

**PREDIKSI PENJUALAN MINUMAN KOPI MENGGUNAKAN
METODE *EXTREME LEARNING MACHINE* (ELM)**

SKRIPSI

**Oleh:
FARIDATUN NUR CHOLISA
NIM. 17650106**



**JURUSAN TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2021**

**PREDIKSI PENJUALAN MINUMAN KOPI MENGGUNAKAN
METODE *EXTREME LEARNING MACHINE* (ELM)**

SKRIPSI

Diajukan kepada:

**Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)**

Oleh:

**FARIDATUN NUR CHOLISA
NIM. 17650106**

**JURUSAN TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2021**

HALAMAN PERSETUJUAN

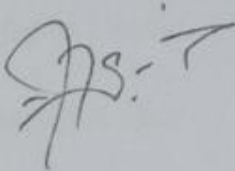
PREDIKSI PENJUALAN MINUMAN KOPI MENGGUNAKAN
METODE *EXTREME LEARNING MACHINE* (ELM)

SKRIPSI

Oleh:
FARIDATUN NUR CHOLISA
NIM. 17650106

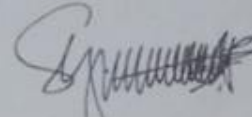
Telah Diperiksa dan Disetujui untuk Diuji
Tanggal : 10 Desember 2021

Dosen Pembimbing I



Khadijah Fahmi Hayati Holle, M.Kom
NIDT. 19900626201608012077


Dosen Pembimbing II



A'la Sya'iqi, M.Kom
NIP. 197712012008011007

Mengetahui,
Ketua Jurusan Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Fachrul Kurniawan, M.MT
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

PREDIKSI PENJUALAN MINUMAN KOPI MENGGUNAKAN METODE *EXTREME LEARNING MACHINE* (ELM)

SKRIPSI

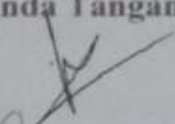

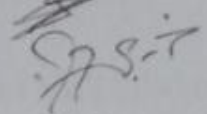
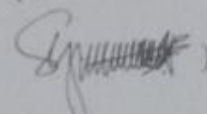
Oleh:
FARIDATUN NUR CHOLISA
NIM. 17650106

Telah Dipertahankan di Depan Dewan Penguji
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Sarjana Komputer (S.Kom)

Pada Tanggal: 10 Desember 2021

Susunan Dewan Penguji

Tanda Tangan

Penguji Utama	: <u>Irwan Budi Santoso, M.Kom</u> NIP. 19770103 201101 1 004	()
Penguji Kedua	: <u>Dr. Cahyo Crysdian</u> NIP. 19740424 200901 1 008	()
Sekretaris Penguji	: <u>Khadijah Fahmi H.H, M.Kom</u> NIDT. 19900626 20160801 2 077	()
Anggota Penguji	: <u>A'la Syauqi, M.Kom</u> NIP. 19771201 200801 1 007	()

Mengetahui,
Ketua Jurusan Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Dr. Fachrul Kurniawan, M.MT
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini :

Nama : Faridatun Nur Cholisa

NIM : 17650106

Fakultas : Sains dan Teknologi

Jurusan : Teknik Informatika

Judul Skripsi : Prediksi Penjualan Minuman Kopi Menggunakan Metode
Extreme Learning Machine (ELM)

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilalihan data, tulisan atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila di kemudian hari terbukti atau dapat dibuktikan Skripsi ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 10 Desember 2021
Yang membuat pernyataan,



Faridatun Nur Cholisa
NIM. 17650106

KATA PENGANTAR

Dalam perjalanan penulis menyelesaikan skripsi yang berjudul “Prediksi Penjualan Minuman Kopi Menggunakan Metode *Extreme Learning Machine* (ELM)” ini tak henti-hentinya mengucap rasa syukur karena diberikan kelancaran dan kemudahan. Skripsi ini telah berhasil diselesaikan oleh penulis atas bantuan dari beberapa pihak. Sehingga penulis ingin menyampaikan ucapan terimakasih kepada:

1. Khadijah Fahmi Hayati Holle, M.Kom yang telah memberikan ilmu yang bermanfaat bagi saya dan selalu mendukung di setiap langkah pengerjaan skripsi ini.
2. A’la Syauqi, M.Kom yang telah memberikan ilmu yang bermanfaat kepada saya.
3. Irwan Budi Santoso, M.Kom dan Dr. Cahyo Crysdiان selaku dosen penguji yang telah memberikan bimbingan serta saran pada skripsi ini.
4. Ayah dan Ibu yang selalu memberikan motivasi dan doa serta mendukung setiap langkah saya.
5. Seluruh teman-teman Unocore yang telah memberikan semangat, dukungan serta informasi yang bermanfaat kepada penulis ketika mengalami kesulitan.

Semoga karya ini dapat bermanfaat bagi teman-teman semua khususnya adik tingkat yang akan melakukan penelitian serupa. Semoga ilmu yang tertuang dalam tulisan ini dapat bermanfaat bagi generasi penerus bangsa.

Malang, 10 Desember 2021

Penulis

DAFTAR ISI

PREDIKSI PENJUALAN MINUMAN KOPI MENGGUNAKAN METODE <i>EXTREME LEARNING MACHINE</i> (ELM)	i
HALAMAN PERSETUJUAN	ii
HALAMAN PENGESAHAN.....	iii
PERNYATAAN KEASLIAN TULISAN	iv
KATA PENGANTAR	v
DAFTAR ISI.....	vii
DAFTAR GAMBAR	ix
DAFTAR TABEL.....	x
ABSTRAK	xii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Pernyataan Masalah.....	8
1.3 Batasan Masalahhh	8
1.4 Tujuan Penelitiann.....	8
1.5 Manfaat Penelitian.....	9
BAB II TINJAUAN PUSTAKA.....	10
2.1 Penjualan Minuman Janji Jiwa.....	12
2.2 Forecasting (Peramalan).....	13
2.3 Jaringan Saraf Tiruan (JST).....	13
2.3.1 Arsitektur Jaringan.....	16
2.3.2 Fungsi Aktivasi.....	19
2.4 Metode Extreme Learning Machine	21
2.4.1 Normalisasi Data	24
2.4.2 Proses Trainingg	26
2.4.3 Proses Testingg.....	28
2.4.4 Proses Denormalisasi Data	29
2.5 Evaluasi Pengukuran	29
2.5.1 Mean Absolute Percent Error (MAPE).....	30

BAB III METODOLOGI PENELITIAN.....	31
3.1 Desain Penelitian	31
3.2 Pengumpulan Data.....	32
3.3 Desain Sistem	32
BAB IV UJI COBA DAN PEMBAHASAN	39
4.1 Data Uji	39
4.2 Training	44
4.3 Testing	48
4.4 Hasil dan Analisis Pembahasan.....	51
4.4.1 Hasil dan Analisis Nilai Error Menggunakan Metode MAPE	51
4.4.2 Hasil dan Uji Coba Kombinasi Variasi Jumlah Fitur Data, Jumlah Hidden Neuron, dan Jumlah Epoch	53
4.4.3 Pembahasan Hasil dan Uji Coba Kombinasi Variasi Jumlah Fitur Data, Jumlah Hidden Neuron, dan Jumlah Epoch	54
BAB V PENUTUP.....	58
5.1 Kesimpulan.....	58
5.2 Saran	59
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1 Fungsi aktivasi Jaringan Saraf Tiruan Sumber : (Lesnussa, et al., 2015)	15
Gambar 2.2 Diagram jaringan lapisan tunggal (Single Layer Net)	17
Gambar 2.3 Diagram jaringan banyak lapisan (Multilayer Net).....	18
Gambar 2.4 Diagram jaringan lapisan kompetitif (Competitive Layer Net)	19
Gambar 2.5 Fungsi aktivasi sigmoid biner	20
Gambar 2.6 Fungsi aktivasi sigmoid bipolar	20
Gambar 2.7 Arsitektur jaringan metode ELM	23
Gambar 2.8 Algoritma metode Extreme Learning Machine (ELM).....	24
Gambar 3.1 Prosedur penelitian.....	31
Gambar 3. 2 Desain sistem prediksi.....	33
Gambar 3.3 Arsitektur jaringan metode ELM	34

DAFTAR TABEL

Tabel 4.1 Data penjualan bulan Juli 2020-Januari 2021	39
Tabel 4.2 Pembentukan Fitur	40
Tabel 4.3 Data Training	41
Tabel 4.4 Data Testing	42
Tabel 4.5 Nilai minimal dan maksimal data <i>training</i>	42
Tabel 4.6 Nilai minimal dan maksimal data testing.....	43
Tabel 4.7 Normalisasi data <i>training</i>	43
Tabel 4. 8 Normalisasi data testing.....	43
Tabel 4. 9 Nilai input weight (bobot awal)	45
Tabel 4.10 Nilai bias	45
Tabel 4.11 Hasil Hinit.....	45
Tabel 4.12 Hasil fungsi aktivasi sigmoid biner.....	46
Tabel 4.13 Hasil transpose data	46
Tabel 4. 14 Hasil perkalian Hx dengan HT	47
Tabel 4.15 Hasil invers	47
Tabel 4.16 Hasil <i>Moore-Penrose Generalized Invers</i>	47
Tabel 4.17 Hasil output weight	48
Tabel 4.18 Hasil <i>Hinit</i> proses <i>testing</i>	49
Tabel 4.19 Hasil fungsi aktivasi proses <i>testing</i>	49
Tabel 4.20 Hasil output layer (prediksi)	50
Tabel 4.21 Hasil denormalisasi data	51
Tabel 4.22 Hasil evaluasi nilai kesalahan (error).....	52

