

Klasifikasi Pesan Biasa, Operator, *Spam*, dan *Debt Collector* Menggunakan *K-Nearest Neighbor*

Dian Christien Arisona¹⁾, Gusti Ngurah Adhi Wibowo²⁾, Siswanto³⁾, Gunawan⁴⁾

^{1,2,4}Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Halu Oleo
^{1,2,4}Jl. H.E.A. Mokodompit Kampus Hijau Bumi Tridharma, Kel. Anduonohu, Kec. Kambu, Kota Kendari, Kode Pos 93232

³Departemen Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Hasanuddin

³Jl. Perintis Kemerdekaan km. 10 Kec. Tamalanrea, Kode Pos 90245

E-mail: darisona@uho.ac.id¹⁾, gnawibawa@gmail.com²⁾, siswanto@unhas.ac.id³⁾, gunawan@uho.ac.id⁴⁾

Abstrak – Penelitian ini menerapkan metode klasifikasi *K-Nearest Neighbor* (KNN) untuk memprediksi kategori pesan yang merupakan pesan biasa, pesan *spam*, pesan operator, serta pesan *debt collector*. KNN merupakan salah satu algoritma klasifikasi yang biasa digunakan untuk klasifikasi teks, prediksi dilakukan dengan memperhatikan jarak antar objek pengamatan. Data yang merupakan pesan teks yang dikumpulkan dari SMS, *whatsapp*, serta *email* tentunya membutuhkan preproses *casefolding*, *stemming*, *tokenizing*, serta *stopwords* terlebih dahulu agar dapat di modelkan dengan metode KNN. Hasil penelitian menunjukkan akurasi pada data uji yang diperoleh yaitu sebesar 93% dan jika fokus pada kategori pesan *debt collector* diperoleh *recall* pada data uji sebesar 83%. Penelitian ini diharapkan dapat dikembangkan lebih lanjut agar dapat diterapkan pada aplikasi untuk mengenali kategori pesan yang berasal dari *debt collector* sehingga mengurangi rasa tidak nyaman yang dirasakan oleh korban.

Kata Kunci: *k-nearest neighbor*, klasifikasi teks, *debt collector*

Abstract – This research implements a *K-Nearest Neighbor* (KNN) classifier to predict messages that recognized as ordinary messages, operator messages, spam messages, and debt collector messages. KNN is one of the classification algorithms that can be used to do a text classification, the prediction is made with consideration of distances between the object of observations. The data is messages that have been collected from SMS, whatsapp, and email therefore preprocessing using casefolding, stemming, tokenizing, and stopwords is necessary to do a modelling using KNN methods. The results of this research showed that the accuracy achieved from the training set was 93% and if we just focus on the messages that classify as messages from debt collector then recall score from the testing set was 83%. This research is expected for further improvement and can be applied to recognizing messages from debt collector so that the victim can feel more comfortable.

Keywords: *k-nearest neighbor*, text classification, *debt collector*

PENDAHULUAN

Teknologi dimasa kini membawa pengaruh besar bagi kehidupan manusia terutama teknologi informasi yang berkembang sangat pesat. Perkembangan teknologi informasi ini menawarkan berbagai kemudahan dan keuntungan dalam menjalankan berbagai aktivitas. Saat ini di Indonesia *Financial Technology* atau *Fintech* berjenis peer-to-peer lending sedang naik daun, khususnya pinjaman *online* karena terbukti banyak peminatnya. *Fintech Lending* atau pinjaman berbasis teknologi informasi adalah satu di antara inovasi pada bidang keuangan dengan pemanfaatan teknologi yang memungkinkan pemberi pinjaman dan penerima pinjaman melakukan transaksi pinjam meminjam tanpa harus bertemu langsung.

