diasumsikan benar, bukti E akan susah ditemukan ($P(E)$ bernilai kecil), karena itu faktor tadi akan bernilai sangat besar. Jika itu terjadi, maka $P(H | E)$ akan bernilai sangat besar. Sebaliknya, jika $P(E)$ bernilai besar ketika H diasumsikan benar, maka faktor tadi akan bernilai kecil sehingga akan memperkecil tingkat kepercayaan kita pada hipotesis H. Dengan menggunakan inferensi Bayes, dapat ditentukan berapa banyak bukti yang didapatkan untuk mengubah tingkat kepercayaan terhadap suatu hipotesis.

$P(H | E)$ bisa diubah menjadi sebuah fungsi dari H, dengan membuat E menjadi konstan. Fungsi yang demikian adalah fungsi kesamaan, di mana fungsi tersebut hanya memiliki satu peubah H, dengan E menjadi parameter saja. Perbandingan dua fungsi kesamaan disebut rasio kesamaan, dilambangkan dengan Λ . Persamaannya adalah

$$\Lambda_E = \frac{L(H|E)}{L(\neg H|E)} = \frac{P(E|H)}{P(E|\neg H)},$$

dari persamaan tersebut didapatkan bahwa

$$P(E) = P(E|H)P(H) + P(E|\neg H)P(\neg H)$$

Maka, kita bisa menulis ulang persamaan Bayes di atas menjadi

$$P(H|E) = \frac{P(E|H)P(H)}{P(E|H)P(H) + P(E|\neg H)P(\neg H)} = \frac{\Lambda_E P(H)}{\Lambda_E P(H) + P(\neg H)}$$

Kemudian kita bisa menggunakan fungsi identitas

$$P(\neg H) = 1 - P(H)$$

Untuk mengubah $P(H | E)$ menjadi fungsi dari $P(H)$ dan Λ_E (bisa didapat dari perhitungan langsung dari bukti yang ada) saja. Caranya adalah dengan menggunakan dua buah bukti sekaligus untuk langsung menghitung $P(H | E)$ secara berturut-turut. Rumusnya adalah

$$P(H|E_1 \cap E_2) = \frac{P(E_1|H)P(E_2|H)P(H)}{P(E_1|H)P(E_2|H)P(H) + P(E_1|\neg H)P(E_2|\neg H)P(\neg H)}$$

dengan menggunakan rasio kesamaan, persamaan di atas dapat diubah menjadi

$$P(H|E_1 \cap E_2) = \frac{\Lambda_1 \Lambda_2 P(H)}{\Lambda_1 \Lambda_2 P(H) + P(\neg H)},$$

III. APLIKASI

A. Spam Filtering

Salah satu aplikasi dari inferensi Bayes adalah penggunaan *naive Bayes classifier* dalam *pattern recognition* untuk mengelompokkan dokumen-dokumen ke kelas-kelas tertentu. Contoh mudahnya adalah pengelompokkan setiap surel masuk ke dalam kelompok *spam* dan *non-spam*.

Untuk melakukan hal tersebut, bayangkan ada beberapa kelas dokumen yang bisa dimodelkan sebagai kumpulan kata-kata di mana di mana kata ke- i dari suatu dokumen terdapat di dokumen kelas C bisa dituliskan sebagai

$$p(w_i|C)$$

Kemudian, peluang bahwa dokumen tersebut adalah dokumen D, jika diketahui termasuk ke kelas C, adalah

$$p(D|C) = \prod_i p(w_i|C)$$

Yang harus kita cari adalah “berapa peluang bahwa dokumen itu berada di kelas C, jika diketahui, dokumen tersebut adalah dokumen D?” yang bisa ditulis sebagai

$$p(C|D)$$

Berdasarkan definisinya

$$p(D|C) = \frac{p(D \cap C)}{p(C)}$$

$$p(C|D) = \frac{p(D \cap C)}{p(D)}$$

Dengan menggunakan teorema Bayes, persamaan di atas dapat diubah menjadi sebagai berikut

$$p(C|D) = \frac{p(C)}{p(D)} p(D|C) \quad (1)$$

Pada kasus *spam filtering*, hanya ada dua kelas, *spam* dan *non-spam*. Karena itu, persamaannya adalah

$$p(D|S) = \prod_i p(w_i|S) \quad (2)$$

$$p(D|\neg S) = \prod_i p(w_i|\neg S) \quad (3)$$

Dengan menggabungkannya ke persamaan (1) di atas, didapatkan

$$p(S|D) = \frac{p(S)}{p(D)} \prod_i p(w_i|S)$$

$$p(\neg S|D) = \frac{p(\neg S)}{p(D)} \prod_i p(w_i|\neg S)$$

Jika keduanya dibandingkan

$$\frac{p(S|D)}{p(\neg S|D)} = \frac{p(S) \prod_i p(w_i|S)}{p(\neg S) \prod_i p(w_i|\neg S)}$$

$$\frac{p(S|D)}{p(\neg S|D)} = \frac{p(S)}{p(\neg S)} \prod_i \frac{p(w_i|S)}{p(w_i|\neg S)}$$