Tabel 4.23 Nilai rata-rata MAPE kombinasi variasi jumlah fitur data, jumlah hidden neuron, dan jumlah epoch	53
Tabel 4.24 Perbandingan data asli dan data prediksi	55

ABSTRAK

Cholisa, Faridatun Nur. 2021. **Prediksi Penjualan Minuman Kopi Menggunakan Metode *Extreme Learning Machine* (ELM)**. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing : (I) Khadijah Fahmi Hayati Holle, M.Kom (II) A'la Syauqi, M.Kom

Kata Kunci : *Jumlah Penjualan, Prediksi, Extreme Learning Machine* (ELM)

Tren minum kopi kekinian lagi diperbincangkan dibanyak kalangan. Khususnya kopi dengan cita rasa baru yaitu kopi susu creamy. Pebisnis di tanah air berlomba lomba untuk membuka kedai kopi dengan cita rasa yang unik. Namun, pada salah satu kedai kopi memiliki sistem pengelolaan penjualan yang kurang baik. Pendataan pasokan bahan baku diperkirakan secara manual. Pada saat pandemi, penjualan kopi menurun. Sehingga berdampak pada kualitas bahan baku yang terlalu lama disimpan. Kedai kopi tersebut membutuhkan perkiraan dalam perencanaan pemasokan bahan baku lebih baik. Oleh karena itu, perancangan sistem prediksi ini penting. Perencanaan yang efektif dan efisien membutuhkan sistem prediksi yang akurasiya baik. Metode ELM merupakan turunan dari jaringan saraf tiruan yang terdiri dari satu *hidden layer*. Metode ini memiliki keunggulan pada kecepatan waktu komputasinya dikarenakan algoritma dari metode ini tanpa melakukan *iterasi* dan menghasilkan *output* yang stabil. Nilai *bobot* dari metode turunan JST ini didapatkan secara *random* dan hasilnya diberikan solusi kuadrat kecil dengan melakukan fungsi *Moore-Penrose Generalized Invers*. Hasil uji coba sebanyak 8 kali dengan parameter yang digunakan yaitu perbandingan jumlah data *training* dan *testing* sebesar 90%:10% dan menggunakan fungsi aktivasi *sigmoid biner*. Didapatkan jumlah *fitur* terbaik yaitu 6 dan jumlah *hidden neuron* terbaik yaitu 3. Nilai kesalahan (*error*) dalam perhitungan *Mean Absolute Percentage Error* (MAPE) sebesar 5,6518%. Hasil dari pengujian tersebut dapat membuktikan bahwa penggunaan metode *Extreme Learning Machine* (ELM) dapat memprediksi jumlah penjualan minuman kopi menghasilkan *output prediksi* yang stabil serta mendapatkan jumlah penjualan minuman kopi dimasa yang akan datang sebagai acuan dalam pemasokan bahan baku.

ABSTRACT

Cholisa, Faridatun Nur. 2021. **Prediction of Coffee Beverage Sales Using the *Extreme Learning Machine (ELM) Method***. Theses. Department of Informatics, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University of Malang. Supervisor : (I) Khadijah Fahmi Hayati Holle, M.Kom (II) A'la Syauqi, M.Kom

Keyword : *Total Sales, Prediction, Extreme Learning Machine (ELM)*

The current trend of drinking coffee is being discussed in many circles. Especially coffee with a new taste, namely creamy milk coffee. Businessmen in the country are competing to open a coffee shop with a unique taste. However, one coffee shop has a poor sales management system. Data collection of raw material supply is estimated manually. During the pandemic, coffee sales declined. This has an impact on the quality of raw materials that are stored for too long. The coffee shop requires a better estimate in planning the supply of raw materials. Therefore, the design of this prediction system is important. Effective and efficient planning requires a prediction system with good accuracy. The ELM method is a derivative of an *artificial neural network* consisting of one *hidden layer*. This method has an advantage in the speed of computation time because the algorithm of this method does not *iterate* and produces a stable output. The weight value of this ANN derivative method is obtained randomly and the result is given a small square solution by performing the *Moore-Penrose Generalized Inverse* function. The results of the trial were 8 times with the parameters used, namely the comparison of *training* and *testing* data of 90%:10% and using the *binary sigmoid* activation function. The best number of *features* is 6 and the best number of *hidden neurons* is 3. The error value in calculating the *Mean Absolute Percentage Error (MAPE)* is 5.6518%. The results of these tests can prove that the use of the *Extreme Learning Machine (ELM)* method can predict the number of sales of coffee drinks, produce a stable predictive output and get the number of sales of coffee drinks in the future as a reference in the supply of raw materials.

الملخص

خليسه, فريادة نور . فردكسي فنجالان مينومان كوفي معغوناكان مطد اكستريم لرنينج ماشين. أطروحة. قسم هندسة المعلوماتية بكلية العلوم و التكنولوجيا جيا مولانا مالك ابراهيم الدولة الاسلامية جامعة مالانج .: مستشار : (١) خديجة فحمي حايبي حويل, أم. كوم (٢) أعلا سوقي, أم. كوم

الكلمات الرئيسية : جوملاح فنجالان, فرديكسي, أكستريم لرنينج ماشين

تم مناقشة الاتجاه الحالي لشرب القهوة في العديد من الدوائر. خاصة القهوة ذات المذاق الجديد وهي قهوة الحليب بالكريمة. يتنافس رجال الأعمال في الدولة على فتح مقهى بطعم فريد. يعد مقهى جنجي جيو أحد المقاهي الشهيرة في مدينة مالانج . جنجي جيو هي علامة تجارية محلية تتمتع بعلامة تجارية جيدة. نظام إدارة المبيعات في مقهى جنجي جيو ليس جيداً. يتم تقدير جمع البيانات الخاصة بتوريد المواد الخام يدوياً. في عام ٢٠٢٠ ، انخفضت مبيعات القهوة في جنجي جيو . هذا له تأثير على جودة المواد الخام التي يتم تخزينها لفترة طويلة. لذلك ، يحتاج مقهى جنجي جيو إلى تقديرات أفضل في التخطيط لتوريد المواد الخام. لذلك ، فإن تصميم نظام التنبؤ هذا مهم. يتطلب التخطيط الفعال والفعال نظام تنبؤ ذو دقة جيدة. طريقة (الم) هي مشتق من شبكة عصبية اصطناعية تتكون من طبقة مخفية واحدة. أظهرت نتائج التجارب التي تم إجراؤها في الدراسة أن طريقة (الم) بها خطأ جيد عن طريق قياس معدل الخطأ (الخطأ) باستخدام متوسط نسبة الخطأ المطلق (ماف) البالغ ٥,٦٥١٨٠٢٪ باستخدام مقارنة كمية الخطأ. بيانات التدريب والاختبار ٩٠٪:١٠٪ ، نطاق الوزن الأولي بين ٠-١ ، باستخدام أفضل عدد من الميزات ، أي ٦ ، باستخدام وظيفة التنشيط التناهي السيني ، واستخدام أفضل عدد من الطبقات المخفية ، وهو ٣. يمكن أن تثبت نتائج هذه الاختبارات أن استخدام طريقة اكستريم لرنينج ماشين (الم) يمكن أن يتنبأ بعدد مبيعات المشروبات. القهوة بدقة وبدقة والحصول على عدد مبيعات مشروبات القهوة في المستقبل كمرجع في توريد المشروبات. مواد أولية.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Lima tahun terakhir ini, produksi kopi di Indonesia semakin meningkat. Hal ini terjadi dikarenakan *lifestyle* generasi milenial pecinta kopi khususnya kaum adam. Tren minum kopi zaman sekarang dapat dinikmati di kedai kopi yang memiliki inovasi terbaru dengan peralatan yang lebih modern yang dikenal dengan *coffee shop*. Kedai kopi (*coffee shop*) kekinian ini dapat dijadikan sebagai pertemuan bersama teman, sahabat, keluarga, dan rekan kerja untuk membahas hal yang penting, arisan, ataupun bersantai. Kedai kopi kekinian ini memperkenalkan kopi dengan cita rasa yang baru yaitu *kopi susu creamy* dimana setiap kedai kopi memiliki ciri khas sendiri berdasarkan jenis kopi yang digunakan. Menurut cnnindonesia.com kopi susu yang sedang naik daun ini menjadikan pembuka awal pecinta kopi untuk semua kalangan baik kaum adam maupun kaum hawa. Karena rasanya yang dominan manis daripada kopi susu tradisional yang masih mempertahankan rasa pahit dari kopinya.

