

PENERAPAN MANAJEMEN RISIKO PADA DATA SIMULASI PERBANKAN MENGGUNAKAN METODE LOGISTIC REGRESSION

IMPLEMENTATION OF RISK MANAGEMENT ON BANKING SIMULATION DATA USING THE LOGISTIC REGRESSION METHOD

**Ahmad Rhandy Irsandha^{1*}, Ahmad Tijani Noor², Bryan Endo Raldie³,
Reza Ghulam Akmal⁴, Alvianus Kristian Sumual⁵**

¹⁻⁵Institut Teknologi Kalimantan

***Email Correspondence: 17231003@student.itk.ac.id**

Abstract

Credit risk is one of the most significant risks affecting banking financial stability. Debtors' inability to meet payment obligations can increase non-performing loans and impact the health of bank assets. Therefore, an analytical approach capable of predicting potential defaults more accurately and measurably is needed. This study aims to apply a logistic regression model to classify credit risk using banking simulation data. The model was constructed by considering customer characteristic variables suspected of influencing payment smoothness status. The analysis results indicate that logistic regression is able to identify significant variables in determining risk status and quantitatively provide the probability of default. Furthermore, the model demonstrates a good level of accuracy in distinguishing at-risk and non-risk customers. These findings suggest that logistic regression can be an effective decision support tool in the creditworthiness assessment process and strengthen banking risk management.

Keywords: Credit Risk, Logistic Regression, Banking, Classification, Simulation Data.

Abstrak

Risiko kredit merupakan salah satu jenis risiko yang paling berpengaruh terhadap stabilitas keuangan perbankan. Ketidakmampuan debitur dalam memenuhi kewajiban pembayaran dapat meningkatkan kredit bermasalah dan berdampak pada kesehatan aset bank. Oleh karena itu, diperlukan pendekatan analitik yang mampu memprediksi potensi gagal bayar secara lebih akurat dan terukur. Penelitian ini bertujuan untuk menerapkan model Regresi Logistik dalam melakukan klasifikasi risiko kredit menggunakan data simulasi perbankan. Model dibangun dengan mempertimbangkan variabel karakteristik nasabah yang diduga berpengaruh terhadap status kelancaran pembayaran. Hasil analisis menunjukkan bahwa regresi logistik mampu mengidentifikasi variabel yang signifikan dalam menentukan status risiko dan memberikan probabilitas terjadinya gagal bayar secara kuantitatif. Selain itu, model menunjukkan tingkat akurasi yang baik dalam membedakan nasabah berisiko dan tidak berisiko. Temuan ini menunjukkan bahwa regresi logistik dapat menjadi alat pendukung keputusan yang efektif dalam proses penilaian kelayakan kredit dan penguatan manajemen risiko perbankan.

Kata Kunci: Risiko Kredit, Regresi Logistik, Perbankan, Klasifikasi, Data Simulasi.

PENDAHULUAN

Sektor perbankan memegang peranan penting dalam menjaga stabilitas ekonomi melalui kegiatan intermediasi, yaitu menyalurkan dana kepada masyarakat dalam bentuk kredit. Namun, pemberian kredit tidak terlepas dari potensi risiko gagal bayar yang dapat memengaruhi kualitas aset dan kesehatan keuangan bank. Ketika tingkat kredit bermasalah

meningkat, hal tersebut dapat menurunkan profitabilitas dan mengganggu stabilitas sistem keuangan. Oleh karena itu, proses penilaian kelayakan kredit menjadi langkah penting dalam penerapan manajemen risiko perbankan (Andreas & Verawati, 2025).

Seiring meningkatnya kompleksitas data dan kebutuhan akan proses evaluasi kredit yang lebih akurat, lembaga keuangan mulai beralih dari metode penilaian berbasis intuisi atau judgement manual menuju pendekatan analitik yang lebih terukur. Salah satu metode analisis yang banyak digunakan adalah Regresi Logistik, karena mampu memprediksi probabilitas terjadinya peristiwa biner, seperti status kredit lancar atau gagal bayar. Model ini tidak hanya berfungsi sebagai alat klasifikasi, tetapi juga dapat memberikan pemahaman mengenai variabel mana yang memiliki pengaruh paling kuat terhadap risiko kredit (Chung, 2020).