Rasio peluang $p(S|D) / p(\neg S|D)$ dapat ditulis dalam rasio kesamaan. Nilai $p(S|D)$ bisa didapat dari perhitungan $\log(p(S|D) / p(\neg S|D))$ berdasarkan pada pengamatan bahwa $p(S|D) + p(\neg S|D) = 1$. Dengan menggunakan logaritma pada persamaan di atas, didapat

$$\ln \frac{p(S|D)}{p(\neg S|D)} = \ln \frac{p(S)}{p(\neg S)} + \sum_i \ln \frac{p(w_i|S)}{p(w_i|\neg S)}$$

Dari situ bisa didapatkan nilai rasio peluangnya tanpa harus menggunakan cara di awal tadi.

Setelah didapatkan nilai tersebut, barulah akhirnya dokumen tersebut dapat dikelompokkan sebagai *spam* atau *non-spam* berdasarkan pada standarnya. Sebuah dokumen dikatakan *spam* jika

$$p(S|D) > p(\neg S|D)$$

atau

$$\ln \frac{p(S|D)}{p(\neg S|D)} > 0$$

IV. KESIMPULAN

1. Inferensi Bayes hanya membutuhkan sedikit *training data* untuk menentukan parameter rata-rata dan variansi yang dibutuhkan untuk membuat klasifikasi.
2. Penggunaan inferensi Bayes pada *pattern*

recognition tidak terbatas pada *spam filtering* saja.

3. Inferensi Bayes digunakan untuk menghitung peluang untuk penentuan keputusan pada kondisi ketidakpastian.
4. *Supervised learning* terkadang tidak efisien, karena proses ini harus mencapai dua tujuan yang terkadang bertentangan.
5. *Probabilistic pattern recognition* sangat baik untuk digunakan karena menghasilkan beberapa kemungkinan *label* untuk setiap *instance* dan juga nilai peluang masing-masing kemungkinan *label*.
6. Dengan menggunakan inferensi Bayes dan bukti yang cukup, akan sangat mudah untuk menentukan kebenaran suatu hipotesis.
7. Metode inferensi bisa melenceng jauh dari kebenaran, karena nilai tingkat kebenaran yang pertama diestimasi tanpa ada bukti apapun.

V. ACKNOWLEDGMENT

Terima kasih kepada Allah SWT, yang telah menciptakan penulis ke dunia ini dan selalu menjaga penulis hingga bisa terselesaikannya makalah ini. Tidak lupa terima kasih penulis sampaikan kepada junjungan Rasulullah SAW, yang selalu menjadi panutan penulis dalam bertindak di dunia ini. Terima kasih juga penulis ucapkan kepada orangtua penulis, yang telah merawat dan membesarkan penulis sehingga sekarang penulis bisa berkuliah di ITB. Terima kasih kepada Pak Rinaldi Munir, yang telah dengan sabar mengajarkan materi Probabilitas dan Statistika dan pelajaran kehidupan yang berharga kepada penulis. Terima kasih kepada teman-teman seperjuangan STI 2009 yang selalu bersama dalam susah maupun senang.

REFERENCES

- [1] Wikipedia http://en.wikipedia.org/wiki/Data_Mining, tanggal akses 16 Desember 2010 pukul 10.00.
- [2] Wikipedia http://en.wikipedia.org/wiki/Pattern_Recognition, tanggal akses 16 Desember 2010 pukul 10.00.
- [3] Wikipedia http://en.wikipedia.org/wiki/Naive_Bayes_Classifier, tanggal akses 16 Desember 2010 pukul 10.00.
- [4] Wikipedia http://en.wikipedia.org/wiki/Bayes_Inference, tanggal akses 16 Desember 2010 pukul 10.00.

PERNYATAAN

Dengan ini saya menyatakan bahwa makalah yang saya tulis ini adalah tulisan saya sendiri, bukan saduran, atau terjemahan dari makalah orang lain, dan bukan plagiasi.

Bandung, 17 Desember 2010



Trilaksono Aribowo (18209015)