Kedai kopi yang berada di Kota Malang pun berkembang sangat pesat. Bahkan terdapat lima *brand coffee shop* yang terkenal berada di Kota Malang. Salah satu *brand coffee shop* yang terkenal di Kota Malang adalah Janji Jiwa. Janji Jiwa memiliki daya tarik tersendiri bagi penggemar kopi di Kota Malang. Janji Jiwa menerapkan bisnis *franchise* yaitu usaha turunan kepada pendiri usaha lainnya. Janji Jiwa telah memiliki cabang lebih dari 100 *outlet* di seluruh Indonesia. Semua kedai kopi saling

bersaing dalam melakukan perubahan dan inovasi dari segi apapun salah satunya desain *outlet* yang minimalis dan strategis guna mendapatkan daya tarik konsumen. Kedai kopi Kopi Janji Jiwa menerapkan konsep *fresh-to-cup* yang memiliki definisi yaitu penyajian kopinya didapatkan langsung dari petani lokal Indonesia (Hafni, et al., 2020). Menurut (Tandiono & Sahetapy, 2020) kedai kopi Janji Jiwa juga menerapkan konsep *coffee-to-go* dengan definisi konsumen dapat menikmati kopi Janji Jiwa yang praktis dapat dibawa beraktifitas, serta konsumen dapat membeli lebih cepat dengan adanya kerjasama Janji Jiwa dengan *ojek online*. Menurut (Kusumawardhani, 2019) kopi Janji Jiwa dipilih dari biji kopi *robusta* yang berasal dari tanah air sendiri yaitu pulau Sumatera. Menurut penggemar kopi Janji Jiwa, kopi susu yang disajikan terasa sangat kuat rasa kopinya tetapi tidak terlalu pahit.

Berdasarkan penelitian (Lestari, 2020) Janji Jiwa merupakan *brand* kedai kopi yang paling baik berdasarkan *brand equity* dengan indikator yang digunakan adalah *brand awareness*, *brand association*, *perceived quality*, dan *brand loyalty*. Secara keseluruhan hasil dari perbandingan *brand equity* Janji Jiwa dengan kedai kopi lain menunjukkan perbandingan yang cukup signifikan. Dikarenakan kedai kopi Janji Jiwa memiliki *brand equity* 0,4125 lebih besar daripada kedai kopi lain. Hal itu membuktikan bahwa keberadaan kedai kopi Janji Jiwa lebih dikenal dibanding kedai kopi lain.

Menurut hasil penelitian (Gencal, 2019) menyatakan bahwa sistem pengelolaan kedai kopi Janji Jiwa dilakukan berdasarkan perhitungan pencatatan sebelum dan sesudah penjualan setiap minggunya secara manual untuk memperkirakan pasokan

bahan baku. Menurut (Burhanudin, 2020) Owner kedai kopi Janji Jiwa mengatakan bahwa pada saat awal mula berdirinya Janji Jiwa pada tahun 2018, mereka mampu menjual produknya mulai dari 10-20 gelas per hari atau sekitar 600 gelas per bulan. Setelah berjalan sekitar satu setengah tahun, penjualan Janji Jiwa mencapai 5 juta cup. Namun selama pandemi, penjualan menurun sekitar 70% - 80%. Dari hasil observasi peneliti kepada kedai kopi Janji Jiwa dengan narasumber *karyawan* dari kedai kopi Janji Jiwa mengatakan bahwa sebelum masa pandemi omset perbulan yang didapat Janji Jiwa berkisaran 70-80 juta perbulan, dan saat masa pandemi menurun pada bulan Maret kisaran 20-30 juta. Kemudian pada bulan Juli omset yang didapat perbulan stabil berada diangka 45 juta perbulan sampai sekarang. Menurut (Komarudin, 2020) pada masa pandemi, kedai kopi Janji Jiwa merasakan dampak penurunan omset penjualan dari produk makanan dan minuman sekitar 40%. Dikarenakan *outlet-outlet* Janji Jiwa tidak *opening* sama sekali.

Dalam kehidupan di dunia ini, kita sebagai umat manusia selalu dipertemukan dengan masalah setiap harinya. Hal tersebut dapat dijadikan sebagai alasan untuk kita tetap belajar dan berusaha dari segi apapun agar tetap bertahan hidup dan meningkatkan kualitas kita sebagai ciptaan Allah SWT yang harus selalu belajar dari kesalahan. Setiap ada permasalahan pasti ada solusinya, menyelesaikan suatu masalah merupakan salah satu perintah Allah SWT yang dijelaskan dalam Q.S Al-Insyirah/94 : ayat 1-8 yang berbunyi (asy-Syaqawi, 2014):

أَلَمْ نَشْرَحْ لَكَ صَدْرَكَ ﴿١﴾ وَوَضَعْنَا عَنكَ وِزْرَكَ ﴿٢﴾ الَّذِي أَنْقَضَ ظَهْرَكَ ﴿٣﴾ وَرَفَعْنَا لَكَ ذِكْرَكَ ﴿٤﴾ فَإِنَّ مَعَ الْعُسْرِ يُسْرًا ﴿٥﴾ إِنَّ مَعَ الْعُسْرِ يُسْرًا ﴿٦﴾ فَإِذَا فَرَغْتَ فَانصَبْ ﴿٧﴾ وَإِلَىٰ رَبِّكَ فَارْغَبْ ﴿٨﴾

“Bukanlah Kami telah melapangkan untukmu dadamu? Dan Kami telah menghilangkan dari padamu bebanmu, yang memberatkan punggungmu? Dan Kami tinggikan bagimu sebutan (nama)mu. Karena sesungguhnya sesudah kesulitan itu ada kemudahan. Sesungguhnya sesudah kesulitan itu ada kemudahan. Maka apabila kamu telah selesai (dari sesuatu urusan), kerjakanlah dengan sungguh-sungguh (urusan) yang lain, dan hanya kepada Rabb-mulah hendaknya kamu berharap.” (QS. Al-Insyirah: 1-8)

Pada ayat di atas menjelaskan bahwa Allah SWT melapangkan dada dan menyelamatkan Nabi Muhammad dan umatNya dari ketidaktahuan dan kebodohan. Serta menegaskan bahwa kesulitan yang sedang dialami pasti akan mendapatkan kemudahan setelahnya, jika dengan sungguh-sungguh mau berusaha dan belajar atas ketidaktahuan tersebut diiringi dengan berharap dan berserah diri hanya kepada Allah SWT (Miftahuddin, 2020). (ambil tafsirnya siapa)

Permasalahan yang dialami Janji Jiwa dapat diatasi dengan cara menerapkan sistem prediksi penjualan sebagai sistem tambahan dalam sistem penjualannya. Sehingga, perkiraan pasokan bahan baku penjualan minuman dapat terbantu dengan adanya data prediksi penjualan di masa akan datang. Karena perhitungan manual

dengan pencatatan penjualan sebelum dan sesudah yang dilakukan kedai kopi Janji Jiwa kurang efektif dan kurang akurat, serta dapat beresiko jika perkiraan pasokan bahan baku terlalu melebihi target atau kurang dari target. Terlebih di masa pandemi seperti ini perlu dilakukan pengurangan pasokan bahan baku. Karena untuk memaksimalkan pendapatan perusahaan dibutuhkan perencanaan produksi yang baik. Sistem prediksi yang memiliki keakuratan yang baik dapat membantu kedai kopi Janji Jiwa untuk menentukan pemasokan bahan baku yang lebih efisien sesuai grafik hasil prediksi penjualan di masa akan datang. Serta dapat meminimalisir pemborosan biaya dan penyimpanan bahan baku yang mengakibatkan penurunan kualitas bahan baku dan sisa bahan baku yang terbuang.

Dalam QS. Luqman ayat 34, menjelaskan tentang peramalan atau perkiraan pada sesuatu yang belum pernah terjadi sebelumnya, yang berbunyi (Susila, 2020):

إِنَّ اللَّهَ عِنْدَهُ عِلْمُ السَّاعَةِ وَيُنزِلُ الْغَيْثَ وَيَعْلَمُ مَا فِي الْأَرْحَامِ ۗ وَمَا تَدْرِي نَفْسٌ مَّاذَا تَكْسِبُ غَدًا ۗ وَمَا تَدْرِي
 نَفْسٌ بِأَيِّ أَرْضٍ تَمُوتُ ۗ إِنَّ اللَّهَ عَلِيمٌ خَبِيرٌ

“Sesungguhnya Allah, hanya pada sisi-Nya sajalah pengetahuan tentang Hari Kiamat; dan Dialah Yang menurunkan hujan, dan mengetahui apa yang ada dalam rahim. Dan tiada seorangpun yang dapat mengetahui (dengan pasti) apa yang akan diusahakannya besok. Dan tiada seorangpun yang dapat mengetahui di bumi mana dia akan mati. Sesungguhnya Allah Maha Mengetahui lagi Maha Mengenal.” (QS. Luqman: 34)

Pada ayat di atas menjelaskan bahwa segala sesuatu yang akan terjadi di hari esok hanyalah Allah SWT yang mengetahuinya. Hal itu menunjukkan bahwa umat manusia tidak dapat mengetahui atau meramalkan sesuatu yang pasti dan yang akan terjadi (diperoleh) esok hari, melainkan umat tersebut mau berusaha. Kita diciptakan untuk selalu berusaha dan bertawakkal hanya kepada Allah SWT. Salah satu bentuk usaha kita dalam menyelesaikan masalah dengan meramalkan atau memperkirakan hasil yang diperoleh esok hari adalah dengan cara mengumpulkan data yang pernah terjadi sebelumnya dan dikelola dengan sebaik mungkin hingga menghasilkan suatu perkiraan secara teoritis. Karena hanya Allah yang maha mengetahui segala sesuatu, umat manusia hanya bisa berusaha.