Penelitian ini bertujuan untuk menerapkan model Regresi Logistik dalam memprediksi risiko kredit berbasis data simulasi perbankan. Melalui pemodelan ini, diharapkan dapat terlihat bagaimana variabel-variabel tertentu, seperti pendapatan, rasio hutang, dan riwayat pembayaran, berkontribusi terhadap kemungkinan terjadinya gagal bayar. Selain itu, hasil penelitian ini diharapkan dapat memberikan gambaran mengenai sejauh mana regresi logistik mampu mendukung proses pengambilan keputusan kredit dan memperkuat praktik manajemen risiko kredit perbankan secara lebih objektif dan terukur (Titin et al., 2024)

METODE

Jenis penelitian ini adalah kuantitatif dengan pendekatan explanatory research. Populasi dalam penelitian ini adalah data kredit mikro/konsumer pada suatu bank umum di Indonesia. Sampel dipilih menggunakan metode *purposive sampling* dari data sekunder yang tersedia, dengan kriteria data yang lengkap untuk variabel-variabel yang diteliti.

Data yang digunakan merupakan data sekunder simulasi yang dibangun dengan karakteristik menyerupai portofolio kredit riil. Variabel dependen adalah status kredit (dikategorikan sebagai 0 = Lancar dan 1 = Macet). Variabel independen meliputi usia nasabah, tingkat pendapatan, jumlah pinjaman, tenor pinjaman, dan rasio debt-to-income (DTI).

Analisis data dilakukan dengan menggunakan model regresi logistik biner (*binary logistic regression*) untuk mengestimasi probabilitas gagal bayar. Pengolahan data dilakukan dengan bantuan perangkat lunak statistik. Uji kelayakan model meliputi uji *goodness-of-fit*, uji signifikansi parameter, serta interpretasi *odds ratio* untuk setiap variabel prediktor.

Di dalam regresi logistik, pada umumnya respons atau target bersifat dikotomis (terdiri dari dua kategori, yaitu 0 dan 1), maka distribusinya mengikuti distribusi Bernoulli dengan fungsi probabilitas sebagai berikut (Freyberger, 2004):

$$f(y_i) = \pi(x_i)^{y_i}(1 - \pi(x_i))^{(1-y_i)}$$

dengan $y_i = 0,1$, dan untuk

$$\pi(x) = \frac{\exp(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}{1 + \exp(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}$$

Persamaan tersebut kemudian diubah menggunakan transformasi logit $\pi(x)$ untuk mendapatkan fungsi $g(x)$ yang bersifat linier terhadap parameter-parameternya. Dengan begitu jadi lebih mudah dalam memprediksi dengan parameter regresi, yang dapat dirumuskan sebagai berikut:


$$g(x) = \ln \left[\frac{\pi(x)}{1 - \pi(x)} \right] = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p$$

Di beberapa kasus, pemetaan output regresi logistik untuk menjadi solusi dalam masalah klasifikasi biner, di mana tujuan utamanya adalah untuk memprediksi dengan benar salah satu dari dua label yang memungkinkan (misalnya, “Lancar” atau “Gagal Bayar”) (Google Developers, 2020).

Untuk memastikan model regresi logistik dapat menghasilkan output yang selalu berada antara 0 dan 1. Dalam kasus sebelumnya, fungsi *sigmoid*, yang dijelaskan sebagai berikut, menghasilkan output pada karakteristik yang sama (Google Developers, 2020):

$$y = \frac{1}{1 + e^{-z}}$$

Fungsi sigmoid akan menghasilkan grafik sebagai berikut (Google Developers, 2020):




Gambar 1. Fungsi Sigmoid (Google Developers, 2020)

Jika z mewakili output dari lapisan linier model yang dilatih menggunakan regresi logistik, maka $\text{sigmoid}(z)$ akan menghasilkan nilai (probabilitas) antara 0 dan 1. Dalam persamaan matematika, hal ini dijabarkan sebagai berikut:

$$y' = \frac{1}{1 + e^{-(z)}}$$

Berikut adalah fungsi *sigmoid* dengan menggunakan label dari machine learning:



Gambar 2. Output Logistic Regression (Google Developers, 2020)