Fintech Lending disebut juga dengan pinjaman *online* dan peningkatan layanan dibidang industri

keuangan merupakan salah satu bentuk dan fungsi dari *fintech*. Pinjaman *Online* merupakan suatu fasilitas pinjaman uang oleh penyedia jasa keuangan yang terintegrasi dengan teknologi informasi, mulai dari proses pengajuan, persetujuan hingga pencairan dana dilakukan secara *online* atau melalui konfirmasi SMS dan/atau telepon. Adapun cara kerja Pinjaman *online* ialah penyelenggara hanya berperan sebagai perantara yang mempertemukan pemberi pinjaman dan penerima pinjaman. Dalam keberadaannya, saat ini sudah banyak pinjaman *online* yang terdaftar di OJK. Walaupun ada banyak juga pinjaman *online* yang beroperasi tanpa pengawasan dan izin dari Otoritas Jasa Keuangan (OJK). Hal inilah yang dikenal sebagai pinjaman *online* ilegal. Praktik pinjaman *online* (pinjol) ilegal merajalela di sejumlah kota dalam beberapa tahun terakhir ini. Sebagian besar kasusnya masyarakat terjerat bunga tinggi yang ditawarkan pinjol ilegal.

Masalah muncul ketika jatuh tempo konsumen tidak bisa membayar tagihan, maka penagihan akan dialihkan kepada pihak ketiga yaitu *debt collector*. Media yang digunakan oleh *debt collector* untuk melakukan penagihan dan ancaman tersebut dapat dilakukan melalui panggilan telepon, mengirim pesan teks, serta mendatangi rumah atau kantor konsumen. Ironisnya *debt collector* memperoleh akses atas data yang terdapat pada ponsel konsumen termasuk foto pribadi di galeri, sosial media, aplikasi transportasi dan belanja *online*, email, bahkan supaya pinjaman cepat disetujui dan dicairkan konsumen dengan terpaksa memberikan nomor IMEI. Lebih buruknya lagi konsumen mengalami teror yang tidak wajar (ditelpon saat tengah malam), diancam, baik lewat telepon maupun pesan singkat, pelecehan seksual secara verbal dan *cyber bullying* dengan cara mengintimidasi dengan menyebar data dan foto konsumen kepada orang yang ada dalam daftar kontak konsumen disertai kata-kata yang mendiskreditkan. Penagihan juga dilakukan kepada keluarga, teman, rekan kerja, dan saudara sehingga mengganggu hubungan keluarga dan hubungan sosial. Hal tersebut menimbulkan trauma, stress, depresi, gelisah (*anxiety*), tidak fokus bekerja, dan kehilangan kepercayaan diri bahkan sampai bunuh diri. Lebih parahnya ada konsumen kehilangan pekerjaan akibat penagihan yang dilakukan kepada atasannya di tempatnya bekerja. Berdasarkan data dari OJK sejak 2019-2021, terdapat 19.711 pengaduan masyarakat terkait ulah pinjol ilegal ini. Sebanyak 9.270 (47,03 %) tergolong pelanggaran berat. Sedangkan, 10.441 pengaduan terkait pelanggaran ringan/ sedang. Bentuk pelanggaran-pelanggaran berat yang paling banyak diadukan masyarakat, antara lain, pencairan pinjaman tanpa persetujuan pemohon, ancaman penyebaran data pribadi, penagihan kepada seluruh kontak telepon genggam dengan teror/intimidasi, dan penagihan dengan kata-kata kasar dan pelecehan seksual.

Salah satu media yang digunakan *debt collector* untuk melakukan penagihan dan ancaman adalah melalui pesan teks. Pesan teks tersebut dapat dikirimkan melalui SMS (*Short Message Service*), *Whatsapp*, serta *Email*. Saat ini telah banyak aplikasi bahkan fitur bawaan dari telepon genggam yang dapat mengkategorikan pesan spam, operator, dan pesan biasa. Pesan spam mengandung pesan yang tidak diinginkan atau tidak diminta, termasuk iklan, penipuan dan lain sebagainya. Pesan operator

mengandung pesan yang tidak diminta tetapi dalam konteks iklan, penawaran, dan informasi. Pesan biasa mengandung pesan yang merupakan percakapan antara dua orang atau lebih. Adapun pesan-pesan penagihan dan ancaman yang dikirimkan oleh *debt collector* biasanya masuk ke dalam kategori pesan spam atau pesan biasa. Untuk meminimalisir ketidaknyamanan yang disebabkan oleh pesan tagihan dan ancaman dari *debt collector*, maka perlu dilakukan penyaringan pesan *debt collector* dengan cara mengklasifikasikan pesan *debt collector* menggunakan suatu metode untuk memperoleh keakuratan hasil prediksi yang optimal.