Dalam melaksanakan penelitian ini, dibutuhkan suatu metode prediksi yang sesuai dan menghasilkan keakuratan yang baik untuk diterapkan pada data penjualan kedai kopi Janji Jiwa. Banyak metode yang digunakan dalam penelitian-penelitian sebelumnya dalam mendapatkan hasil prediksi yang akurat. Metode yang sering digunakan dalam sebuah sistem prediksi antara lain Moving Average, Exponential Smoothing, Jaringan Syaraf Tiruan, Regresi Linear, dll. Dari beragam metode yang biasa digunakan untuk peramalan, metode JST merupakan metode paling banyak digunakan. Metode JST memiliki kelebihan dapat menghitung secara berurutan lebih cepat dan karakteristik yang dimiliki JST mirip dengan jaringan syaraf pada makhluk hidup. Menurut (Izati, et al., 2019) Metode JST *Feed Forward Neural Networks* yang ada sebelumnya memiliki waktu komputasi lebih lama dibandingkan dengan model JST baru yaitu metode ELM. Berdasarkan metode yang tingkat akurasi yang lebih baik

dan memiliki nilai *error* yang lebih kecil menurut (Pratiwi & Harianto, 2019) dari penelitiannya yang membandingkan metode *Extreme Learning Machine* (ELM) dan metode Backpropagation adalah metode *Extreme Learning Machine* (ELM) yang memiliki nilai *error* yang lebih kecil daripada metode Backpropagation. *Extreme Learning Machine* (ELM) merupakan salah satu metode jaringan saraf tiruan *feed-forward* dengan satu *hidden layer* atau lebih dikenal dengan *single hidden layer feed-forward neural networks* (SLFNs) yang pertama kali dikenalkan oleh Huang pada tahun 2004 (Huang, et al., 2004). *Extreme Learning Machine* (ELM) memiliki keunggulan dalam *learning speed*. Pada penelitian lainnya, menurut (Alfiyatin, et al., 2019) *Extreme Learning Machine* (ELM) memiliki tingkat akurasi yang lebih baik daripada metode-metode konvensional seperti Moving Average dan Exponential Smoothing.

Indikator yang digunakan sebagai penentu tingkat penyimpangan atau nilai *error* adalah indikator MAPE. *Mean Absolut Persen Error* (MAPE) merupakan tolak ukur untuk melihat penggunaan metode yang dipilih memiliki tingkat kesalahan atau nilai *error* dengan rentan nilai antara 0-1. Hasil yang paling mendekati 0 berarti nilai *error* nya kecil dan paling baik. Hal itu menunjukkan bahwa hasil prediksi yang dilakukan semakin akurat.

Berdasarkan latar belakang tersebut maka metode *Extreme Learning Machine* (ELM) akan diimplementasikan untuk sistem prediksi penjualan kopi harian. Karena dari beberapa penelitian sebelumnya menunjukkan bahwa metode ELM menghasilkan nilai *error* terkecil dan memiliki kecepatan waktu *training* yang baik dibandingkan

model JST yang lainnya. Sehingga pengolahan data prediksi secara *real-time* dapat menghasilkan *output* yang stabil.

1.2 Pernyataan Masalah

Berdasarkan latar belakang di atas, maka masalah yang akan dibahas dalam penelitian ini adalah

1. Bagaimana performa dari penggunaan metode *Extreme Learning Machine* (ELM) dalam memprediksi penjualan minuman kopi di *Coffee Shop* yang diukur menggunakan perhitungan *Mean Absolute Percentage Error* (MAPE)?
2. Berapa jumlah *fitur*, jumlah *hidden neuron*, dan jumlah *epoch* terbaik dari hasil prediksi penjualan minuman kopi dengan menggunakan *Extreme Learning Machine* (ELM)?

1.3 Batasan Masalah

Agar penelitian ini lebih terarah dan tidak menyimpang dari tujuan, maka ditetapkan batasan-batasan masalah sebagai berikut :

1. Sumber informasi dari *Coffee Shop* di Malang yaitu Janji Jiwa.
2. Pihak yang diwawancarai merupakan karyawan dari Janji Jiwa Malang.
3. Data terkait pengelolaan sistem prediksi penjualan yaitu jumlah penjualan perhari dalam periode bulanan sebelumnya.
4. Output yang dihasilkan dari sistem prediksi penjualan adalah hasil prediksi jumlah penjualan di masa akan datang (bulan depan) dengan nilai perhari.

1.4 Tujuan Penelitian

Berdasarkan pernyataan masalah di sub bab 1.2, maka tujuan yang ingin dicapai dalam penelitian ini adalah

1. Mengukur performa dari hasil prediksi metode *Extreme Learning Machine* (ELM) dalam penjualan minuman kopi pada kedai kopi Janji Jiwa yang diukur menggunakan perhitungan *Mean Absolute Percentage Error* (MAPE).
2. Mengukur nilai jumlah *fitur*, jumlah *hidden neuron*, dan jumlah *epoch* terbaik dari hasil prediksi penjualan minuman dengan menggunakan metode *Extreme Learning Machine* (ELM).

1.5 Manfaat Penelitian

Pada penelitian ini, diharapkan dapat memberikan manfaat sebagai berikut :

1. Diharapkan dapat membantu kedai kopi Janji Jiwa dalam perencanaan produksi berdasarkan hasil prediksi penjualan minuman kopi.
2. Dengan menerapkan sistem informasi prediksi maka dapat meminimalisir terjadinya pemborosan pada biaya dan sisa bahan baku yang terbuang sia-sia.
3. Diharapkan dapat menjadi dasar penelitian bagi peneliti selanjutnya dalam mengembangkan sistem informasi prediksi yang lebih baik.
4. Dapat meningkatkan keilmuan yang mendasar tentang penerapan metode *Extreme Learning Machine* (ELM).

BAB II

TINJAUAN PUSTAKA

Pada proses penelitian yang akan dilakukan diperlukan beberapa penelitian terdahulu sebagai referensi dan pemahaman bagi penulis untuk mendapatkan informasi dan inspirasi yang akan dikembangkan dalam penelitian ini. Oleh karena itu, penulis mengumpulkan beberapa referensi penelitian terdahulu terkait permasalahan yang diangkat dalam penelitian ini.

Pada pembahasan Alfiyatin *et al.* (2019) dalam penelitiannya tentang penerapan *Extreme Learning Machine* (ELM) untuk peramalan laju inflasi di Indonesia, peneliti mengatakan bahwa pada metode ELM yang dijadikan sebagai metode peramalan untuk laju inflasi bekerja dengan baik dan kinerjanya tidak berkurang walaupun ada penambahan variabel yang digunakan. Namun, pada proses penentuan jumlah neuron di *hidden layer* mengalami proses *trial* dan *error*. Selain itu, menurut penelitiannya nilai *error* yang didapatkan dari peramalan laju inflasi adalah 0,0202008, dimana peneliti menyatakan bahwa nilai *error* dari proses metode ELM tersebut lebih baik daripada metode backpropagation. Penelitian lain dari Pangaribuan (2016) juga menyatakan hal yang sama yaitu metode ELM memiliki performa lebih baik daripada metode backpropagation dari segi kecepatan memproses data dan memiliki tingkat kesalahan (*error*) yang lebih baik. Nilai *error* yang dihasilkan metode ELM adalah 0,4036 sedangkan metode backpropagation menghasilkan *error* 0,9425. Diketahui bahwa tingkat kesalahan yang paling mendekati 0 adalah hasil yang paling baik.

Ahmad *et al.* (2018) dalam tulisannya membandingkan metode *Extreme Learning Machine* (ELM), *Support Vector Machine* (SVM), dan *Random Forest* untuk menunjukkan metode manakah yang memiliki keunggulan. Dari hasil penelitiannya menunjukkan bahwa metode ELM memiliki keunggulan berdasarkan pengujian tingkat kesalahannya (*error*), presisi, dan recall pada sebuah sampel data. Peneliti juga mengatakan bahwa metode ELM merupakan metode yang cocok untuk sistem deteksi intrusi yang dirancang untuk menganalisis data dalam jumlah yang besar.