HASIL DAN PEMBAHASAN

Dalam pemodelan risiko kredit ini, kita menggunakan lima fitur (variabel independen) untuk memprediksi satu target (variabel dependen). Fitur adalah atribut atau karakteristik dari nasabah yang kita gunakan sebagai input. Target adalah hasil yang ingin kita prediksi. Dalam kasus ini, variabel target kita adalah Status Kredit. Variabel ini bersifat biner, yang berarti hanya memiliki dua kemungkinan nilai: 0 untuk nasabah yang pembayarannya Lancar dan 1 untuk nasabah yang Gagal Bayar. Tujuan utama model regresi logistik adalah menghitung probabilitas seorang nasabah jatuh ke dalam kategori '1' (Gagal Bayar) berdasarkan fitur-fitur yang dimilikinya.

Fitur pertama yang digunakan adalah Usia (dalam tahun) dan Pendapatan (dalam juta Rupiah). Usia adalah variabel demografis standar yang digunakan untuk memprofilkan nasabah; stabilitas finansial dan riwayat kredit seringkali berkorelasi dengan usia. Pendapatan adalah salah satu indikator risiko paling fundamental. Ini secara langsung mengukur kapasitas atau kemampuan nasabah untuk menghasilkan dana guna membayar cicilan. Secara logis, semakin tinggi pendapatan, semakin besar kemampuan bayar, yang seharusnya menurunkan risiko kredit macet.

Selanjutnya, kita memiliki dua fitur yang mendefinisikan struktur pinjaman itu sendiri: Jumlah Pinjaman (dalam juta Rupiah) dan Tenor (dalam bulan). Jumlah Pinjaman menentukan besarnya eksposur (tingkat kerugian) yang dihadapi bank jika nasabah tersebut gagal bayar. Tenor, atau durasi pinjaman, memiliki dampak ganda: tenor yang lebih panjang (misal 60 bulan) memperkecil cicilan bulanan (sehingga meringankan beban), namun juga berarti bank terekspos pada ketidakpastian kondisi nasabah untuk jangka waktu yang lebih lama. Model akan belajar menimbang kedua aspek ini.

Terakhir, dan mungkin yang paling penting, adalah DTI Ratio (Debt-to-Income Ratio). Ini adalah rasio keuangan kunci yang membandingkan total pembayaran utang bulanan nasabah dengan pendapatan bulannya. Variabel ini adalah ukuran langsung dari beban finansial nasabah. Seorang nasabah dengan DTI 0.5 (atau 50%) berarti setengah dari gajinya sudah habis hanya untuk membayar utang. DTI yang tinggi adalah sinyal bahaya yang kuat, menunjukkan bahwa nasabah memiliki sedikit "ruang bernapas" secara finansial dan sangat rentan terhadap guncangan pendapatan, sehingga probabilitas gagal bayarnya pun meningkat drastis. Model akan sangat bergantung pada fitur ini untuk menilai kelayakan kredit.

Tabel 1. Data Simulasi Kredit Bank

No	Usia	Pendapatan (Juta)	Jumlah Pinjaman (Juta)	Tenor (Bulan)	DTI Ratio	Status Kredit
1	45	18	100	36	0.35	0
2	38	12	150	48	0.45	1
3	52	25	80	24	0.25	0
4	29	8	120	60	0.55	1
5	35	15	200	36	0.50	1
6	48	22	90	30	0.30	0
7	41	10	180	48	0.60	1
8	31	9	130	42	0.48	1
9	44	20	110	24	0.28	0
10	36	14	160	36	0.42	0
11	42	16	95	30	0.32	0
12	33	11	140	54	0.52	1
13	47	19	85	27	0.29	0
14	39	13	170	45	0.47	1
15	28	7	190	66	0.65	1
16	51	24	75	21	0.24	0
17	37	17	125	39	0.38	0
18	43	21	105	33	0.31	0
19	32	10	155	51	0.53	1
20	46	23	88	26	0.27	0
21	40	15	135	42	0.44	0
22	34	12	165	48	0.49	1
23	49	26	78	22	0.23	0
24	30	8	145	57	0.58	1
25	44	18	115	36	0.36	0
26	38	14	175	45	0.46	1
27	53	27	70	20	0.22	0
28	35	11	185	54	0.56	1
29	41	19	98	30	0.33	0
30	47	22	82	25	0.26	0
31	39	13	158	48	0.48	1