Klasifikasi merupakan suatu teknik untuk menilai objek data serta mengelompokkan objek berdasarkan atribut – atribut atau ciri objek ke dalam salah satu kategori yang telah didefinisikan. Klasifikasi melakukan pembelajaran model berdasarkan data latih yang telah di berikan label atau kelas target.

Beberapa penelitian terdahulu terkait dengan klasifikasi pesan spam telah dilakukan oleh Putera dkk. dalam penelitian tentang Klasifikasi Sms Spam Menggunakan Algoritma K-Nearest Neighbor. Kemudian Fitriyanto dan Saifudin membahas klasifikasi e-mail spam menggunakan metode K-Nearest Neighbor. Berdasarkan penelitian – penelitian yang dilakukan sebelumnya dengan tujuan untuk mengklasifikasikan pesan spam, maka pada penelitian ini akan difokuskan untuk mengidentifikasi pesan yang bersumber dari SMS, *whatsapp*, serta *email* yang merupakan pesan biasa, pesan spam, pesan operator, serta pesan *debt collector* dengan menggunakan algoritma *K-Nearest Neighbor* (KNN).

METODOLOGI PENELITIAN

Pengumpulan Data

Data yang digunakan adalah data yang dikumpulkan oleh peneliti melalui pesan *Whatsapp*, SMS, dan *Email*. Dataset terdiri dari dua set: pesan teks dan klasifikasi yang telah dilakukan secara manual oleh peneliti. Total data pesan teks yang digunakan adalah sebanyak 1392 pesan. Jumlah pesan teks pada masing-masing kategori dapat dilihat pada Tabel 1.

Tabel 1 Rincian Kategori Pesan Teks

No	Kategori Pesan	Jumlah
1	Pesan Biasa	570
2	Pesan Operator	423
3	Pesan <i>Spam</i>	343

4	Pesan <i>Debt Collector</i>	56
	Total	1392

Berdasarkan Tabel 1 terlihat bahwa sebaran data pada masing-masing kategori pesan teks tidak seimbang. Kategori pesan biasa memiliki jumlah paling banyak yaitu sebanyak 570 pesan, sedangkan kategori pesan *debt collector* memiliki jumlah paling sedikit yaitu sebanyak 50 pesan.

Adapun contoh pesan teks pada masing-masing kategori dapat dilihat pada Tabel 2.

Tabel 2 Contoh Pesan Teks

No	Kategori Pesan	Jumlah
1	yahh masih lama ya, urgent ini wkwk GRATIS 10GB! Bagi yg blm mengganti kartu SIM menjadi SIM 4G, tukarkan	Pesan Biasa
2	skrg di gerai IndosatOoredoo terdekat dan nikmati GRATIS 10GB di jaringan 4G.	Pesan Operator
3	3 RAMADHAN Selamat Anda Pemenang Rp.100jt. PIN CODE 7Y7R8K9Z Info: www.hadiah-3ramadhan.blogspot.com	Pesan Spam
4	maksud nya bagaimana tagihan nya di diemin aja ?	Pesan <i>Debt Collector</i>

K-Nearest Neighbor (KNN)

K-Nearest Neighbor merupakan metode klasifikasi berbasis *instance* (contoh) dimana akan dihitung kesamaan antara data uji dengan data latih yang mempertimbangkan nilai kesamaan tertinggi sejumlah k (Zheng *et al.*, 2015). Algoritma K-Nearest Neighbor (KNN) adalah sebuah metode untuk melakukan klasifikasi terhadap objek yang berdasarkan dari data pembelajaran yang jaraknya paling dekat dengan objek tersebut. Dimana kelas yang paling banyak muncul yang nantinya akan menjadi kelas hasil dari klasifikasi tentang analisis penelitian dan temuan-temuan terbaru yang ditemukan dalam penelitian, kajian atau hasil percobaan/eksperimen dan analisis

Preproses Data

Preproses merupakan tahap proses awal terhadap teks untuk mempersiapkan teks tersebut menjadi data yang dapat digunakan pada proses berikutnya. Sekumpulan karakter yang memiliki makna (teks)

harus dipecah menjadi unsur yang lebih berarti (Feldman dan Sanger, 2006). Pada tahapan ini mencangkup langkah – langkah sebagai berikut :

1. Case Folding

Proses *case folding* merupakan tahapan yang digunakan untuk mengubah setiap huruf pada kata menjadi bentuk yang standar, menghilangkan angka serta tanda baca, menghilangkan *whitespace* (karakter kosong), menghilangkan kalimat yang tidak digunakan dan menangani bentuk kata *slangs* atau singkatan menjadi kata aslinya berdasarkan *dictionary*.