Handika *et al.* (2016) melakukan perbandingan pada dua metode untuk peramalan jumlah penjualan barang dengan menggunakan metode *Extreme Learning Machine* (ELM) dan *Particle Swarm Optimization Extreme Learning Machine* (PSO-ELM). Hasil yang didapatkan adalah metode PSO ELM memperoleh nilai *error* yang lebih kecil daripada metode ELM. Mereka menyimpulkan bahwa metode PSO ELM mampu mengoptimalkan jumlah *hidden neuron* dari metode ELM untuk meramalkan jumlah penjualan barang.

Sun *et al.* (2008) melakukan penelitian yang membahas tentang analisis peramalan penjualan fashion dengan data yang disediakan oleh pengecer mode Hong Kong dengan menggunakan metode ELM. Menurut peneliti metode ELM merupakan proses yang menghasilkan faktor paling signifikan yang mempengaruhi jumlah penjualan. Hasil dari penelitian berhasil menunjukkan bahwa metode ELM dapat digunakan dalam peramalan penjualan untuk ritel fashion dan menghasilkan tingkat kesalahan yang lebih kecil daripada prediksi lainnya yang menggunakan metode BPNN.

Fardani *et al.* (2015) menyajikan sebuah hasil dari penelitiannya tentang peramalan jumlah kunjungan pasien menggunakan metode *Extreme Learning Machine* (ELM) yaitu nilai kesalahan (*error*) yang didapat paling optimal adalah 0,0277 pada fungsi aktivasi *sigmoid biner* dengan jumlah *hidden neuron* sebanyak 7 unit. Peneliti melakukan evaluasi beberapa kali untuk mendapatkan hasil yang optimal dengan menggunakan 116 data.

2.1 Penjualan Minuman Janji Jiwa

Kedai kopi Janji Jiwa menjual beberapa menu minuman dan makanan. Menu *best seller* Janji Jiwa adalah kopi susu nya yang masih terasa kopi tradisional namun *taste* nya dominan manis. Hal itu menarik pecinta kopi baru yang awalnya tidak menyukai kopi yang *identik* dengan rasa pahit. Bahkan kaum hawa sekarang banyak yang menjadi pecinta kopi. Kedai kopi Janji Jiwa memberikan pelayanan terbaik dari segi kualitas, tempat, dan harga. Selain itu, Janji Jiwa memiliki aplikasi khusus dengan nama Jiwa+ (Isna, 2020). Janji Jiwa berasal dari perusahaan Jiwa Group.

Penjualan kedai kopi Janji Jiwa berkembang pesat secara signifikan diiringi strategi yang baik. Sejak berdirinya kedai kopi ini pada tahun 2018, produknya terjual 10-20 gelas perharinya. Setelah berkembang selama 1,5 tahun, produknya terjual sekitar lima juta cup perbulan dan memiliki outlet sekitar 700 yang tersebar di Indonesia (Setiawan, 2019). Keberhasilan bisnis kedai kopi Janji Jiwa juga dikarenakan menerapkan *coffee-to-go* yang bekerjasama dengan *ojek online* untuk mengantar pesanan konsumen (Kusumawardhani, 2019).

Saat masuk masa pandemi, owner Janji Jiwa merasakan dampak terhadap penjualannya yang menurun drastis sekitar 70%. Karena kedai kopi Janji Jiwa terpaksa tutup untuk mematuhi peraturan pemerintah. Kemudian Janji Jiwa survive dari keterpurukan tersebut dengan menjual via *online* dengan mengencangkan promosi online para influencer tanah air (Ulya, 2020). Menurut karyawan Janji Jiwa grafik penjualan online kurang stabil, sehingga perkiraan pasokan bahan baku kurang maksimal.

2.2 Forecasting (Peramalan)

Forecasting atau juga bisa disebut peramalan merupakan suatu teknik untuk memprediksi suatu nilai pada masa yang akan datang berdasarkan data atau informasi yang sesuai (Nachrowi & Usman, 2004). Data atau informasi yang didapat bisa dari masa lalu ataupun saat ini.

Berdasarkan cara perolehannya, forecasting dapat menggunakan dua cara yaitu cara kualitatif dan cara kuantitatif. Teknik kualitatif lebih menitikberatkan intuisi atau pendapat para pakar. Sebagai contoh, seorang presiden membutuhkan data perkiraan pertumbuhan ekonomi pada tahun 2004. Berdasarkan contoh tersebut, presiden akan membutuhkan bantuan para ekonom untuk meminta pendapatnya tentang kasus tersebut. Sedangkan untuk teknik kuantitatif didasari dengan metode statistik dan matematik. Teknik kuantitatif terbagi menjadi dua kategori yaitu metode time series dan metode regresi (kausal).

2.3 Jaringan Saraf Tiruan (JST)

Jaringan Saraf Tiruan merupakan rangkaian prosesor dasar yang sangat terhubung yang disebut *neuron* (Park, et al., 1991). Jaringan saraf tiruan menunjukkan analogi dengan susunan cara fungsi *neuron* dalam pembelajaran *biologi* dan memori. Blok bangunan fundamental adalah unit ('*node*') sebanding dengan *neuron*, dan berbobot koneksi yang dapat disamakan dengan sinapsis di sistem *biologis* (Sinha & Wang, 2008).

Node adalah informasi sederhana elemen pemrosesan. Jumlah *node* di JST dan pola koneksi dari *node* dapat bervariasi. Jumlah total *node* di lapisan masukan dan keluaran bertepatan dengan jumlah variabel masukan dan keluaran dalam kumpulan data. Jumlah ideal *node* di *hidden layer* harus ditemukan melalui *trial and error*. Diketahui lebih banyak *neuron* memberikan kemampuan untuk menghafal dan mengurangi kemampuan penalaran JST. Sebagai aturan umum, JST harus berisi minimum jumlah *neuron* yang mampu mensimulasikan data pelatihan. Setiap koneksi antar *node* membawa *bobot* yang mewakili beberapa proses pembelajaran sebelumnya. Dengan memvariasikan *bobot* tersebut, *input-output* hubungan dapat disimulasikan. Jaringan haruslah dilatih untuk mereproduksi hubungan *input-output* ini untuk menemukan *bobot* optimal (Sinha & Wang, 2008).


Algoritma pada JST beroperasi langsung berupa angka sehingga data yang tidak berupa numerik diharuskan untuk diubah menjadi data numerik. Proses pemrograman JST tidak menghasilkan *output* tertentu. Semua *output* yang ditarik oleh jaringan didasari dengan proses pembelajaran (Wuryandari & Afrianto, 2012). Pada dasarnya,

JST memiliki beberapa ketentuan karakteristik sebagai berikut (Lesnussa, et al., 2015)

:

1. Penghubung antar lapisan *neuron* dengan lapisan lain yang biasa disebut arsitektur jaringan.
2. Metode yang menghubungkan *neuron* untuk menentukan *bobot* yang terhubung di dalamnya.
3. Fungsi aktivasi ($y = f(\text{net})$) dimana Y menerima *input* dari *neuron* X_1, X_2, X_3 dengan *bobot* hubungan masing-masing dari w_1, w_2, w_3 . Kemudian tiga impuls *neuron* dijumlahkan dengan bentuk sebagai berikut :

$$\text{net} = X_1w_1 + X_2w_2 + X_3w_3$$



Gambar 2.1 Fungsi aktivasi Jaringan Saraf Tiruan
Sumber : (Lesnussa, et al., 2015)

Adapun konsep dasar JST yang berproses dalam *neuron* dengan pola informasi yang terhubung pada *input* dan *output*. Lapisan-lapisan penyusun JST yang berbentuk *neuron-neuron* tersebut terkumpul dalam lapisan yang dinamakan lapisan *neuron*. Lapisan pada model tersebut terbagi menjadi tiga kategori sebagai berikut (Lesnussa, et al., 2015) :

1. Lapisan *input*, pada lapisan ini terdiri dari unit-unit input yang berfungsi untuk menerima pola data dari luar yang digambarkan sebagai permasalahan.
2. Lapisan *tersembunyi*, pada lapisan ini terdapat unit-unit lapisan tersembunyi. Dikatakan tersembunyi dikarenakan *outputnya* tidak dapat diaamati secara langsung.
3. Lapisan *output*, pada lapisan ini terdapat unit *output*. Dimana pada lapisan ini ditemukannya suatu solusi JST dari suatu permasalahan yang berawal dari lapisan *input*.