32	31	9	128	60	0.59	1
33	45	20	108	33	0.34	0
34	36	16	168	42	0.43	0
35	42	24	92	28	0.30	0
36	33	10	138	57	0.54	1
37	48	25	87	24	0.28	0
38	40	17	148	39	0.40	0
39	29	7	195	63	0.62	1
40	46	21	102	31	0.32	0
41	37	15	142	45	0.45	1
42	43	23	96	27	0.29	0
43	34	12	172	51	0.50	1
44	50	28	76	21	0.23	0
45	32	11	162	54	0.55	1
46	44	19	112	33	0.35	0
47	39	16	132	42	0.41	0
48	47	26	84	25	0.26	0
49	35	13	152	48	0.47	1
50	41	18	118	36	0.37	0

Tabel di atas memberikan data asumsi para sebanyak 50 nasabah dengan usia, pendapatan, jumlah pinjaman, tenor, DTI Ratio, dan status kredit yang ada. Proses analisa menggunakan bantuan *google colab* yang dimulai dengan mengimport data pada tabel. Pustaka Pandas digunakan sebagai tulang punggung untuk manipulasi data. Fungsinya adalah untuk membaca *dataset* (misalnya dari file CSV) ke dalam sebuah struktur data yang disebut DataFrame, yang menyerupai tabel atau *spreadsheet*, sehingga memudahkan proses inspeksi dan pembersihan data. Tentu, ini adalah penjabaran ulang dari metodologi tersebut, di mana setiap langkah utama dirangkum ke dalam satu paragraf tunggal untuk alur penulisan yang lebih padat.

Langkah paling awal dalam analisis adalah mempersiapkan lingkungan kerja dengan mengimpor pustaka Python yang esensial. Pustaka Pandas (`'pd'`) dimuat untuk manipulasi data tabular (DataFrame), sementara dari *Scikit-learn* (`'sklearn'`), kita mengimpor `'train test split'` untuk validasi model, `'LogisticRegression'` sebagai algoritma inti, dan serangkaian *metrics* (seperti `'accuracy score'`, `'confusion matrix'`, dan `'classification report'`) untuk evaluasi. Pustaka *Numpy* (`'np'`) juga disertakan sebagai fondasi komputasi numerik, yang mendukung operasi pada *array* dan matriks.

Proses selanjutnya adalah memuat *dataset* dari file CSV ke dalam DataFrame Pandas. Langkah krusial dalam tahap preprocessing ini adalah menangani anomali data pada kolom `'DTI Ratio'`. Karena data ini terdeteksi sebagai teks (object) akibat penggunaan koma (',') sebagai pemisah desimal standar regional Indonesia maka dilakukan dua operasi: pertama,

mengganti semua karakter koma menjadi titik (`,`) menggunakan fungsi ``str.replace()``, dan kedua, mengonversi tipe data kolom tersebut menjadi angka (float) menggunakan ``astype(float)``. Ini memastikan data siap untuk diolah secara matematis oleh model.


Setelah data bersih, dilakukan pemisahan antara variabel independen (fitur) dan variabel dependen (target). Sebuah list bernama ``fitur`` didefinisikan untuk menampung nama-nama kolom prediktor, yaitu ``Usia``, ``Pendapatan (Juta)``, ``Jumlah Pinjaman (Juta)``, ``Tenor (Bulan)``, dan ``DTI Ratio``. Berdasarkan list ini, dibuatlah matriks fitur ``X`` yang berisi data dari kolom-kolom tersebut. Secara terpisah, variabel target ``y`` dibuat, yang hanya berisi satu kolom "jawaban" yang ingin diprediksi, yaitu ``Status Kredit`` (yang bernilai 0 untuk Lancar atau 1 untuk Gagal Bayar)

Untuk memastikan evaluasi model yang objektif, dataset dibagi menjadi dua himpunan terpisah: data latih dan data uji. Menggunakan fungsi ``train test split``, data ``X`` dan ``y`` dipecah dengan proporsi 70% untuk data latih (``X train``, ``y train``) dan 30% untuk data uji (``X test``, ``y test``), yang diatur melalui parameter ``test size=0.3``. Parameter ``random state=42`` ditetapkan untuk menjamin reproduktibilitas penelitian; ini memastikan bahwa proses pengacakan data akan selalu menghasilkan pembagian yang sama setiap kali skrip dijalankan, sehingga hasil model dapat diverifikasi secara konsisten.