2. Stemming

Stemming merupakan proses ekstraksi atau normalisasi sebuah kata untuk mencari kata dasar (*root word*) berdasarkan hasil proses filtering dengan menghilangkan imbuhan *affixes* (semua imbuhan), *suffix* (imbuhan akhiran), *prefix* (imbuhan awalan) dan *confixes* (kombinasi imbuhan awalan dan akhiran).

3. Tokenizing

Tokenizing adalah proses pemisahan teks menjadi potongan-potongan yang disebut sebagai token untuk kemudian di analisa. Kata, angka, simbol, tanda baca dan entitas penting lainnya dapat dianggap sebagai token.

4. Stopword

Stopword merupakan proses *filtering* atau menghilangkan kata – kata yang tidak memiliki arti penting. Pada setiap term yang terdapat pada proses tokenisasi akan dicocokkan ke dalam daftar kata *stopword* yang merupakan *dictionary* (kamus data) atau kumpulan kata yang tidak memiliki arti penting yang telah ditentukan sebelumnya.

Evaluasi

Evaluasi performa dari klasifikasi dengan menggunakan KNN yang dilakukan di penelitian ini ditampilkan dalam hasil pengukuran dengan menghitung akurasi, *recall*, dan *precision*. Nilai akurasi digunakan untuk mengukur ketepatan prediksi yang dihasilkan. Nilai *precision* mengukur perbandingan prediksi positif yang benar (*true positif*) terhadap total prediksi positif. Nilai *recall* mengukur perbandingan prediksi positif yang benar (*true positif*) terhadap semua prediksi di kelas aktual (Han, *et al.*, 2012). Berikut ini merupakan perhitungan untuk evaluasi performa:

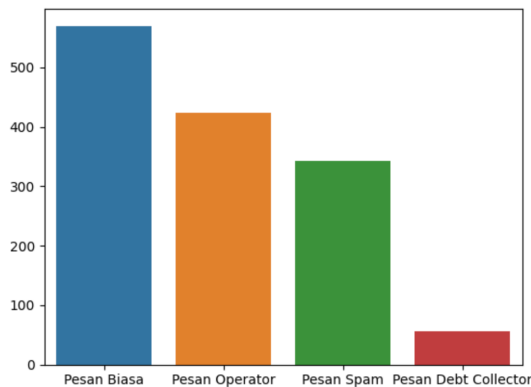
$$Akurasi = \frac{\sum true\ positif + \sum true\ negatif}{Jumlah\ Data} \quad (1)$$

$$Presisi = \frac{\sum true\ positif}{\sum true\ positif + \sum false\ positif} \quad (2)$$

$$Recall = \frac{\sum true\ positif}{\sum true\ positif + \sum false\ negatif} \quad (3)$$

HASIL DAN PEMBAHASAN

Pada penelitian ini proses pelatihan dilakukan dengan menggunakan *software python*. Gambaran mengenai data dapat dilihat pada Gambar 1.



Gambar 1 Jumlah Pesan Teks per Kategori

Berdasarkan hasil eksplorasi data pesan teks, maka dapat disimpulkan total data pada setiap jenisnya memiliki data yang beragam atau tidak seimbang (*Imbalance*). Jenis Pesan Biasa memiliki total data sebanyak 570, jenis Pesan Operator memiliki total data sebanyak 423, jenis Pesan Spam memiliki total data sebanyak 343, dan jenis Pesan Debt Collector memiliki total data sebanyak 56.

Sebelum masuk kedalam pengolahan data, terlebih dahulu dilakukan preproses terhadap data. Hasil setelah dilakukan *Case Folding* dapat dilihat pada Tabel 3.