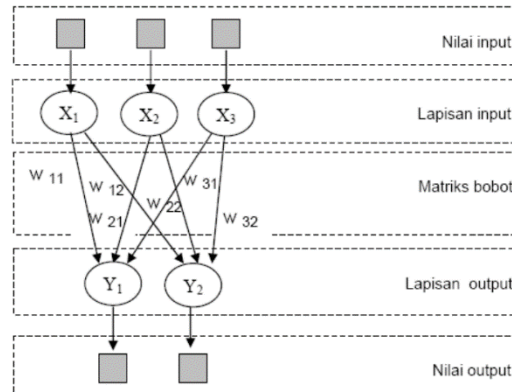
2.3.1 Arsitektur Jaringan

Pada Jaringan Saraf Tiruan terdapat suatu lapisan yang dinamakan lapisan *neuron (neuron layers)*. Informasi dihubungkan melalui lapisan input hingga lapisan output dengan penghubung lapisan tersembunyi. Faktor penting dalam penentuan perilaku suatu neuron yaitu fungsi aktivasi dan pola bobotnya (Wuryandari & Afrianto, 2012). Pada arsitektur Jaringan Saraf Tiruan terdapat 3 macam arsitektur JST dengan lapisan yang berbeda-beda sebagai berikut (Wuryandari & Afrianto, 2012) :

1. Jaringan Lapisan Tunggal (Single Layer Net)

Sesuai dengan namanya jaringan *single layer* hanya memiliki satu lapisan saja dengan *bobot* penghubungnya. Proses jaringan *single layer* hanya menerima *input* kemudian langsung ditransfer ke lapisan *output*

tanpa terhubung dengan lapisan tersembunyi. Besarnya suatu hubungan antara dua *neuron* ditentukan oleh kesesuaian *bobotnya*. Diagram arsitektur untuk jaringan *single layer* disajikan dalam Gambar 2.2 dibawah.



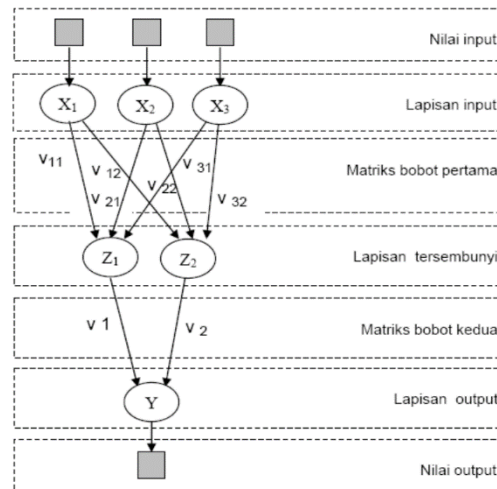
Gambar 2.2 Diagram jaringan lapisan tunggal (Single Layer Net)

Sumber : (Wuryandari & Afrianto, 2012)

2. Jaringan Banyak Lapisan (Multilayer Net)

Pada jaringan ini memiliki lapisan lebih dari satu yang terletak antara lapisan *input* dengan lapisan *output* yang biasa digunakan sebagai lapisan tersembunyi. Lapisan tersembunyi terdiri dari *hidden neuron* yang memproses perhitungan dari *input layer* dan dilanjutkan ke *output layer*. Jumlah *hidden neuron* yang digunakan dapat lebih dari satu, tergantung pada kebutuhan. Pada jaringan *multilayer* lebih sulit daripada *single layer* dalam menyelesaikan permasalahan yang diberikan. Hal itu dikarenakan pembelajarannya yang lebih rumit. Namun, pada beberapa permasalahan yang menggunakan jaringan *multilayer* ini lebih banyak sukses dalam

menyelesaikan masalah. Diagram arsitektur untuk jaringan multilayer disajikan dalam Gambar 2.3 dibawah.




Gambar 2.3 Diagram jaringan banyak lapisan (Multilayer Net)

Sumber : (Wuryandari & Afrianto, 2012).

3. Jaringan Lapisan Kompetitif (*Competitive Layer Net*)

Pada jaringan ini berbeda dengan jaringan sebelumnya, jaringan *competitive layer* ini tidak memperlihatkan hubungan antar *neuron* pada diagram arsitektur. Jaringan *competitive layer* memiliki fungsi untuk memberikan hak aktif pada sekumpulan *neuron* yang bersaing. Diagram

arsitektur untuk jaringan competitive layer disajikan dalam Gambar 2.4 dibawah.




Gambar 2.4 Diagram jaringan lapisan kompetitif (Competitive Layer Net)

Sumber : (Wuryandari & Afrianto, 2012)

2.3.2 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang digunakan untuk menentukan nilai keluaran suatu *neuron* dan faktor yang berperan penting untuk menentukan kelakuan suatu *neuron*. Pada setiap lapisan yang sama, *neuron-neuron* yang terhubung juga mempunyai fungsi aktivasi yang sama (Fardani, et al., 2015). Menurut (Wibawa, 2016) fungsi aktivasi memiliki fungsi untuk menghitung nilai keluaran berdasarkan *input* dan *bobot* pada *neuron*. Fungsi aktivasi terdiri dari 4 macam yang digunakan dalam jaringan saraf tiruan sebagai berikut (Mosabeth, et al., 2018):

1. Fungsi Aktivasi Sigmoid Biner




Gambar 2.5 Fungsi aktivasi sigmoid biner

Sumber : (Mosabeth, et al., 2018)

Fungsi aktivasi *sigmoid biner* merupakan fungsi aktivasi yang melakukan proses pada suatu *output* jaringan dan sesuai nilai target dengan jangkauan nilai $[0,1]$. Fungsi sigmoid memiliki persamaan sebagai berikut :

$$H = \frac{1}{1 + \exp(-H_{init})} \quad (2.1)$$

2. Fungsi Aktivasi Sigmoid Bipolar



Gambar 2.6 Fungsi aktivasi sigmoid bipolar

(Mosabeth, et al., 2018)

Selain fungsi aktivasi *sigmoid biner*, pada dasarnya fungsi aktivasi memiliki 2 jenis sigmoid. Fungsi aktivasi sigmoid lainnya adalah fungsi aktivasi *sigmoid bipolar* yang memiliki jangkauan nilai $[-1,1]$. Persamaan fungsi aktivasi *sigmoid bipolar* dapat dituliskan sebagai berikut :

$$H = \frac{1 - \exp(-H_{init})}{1 + \exp(-H_{init})} \quad (2.2)$$

3. Fungsi Aktivasi Sin

Fungsi aktivasi sin memiliki jangkauan nilai yang sama dengan fungsi aktivasi sigmoid *bipolar* yaitu dengan nilai $[-1,1]$. Persamaan fungsi aktivasi sin dapat dituliskan sebagai berikut :

$$H = \text{Sin}(H_{init}) \quad (2.3)$$

4. Fungsi Aktivasi Radial Basis

Fungsi aktivasi radial basis merupakan jaringan dengan lapisan tunggal yang dapat mengkonversi nilai *input* bernilai *kontinu* menjadi *output* nilai biner dengan jangkauan nilai $[0,1]$. Berikut persamaan dari fungsi aktivasi radial basis :

$$H = \exp(-((H_{init})^2)) \quad (2.4)$$


2.4 Metode Extreme Learning Machine

Extreme Learning Machine (ELM) adalah metode jaringan saraf berbasis model dan data baru yang inovatif menggunakan algoritma jaringan *Single-hidden Layer*

FeedForward Networks (SLFNs) yang canggih untuk menghasilkan solusi bentuk tertutup untuk bobot output melalui solusi kuadrat terkecil (Yaseen, et al., 2018). Menurut (Pangaribuan, 2016) metode ELM adalah jenis dari metode jaringan saraf tiruan *feed-forward* dengan satu *hidden layer* atau biasa dikenal dengan istilah *single hidden layer feed-forward neural network*. Metode ELM lebih unggul daripada model JST yang lainnya, karena metode ELM memiliki waktu komputasi lebih cepat dan menghasilkan *output* yang lebih stabil secara *real-time*. Metode ELM mengimplementasikan algoritma tanpa *iterasi*, sehingga proses aktivasi dari metode ini cukup cepat (Fitriati, 2016). Pada model JST yang lainnya menggunakan parameter jaringan secara iteratif pada proses *training*, oleh karena itu membutuhkan waktu yang lama. Kelebihan utama dari metode ELM adalah kompleksitas yang lebih rendah yang terlibat dalam desain dan kemampuannya untuk memecahkan masalah regresi atau peramalan dalam waktu yang lebih singkat, karena *bobot* di dalam *neuron* tersembunyi didapatkan secara acak dan hasilnya memiliki solusi kuadrat terkecil yang unik diselesaikan dengan fungsi *invers Moore-Penrose*. Dalam pemodelan data menggunakan model ELM, terdapat 3 langkah sederhana prosedur pembangunan yang digunakan sebagai berikut (Yaseen, et al., 2018) :

1. Membangun lapisan tersembunyi bobot secara acak (bukan secara *iteratif* seperti dalam kasus Model JST).
2. Menghubungkan *input* melalui parameter lapisan tersembunyi untuk menghasilkan matriks *output* lapisan tersembunyi.