Pada tahap inti *machine learning* ini, model Regresi Logistik dibangun. Pertama, sebuah "objek" model yang masih kosong diinisialisasi dari kelas ``LogisticRegression``. Selanjutnya, perintah ``fit(X_train, y_train)`` dieksekusi. Perintah ini menginstruksikan model untuk "belajar" dari data latih dengan cara menganalisis hubungan matematis antara fitur-fitur di ``X_train`` dan jawaban yang sesuai di ``y_train``. Model akan mencari pola dan menghitung koefisien logistik yang paling optimal untuk memprediksi probabilitas status kredit.


Setelah dilatih, kinerja model dievaluasi menggunakan data uji yang belum pernah dilihat sebelumnya. Model diminta membuat prediksi (``y pred``) pada data ``X test``. Prediksi ini kemudian dibandingkan dengan jawaban sebenarnya (``y test``) menggunakan beberapa metrik. ``accuracy score`` dihitung untuk melihat persentase tebakan benar secara keseluruhan. Lebih penting lagi, ``confusion_matrix`` dicetak untuk menganalisis tipe kesalahan secara rinci (True Positive, False Negative, dll.), dan ``classification report`` ditampilkan untuk meninjau *Precision* dan *Recall*, yang krusial untuk memahami efektivitas model dalam menangkap risiko (kasus Gagal Bayar).

Langkah terakhir mendemonstrasikan penggunaan praktis model untuk *scoring* nasabah baru. Sebuah data fiktif (``data_baru``) disiapkan dalam format yang sesuai. Alih-alih memprediksi kelas "0" atau "1" secara kaku, fungsi ``predict_proba()`` digunakan untuk mendapatkan keluaran yang lebih bernuansa, yaitu probabilitas. Hasilnya, seperti Probabilitas Nasabah Pertama: `[[5.49625385e-06 9.99994504e-01]]`. Probabilitas Nasabah Kedua: `[[9.99999978e-01 2.21343687e-08]]`, probabilitas pada nasabah pertama menunjukkan ke arah 1 yang artinya gagal bayar sebesar 99,99%. Sementara probabilitas pada nasabah kedua menunjukkan ke arah 0 yang artinya lancar sebesar 99,99%. Angka probabilitas inilah yang dalam praktiknya menjadi Risk Score, yang menjadi dasar kuantitatif bagi bank untuk mengambil keputusan persetujuan atau penolakan kredit.



Gambar 3. Visualisasi Logit pada Grafik Fungsi Sigmoid

Logit merupakan hasil transformasi dari probabilitas dalam model regresi logistik, yang bertujuan mengubah nilai probabilitas (antara 0 dan 1) menjadi bentuk linier yang dapat bernilai dari negatif tak hingga hingga positif tak hingga. Secara matematis, logit didefinisikan sebagai logaritma dari *odds* ($(p/(1-p))$), yaitu perbandingan antara peluang terjadinya suatu kejadian dengan peluang tidak terjadinya. Dalam regresi logistik, logit ini dimodelkan sebagai fungsi linier dari variabel-variabel input. Nilai logit inilah yang kemudian diubah kembali menjadi probabilitas menggunakan fungsi sigmoid. Koefisien regresi (β_1) menunjukkan seberapa besar pengaruh suatu variabel terhadap logit, dan secara eksponensial (e^{β_i}) menunjukkan perubahan *odds ratio*. Nilai logit positif besar akan menghasilkan probabilitas mendekati 1 (kejadian sangat mungkin terjadi), sedangkan nilai logit negatif besar akan menghasilkan probabilitas mendekati 0 (kejadian sangat tidak mungkin). Misalnya, pada grafik sigmoid yang ditunjukkan, Nasabah 1 memiliki logit 12.11 dengan probabilitas 1.00 artinya hampir pasti termasuk kategori “gagal bayar” sementara Nasabah 2 memiliki logit -17.63 dengan probabilitas 0.00 yang menunjukkan “lancar”. Dengan demikian, logit menjadi jembatan antara hubungan linier variabel input dan probabilitas hasil prediksi dalam regresi logistik.