Tabel 3 Pesan Teks Setelah *Case Folding*

No	Kategori Pesan
1	yahh masih lama ya urgent ini wkwk gratis 10gb bagi yg blm mengganti kartu
2	sim menjadi sim 4g tukarkan skrg di gerai indosatooredoo terdekat dan nikmati gratis 10gb di jaringan 4g
3	3 ramadhan selamat anda pemenang rp100jt pin code 7y7r8k9z info wwwhadiah3ramadhanblogspotcom
4	maksud nya bagaimana tagihan nya di diemin aja

Setelah dilakukan *case folding*, selanjutnya akan dilakukan proses *stemming* yang hasilnya dapat dilihat pada Tabel 4.

Tabel 4 Pesan Teks Setelah *Stemming*

No	Kategori Pesan
1	yahh masih lama ya urgent ini wkwk

- 2 gratis 10gb bagi yg blm mengganti kartu sim menjadi sim 4g tukarkan skrg di gerai indosatooredoo terdekat dan nikmati gratis 10gb di jaringan 4g
- 3 Pesan resmi selamat no simcard anda mdptkan hadiah cekrp100jt dari tri care pin7y7r8k9z info klik www3blogspotcom
- 4 maksud nya bagaimana tagihan nya di diemin aja

Selanjutnya akan dilakukan proses *tokenizing* yang hasilnya dapat dilihat pada Tabel 5.

Tabel 5 Pesan Teks Setelah *Tokenizing*

No	Kategori Pesan
1	yahh,masih,lama,ya,urgent,ini,wkwk gratis,10gb,bagi,yg,blm,mengganti,kartu,si
2	m,menjadi,sim,4g,tukarkan,skrg,di,gerai,in dosatooredoo,terdekat,dan,nikmati,gratis,10 gb,di,jaringan,4g
3	Pesan,resmi,selamat,no,simcard,anda,mdpt kan,hadiah,cekrp100jt,dari,tri,care,pin7y7r8 k9z,info,klik,www3blogspotcom
4	Maksud,nya,bagaimana,tagihan,nya,di,diemin,aja

Berdasarkan Tabel 5 dapat diperhatikan bahwa setiap kata dalam kalimat telah dipisahkan dengan sebuah koma. Selanjutnya akan dilakukan proses *stopwords* yang hasilnya dapat dilihat pada Tabel 6.

Tabel 6 Pesan Teks Setelah *Stopwords*

No	Kategori Pesan
1	yahh,masih,lama,ya,urgent,ini,wkwk gratis,10gb,bagi,yg,blm,mengganti,kartu,si
2	m,menjadi,sim,4g,tukarkan,skrg,di,gerai,in dosatooredoo,terdekat,dan,nikmati,gratis,10 gb,di,jaringan,4g
3	pesan,resmi,selamat,no,simcard,mdptkan,ha diah,cek,rp100juta,dr,tri,care,pin,7y7r8k9z,i nfo,klik, www3blogspotcom
4	nya,itikad,bayar,tagih,nya,jam,gin,tagih,bay ar

Berdasarkan Tabel 6 dapat diperhatikan bahwa setiap kata dalam kalimat telah dipisahkan dengan sebuah koma dan telah dihilangkan beberapa karakter atau kata yang telah di list. Beberapa kata yang termasuk dalam daftar stopwords adalah yang, di, ke, dari, adalah, dan, atau, dan lain sebagainya.

Selanjutnya akan dilakukan pelatihan pada data yang telah di preproses dengan menggunakan algoritma KNN. Adapun perbandingan antara data latih dan data uji yang akan digunakan adalah 90:10, sehingga data latih yang digunakan berjumlah 1252 pesan teks dan data uji sebanyak 140 pesan teks.

Hasil klasifikasi pada data latih dengan beberapa skenario berbeda yaitu dengan *casefolding-tokenizing*, *stemming-tokenizing*, *stopwords-tokenizing*, serta dengan menggunakan *casefolding-stemming-stopwords-tokenizing* sekaligus. Perbandingan antara skenario-skenario tersebut dapat dilihat pada Tabel 7.