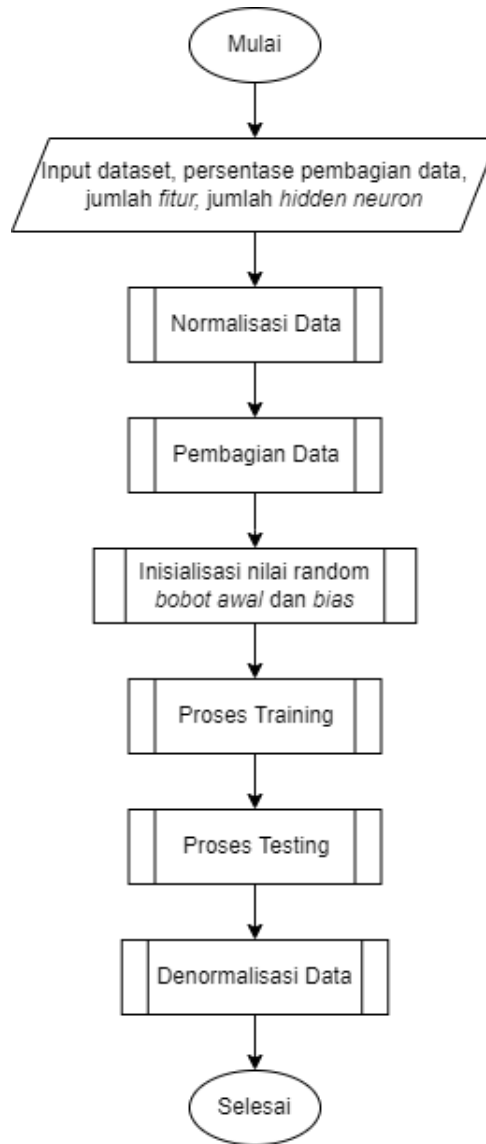
3. Memperkirakan *bobot output* dengan membalik matriks *output* lapisan tersembunyi, dimana matriks *invers Moore-Penrose* digunakan dan kemudian dihitung produk dengan variabel respon (yaitu, memecahkan serangkaian persamaan linier). Proses ini membutuhkan pengacakan *neuron* tersembunyi satu kali *node neuron* tersembunyi telah diidentifikasi. Biasanya, *neuron* yang tersembunyi diidentifikasi dengan *trial-and-error* melalui dataset validasi silang. Dengan pandangan ke depan yang lebih besar untuk implementasi *real-time*, ELM menawarkan keunggulan berbeda dibandingkan model lain yang mengalami konvergensi lambat, generalisasi inferior, masalah minimum lokal, data yang terlalu pas, dan penyetulan berulang. Kinerja ELM yang cepat dan lebih baik dapat menguntungkan dalam aplikasi *real-time*.



Gambar 2.7 Arsitektur jaringan metode ELM

Sumber : (Xu, et al., 2011)

Pada Gambar 2.7 menunjukkan arsitektur jaringan metode ELM dengan menerapkan algoritma ELM yang dikembangkan dari jaringan SLFNs model JST. Algoritma metode ELM dapat dituliskan sebagai berikut :



Gambar 2.8 Algoritma metode Extreme Learning Machine (ELM)

2.4.1 Normalisasi Data

Normalisasi data merupakan proses transformasi atau perubahan bentuk data untuk *pre-processing* pada sistem data mining dengan spesifik nilai yang lebih kecil. Perubahan bentuk data ini terjadi dikarenakan nilai *range* masukan tidak sama, yaitu bernilai puluh-an sampai ribu-an. Atribut yang tersedia dari

dataset dilakukan proses normalisasi dengan cara input nilai yang besar menghasilkan output nilai yang kecil sesuai kebutuhan (Saranya & Manikandan, 2013). Data yang dinormalisasi akan menghasilkan nilai dengan rentang [0,1] atau [-1,1] (Ali & Faraj, 2014). Nilai rentang data menyesuaikan dari fungsi aktivasi yang digunakan, jika fungsi aktivasi menggunakan sigmoid biner maka rentang datanya [0,1], sedangkan jika fungsi aktivasi menggunakan sigmoid bipolar maka rentang datanya [-1,1]. Selain itu menurut (Pangaribuan, 2016) data normalisasi adalah data yang akan diinputkan ke dalam data denormalisasi. Cara normalisasi data yaitu nilai asli data dari setiap parameter dikurangi nilai minimum data set, kemudian hasilnya dibagi dengan hasil operasi dari nilai maksimal dataset dikurangi nilai minimum dataset. Adapun persamaan yang menunjukkan normalisasi data sebagai berikut (Ali & Faraj, 2014) :

$$x' = \frac{x - \min}{\max - \min} \quad (2.5)$$

Keterangan :

x' = Nilai dari hasil normalisasi data

x = Nilai asli data (nilai data index ke-i pada setiap fitur)

min = Nilai minimum dataset fitur X

max = Nilai maksimal dataset fitur X

2.4.2 Proses Training

Proses *training* merupakan proses tahapan pada metode ELM setelah proses normalisasi data dengan tujuan untuk mendapatkan rumus dari proses *learning machine* yaitu nilai *output weight* (β). Pada proses *training* sebelum data di proses, dilakukannya pembagian dataset dalam menjalankan tahapan-tahapan proses. Langkah-langkah yang harus dilakukan dalam proses training sesuai dengan tahapan algoritma ELM yang diringkas sebagai berikut (Ding, et al., 2013):

1. Proses pertama yaitu, melakukan inisialisasi nilai input bobot dan bias secara random dengan nilai antara -1 dan +1 atau 0 dan 1.
2. Perhitungan matriks keluaran *hidden neuron* (H_{init}). Adapun rumus untuk matriks H_{init} sebagai berikut :

$$H_{init\ ij} = \sum_{i=1}^n (a_i \cdot x_j + b_i) \quad (2.6)$$

3. Menghitung fungsi aktivasi dari hasil H_{init} . Biasanya nilai keluaran *hidden layer* yang dihitung dengan fungsi aktivasi dilambangkan $H_{(x)}$. Persamaan fungsi aktivasi yang digunakan adalah fungsi aktivasi sigmoid biner sebagai berikut :

$$H_{(x)} = \sum_{i=1}^n f(a_i \cdot x_j + b_i) \quad (2.7)$$

4. Melakukan *transpose* dari hasil keluaran *hidden layer* dengan fungsi aktivasi ($H_{(x)}$), biasanya dilambangkan H^T .

5. Melakukan perkalian antara matriks hasil transpose (H^T) tersebut dengan hasil keluaran *hidden layer* dengan fungsi aktivasi sigmoid ($H_{(x)}$).
6. Melakukan proses *invers* matriks pada hasil perkalian matrik H^T dan $H_{(x)}$.
7. Hasil matriks *invers* $(H^T H)^{-1}$ dikalikan dengan matriks keluaran *hidden layer* dengan fungsi aktivasi yang telah di transpose (H^T). Hasil dari perkalian tersebut disebut matriks *Moore-Penrose Generalized Invers* (H^+) sesuai dengan persamaan berikut :

$$H^+ = (H^T H_{(x)})^{-1} H^T \quad (2.8)$$

Keterangan :

H^+ = *Moore-Penrose Generalized Invers*

$H_{(x)}$ = Matriks keluaran *hidden layer* dengan fungsi aktivasi

H^T = Matriks keluaran *hidden layer* dengan fungsi aktivasi yang telah di transpose

8. Perhitungan nilai *output bobot* menggunakan nilai dari hasil matriks *Moore-Penrose Generalized Invers* dikalikan dengan nilai target data *training* seperti berikut (Huang, et al., 2004) :

$$\beta = H^+ T \quad (2.9)$$

Keterangan :

β = Matriks Output Bobot

H^+ = Matriks Moore-Penrose Generalized Invers

T = Matriks Target

2.4.3 Proses Testing

Proses *testing* adalah proses yang bertujuan untuk menguji hasil *bobot akhir* yang didapatkan dari proses sebelumnya kemudian diproses kembali pada tahapan proses *testing*. Proses *testing* ini dilakukan dengan menggunakan data uji yaitu *input weight*, *output weight*, dan *bias* yang didapatkan dari proses *training* sebelumnya. Tahapan proses *testing* hampir sama dengan proses *training*, yang membedakannya yaitu pada proses *testing* tidak melakukan proses inisialisasi *bobot* dan *bias* serta tidak melakukan proses seleksi data seperti proses *training*. Berikut langkah-langkah dalam melakukan proses *testing* :

1. Menginisialisasi input *bobot* dan *bias* yang didapat dari proses *training*.
2. Menghitung matriks keluaran *hidden neuron* (H_{init}) menggunakan Persamaan 2.6 sama seperti proses *training*.
3. Perhitungan nilai prediksi (lapisan *output*) menggunakan nilai *output weight* dari proses *training* dikalikan dengan matriks keluaran *hidden neuron* fungsi aktivasi *sigmoid* data *testing*. Dengan persamaan sebagai berikut :

$$y = H_{(x)}\beta \quad (2.10)$$

Keterangan

y = Output layer (hasil prediksi)

$H_{(x)}$ = Matriks keluaran *hidden neuron* yang dihitung menggunakan fungsi aktivasi