Gambar 4. Confusion Matrix

Confusion matrix menunjukkan performa model klasifikasi dengan membandingkan hasil prediksi terhadap data aktual. Dalam kasus ini, terdapat dua kelas: Lancar (0) dan Gagal Bayar (1). Dari hasil yang ditampilkan, model berhasil memprediksi dengan cukup baik: terdapat 9 nasabah yang benar-benar lancar dan diprediksi lancar (True Negative), 5 nasabah yang benar-benar gagal bayar dan diprediksi gagal bayar (True Positive), serta hanya 1 nasabah yang seharusnya gagal bayar namun diprediksi lancar (False Negative). Tidak ada kesalahan prediksi pada nasabah lancar yang dikira gagal bayar (False Positive = 0). Berdasarkan nilai-nilai tersebut, model memiliki akurasi 93,3%, precision 100%, dan recall 83%, yang berarti model sangat akurat dan tidak pernah salah ketika memprediksi gagal bayar, meskipun masih melewatkan satu kasus gagal bayar. Secara keseluruhan, model ini sangat andal dalam mengenali nasabah yang lancar maupun gagal bayar, namun tetap perlu perhatian pada kasus gagal bayar yang terlewat agar sensitivitas model terhadap risiko bisa lebih optimal.

KESIMPULAN

Dari hasil analisis yang dilakukan, model *Logistic Regression* terbukti cukup membantu dalam menilai apakah seorang debitur berpotensi mengalami gagal bayar atau tidak. Dengan menggunakan data simulasi yang berisi informasi seperti pendapatan, jumlah pinjaman, rasio utang, serta riwayat pembayaran sebelumnya, model ini mampu memberikan gambaran yang jelas mengenai tingkat risiko kredit.

Model ini mampu memberikan gambaran yang jelas mengenai probabilitas risiko gagal bayar nasabah melalui pendekatan statistik yang terukur. Regresi logistik efektif mengubah variabel-variabel keuangan dan karakteristik nasabah menjadi nilai logit yang menggambarkan tingkat risiko secara linier, kemudian dikonversi menjadi probabilitas dengan fungsi sigmoid. Hasil evaluasi melalui confusion matrix menunjukkan bahwa model memiliki tingkat akurasi yang tinggi serta kemampuan klasifikasi yang baik dalam membedakan antara nasabah lancar dan gagal bayar. Dengan demikian, regresi logistik terbukti menjadi alat analisis yang relevan dan bermanfaat dalam mendukung proses pengambilan keputusan manajemen risiko perbankan, terutama dalam mengidentifikasi potensi kredit bermasalah sejak dini dan memperkuat strategi mitigasi risiko kredit secara lebih tepat sasaran.

DAFTAR PUSTAKA

- Andrian, A., & Verawati, I. (tahun tidak tersedia). *Analisis performa logistic regression dan random forest dalam klasifikasi kelayakan penerimaan kredit*. Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Amikom Yogyakarta.
- Costa e Silva, E., Lopes, I. C., Correia, A., & Faria, S. (tahun tidak tersedia). *A logistic regression model for consumer default risk*. CIICESI, ESTG, Politécnico do Porto.
- Mufida, E., Andriansyah, D., & Hertiana, H. (tahun tidak tersedia). *Customer churn prediction pada sektor perbankan dengan model logistic regression dan random forest*. Universitas Bina Sarana Informatika.
- Munir, M. M. (tahun tidak tersedia). *Pengembangan model credit risk scoring untuk pembiayaan di lembaga keuangan syariah* [Tesis master tidak dipublikasikan]. Universitas PTIQ Jakarta.
- Putra, H., & Rumini. (tahun tidak tersedia). *Comparative study of logistic regression, random forest, and XGBoost for bank loan approval classification*. Informatika, Universitas Amikom Yogyakarta.

Salamah, U. (tahun tidak tersedia). *Application of logistic regression methods to retinal damage detection on digital fundus images*. Faculty of Computer Science, Universitas Mercu Buana.

Yulianti, T., Cahyana, A. H., Komarudin, M., Mulyani, Y., & Septama, H. D. (2024). Penilaian pembayaran kredit dengan logistic regression dan random forest pada Home Credit. *Pseudocode*, *11*(2), 79–88.
<https://doi.org/10.33369/pseudocode.11.2.79-88>