Tabel 7 Perbandingan Skenario Klasifikasi KNN pada Data Latih

No	Skenario	Recall	Presisi	Akurasi
1	KNN dengan <i>casefolding-tokenizing</i>	0.54	0.96	0.83
2	KNN dengan <i>stemming-tokenizing</i>	0.56	0.97	0.80
3	KNN dengan <i>stopwords-tokenizing</i>	0.66	0.94	0.84
4	KNN dengan <i>casefolding-stemming-stopwords-tokenizing</i>	0.92	0.98	0.97

Berdasarkan Tabel 7 terlihat hasil klasifikasi pada data latih dengan beberapa skenario berbeda dan hasil terbaik adalah dengan menggunakan semua preprosesing dengan akurasi sebesar 97%, yang artinya dari total 1252 pesan teks terdapat 1214 pesan teks yang diprediksi sesuai dengan kategori aslinya dan sisanya salah prediksi. *Presisi* pada kategori pesan *debt collector* sebesar 98%. Kemudian *recall* pada kategori pesan *debt collector* sebesar 92%. Selanjutnya, hasil uji coba menggunakan data latih dapat dilihat pada Tabel 8.

Tabel 8 Perbandingan Skenario Klasifikasi KNN pada Data Uji

No	Skenario	Recall	Presisi	Akurasi
1	KNN dengan <i>casefolding-tokenizing</i>	0.17	0.50	0.69

2	KNN dengan <i>stemming-tokenizing</i>	0.17	0.33	0.64
3	KNN dengan <i>stopwords-tokenizing</i>	0.33	0.67	0.71
4	KNN dengan <i>casefolding-stemming-stopwords-tokenizing</i>	0.83	100	0.93

Berdasarkan Tabel 8 terlihat hasil klasifikasi pada data uji dengan beberapa skenario berbeda dan hasil terbaik adalah dengan menggunakan semua preprosesing dengan akurasi sebesar 93%, yang artinya dari total 140 pesan teks terdapat 130 pesan teks yang diprediksi sesuai dengan kategori aslinya dan sisanya salah prediksi. *Presisi* pada kategori pesan *debt collector* sebesar 100%. Kemudian *recall* pada kategori pesan *debt collector* sebesar 83%.

KESIMPULAN

Berdasarkan penelitian dengan berbagi skenario preproses yang berbeda, diperoleh hasil akurasi data latih-uji sebesar 97%-93% hal tersebut menunjukkan bahwa model KNN dengan menggunakan *casefolding*, *stemming*, *stopwords*, serta *tokenizing* sudah *goodfit*, terlihat dari selisih akurasi antra data latih dan data uji sebesar 4%.

Jika fokus penelitian berada pada kategori pesan *debt collector* maka dengan nilai *recall* pada data latih-uji sebesar 92%-83% masih tergolong *overfit*, dapat dilihat dari selisih *recall* antara data latih dan data uji sebesar 9%. Meskipun masih tergolong *overfit* namun ketepatan model KNN dalam memprediksi data baru yang kategori aslinya adalah pesan *debt collector* masih tergolong tinggi yaitu 83%. Nilai tersebut menunjukkan bahwa dari total 6 pesan teks yang kategori aslinya adalah pesan *debt collector*, terdapat 5 pesan teks yang sudah diprediksi dengan tepat sebagai pesan *debt collector* dan sisanya sebanyak 1 pesan teks yang kategori aslinya merupakan pesan *debt collector* gagal diprediksi sebagai pesan *debt collector* melainkan diprediksi sebagai kategori pesan lainnya.

DAFTAR PUSTAKA

- Arvante, J.Z.Y. (2022). Dampak Permasalahan Pinjaman Online dan Perlindungan Hukum Bagi Konsumen Pinjaman Online. 2, pp. 73-80.
- Feldman, R. dan Sanger, J., (2006). *Advanced Approaches in Analyzing Unstructured Data*. [online] United States of America by Cambridge University Press, New Yor: Cambridge University Press. Tersedia di: <<http://www.cambridge.org/9780521836579>>.
- Fitriyanto, A., Saifudin, I. (2019). Klasifikasi E-mail Spam Menggunakan Metode K-Nearest Neighbor. 1-9
- Han, J., Pei, J., & Kamber, M. (2011). *Data mining: concepts and techniques*. Elsevier.
- Putera , A.W., Suriati, Lestari, Y.D. (2023). Klasifikasi Sms Spam Menggunakan Algoritma K-Nearest Neighbor. 5(1), pp. 43-55.
- Zheng, W., Wang, H., Ma, L. dan Wang, R. (2015). An Improved k-Nearest Neighbor Classification Algorithm Using Shared Nearest Neighbor Similarity. 26(10), pp.133–137.