β = Nilai *output weight* dari hasil proses training

2.4.4 Proses Denormalisasi Data

Pada proses denormalisasi data, data input didapatkan dari hasil prediksi dengan rentang nilai antara 0-1 yang merupakan hasil dari proses normalisasi data. Berikut rumus denormalisasi data yang digunakan (Ali & Faraj, 2014) :

$$x = x'(max - min) + min \quad (2.11)$$

Keterangan :

x' = Nilai hasil prediksi sebelum dilakukan proses denormalisasi

x = Nilai asli setelah dilakukan proses denormalisasi

min = Nilai minimal pada data fitur X

max = Nilai maksimal pada data fitur X

2.5 Evaluasi Pengukuran

Mengevaluasi kinerja peramalan model yang diusulkan dibutuhkan pengujian nilai kesalahan (*error*). Nilai *error* tersebut dapat dijadikan sebagai kriteria penilaian terhadap metode yang digunakan. Pengukuran yang banyak digunakan adalah *Mean Absolute Error* (MAE), *Mean Absolut Persen Error* (MAPE), *Mean Square Error*

(MSE), dan *Root Mean Square Error* (RMSE). Nilai kesalahan (*error*) menghasilkan output antara 0 dan 1, dimana nilai yang paling rendah (paling mendekati 0) menunjukkan prediksi yang paling baik. Nilai statistik antara nilai yang paling mendekati 0 (menunjukkan nilai yang paling baik) dan mendekati 1 (menunjukkan nilai yang paling buruk) (Yang, et al., 2017). Pada penelitian ini, penulis menggunakan pengukuran MAPE sebagai evaluasi dan penentu kinerja terhadap metode yang digunakan untuk menghasilkan nilai kesalahan (*error*).

2.5.1 Mean Absolute Percent Error (MAPE)

MAPE (*Mean Absolute Percent Error*) adalah pengukuran yang digunakan untuk mengevaluasi nilai kesalahan (*error*) dan akurasi dari hasil prediksi. Menurut (Maricar, 2019) pengukuran akurasi peramalan merupakan faktor penting untuk membandingkan nilai hasil peramalan dengan nilai sebenarnya. Berikut persamaan dari MAPE (*Mean Absolute Percent Error*) untuk melakukan perhitungan nilai *error* dalam bentuk persentase (Maricar & Pramana, 2019):

$$MAPE = \sum_{t=1}^n \frac{|x_t - y_t|}{x} \times 100\% \quad (2.12)$$

Keterangan :

n = Jumlah data

$t = [1, 2, \dots, n]$, n adalah keseluruhan jumlah data

x_t = Nilai aktual (asli)


y_t = Nilai hasil prediksi

BAB III METODOLOGI PENELITIAN

Bab ini membahas tentang perancangan sistem yang terdiri dari desain penelitian, pengumpulan data, desain sistem, dan perhitungan manual sistem prediksi yang menerapkan metode Extreme Learning Machine (ELM) dengan objek *coffee shop* Janji Jiwa Malang.

3.1 Desain Penelitian

Pada dasarnya, penelitian membutuhkan prosedur yang terstruktur agar penelitian yang dilakukan dapat berjalan dengan lancar dengan baik dan lebih efektif. Prosedur penelitian yang akan dijadikan sebagai tahapan dan acuan untuk penelitian ini ditunjukkan Gambar 3.1 berikut.



Gambar 3.1 Prosedur penelitian

Dari proses diagram diatas dimulai dengan pengumpulan data penjualan minuman pada kedai kopi Janji Jiwa, selanjutnya data tersebut dikelola dengan penerapan metode *Extreme Learning Machine* (ELM) dengan hasil akhir *output prediksi* sebagai ramalan penjualan untuk masa akan datang dan acuan penentu pasokan bahan baku. Hasil akhir tersebut dikelola lagi dalam proses uji nilai *error*

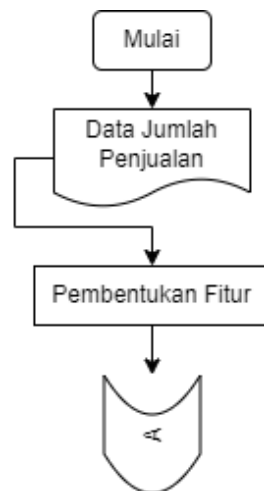
(kesalahan) untuk mengetahui tingkat kesalahan (*error*) yang dihasilkan sudah menghasilkan yang terbaik atau belum.

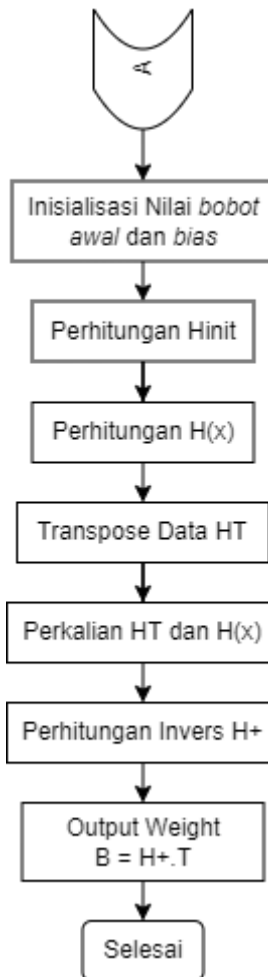
3.2 Pengumpulan Data

Pengumpulan data yang digunakan penulis dalam menyelesaikan penelitian ini adalah dengan cara interview langsung kepada karyawan Janji Jiwa Malang dan memohon izin untuk meminta data penjualan dari periode Juli 2020 – Januari 2021 sebagai data primer yang akan diolah dalam sistem.

3.3 Desain Sistem

Desain sistem merupakan tahapan kedua untuk membuat rancangan alur dari sistem yang akan berjalan. Berikut proses yang menggambarkan alur dari sistem prediksi yang dibangun :



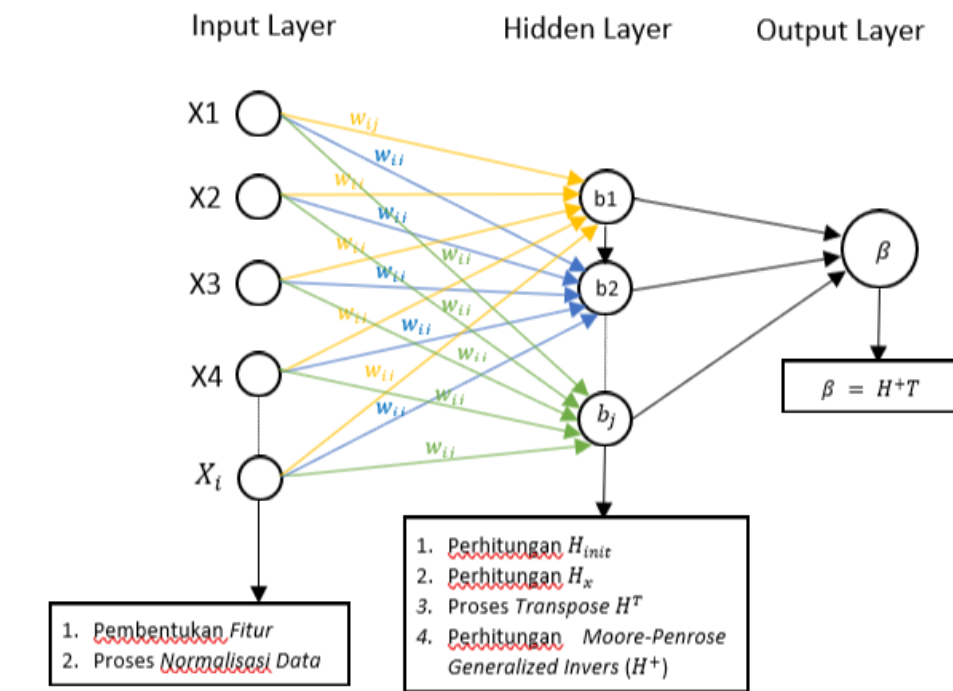


Gambar 3. 2 Desain sistem prediksi

Pada Gambar 3.2 merupakan desain sistem yang akan dibangun dalam proses implementasi metode ELM sebagai metode prediksi penjualam minuman kopi di kedai kopi Janji Jiwa. Alur dari sistem tersebut meliputi *pre-processing* dan proses *learning* dari metode ELM.

Perancangan jaringan sistem yang digunakan dalam proses sistem prediksi jumlah penjualan minuman kopi menggunakan penerapan perkembangan dari model

JST yaitu metode ELM. Metode ini merupakan model inovatif terbaru dari metode Jaringan Saraf Tiruan yang menggunakan algoritma *Single-hidden Layer FeedForward Networks* (SLFNs). Arsitektur dari SLFNs mirip dengan SLFN, perbedaannya terletak pada *hidden neuron*. SLFN memiliki arsitektur *input layer* dan *output layer*. Sedangkan SLFNs memiliki arsitektur *input layer*, *single hidden layer*, dan *output layer*. Pada lapisan *input* digunakan untuk mengolah data inputan dalam bentuk *fitur* misalnya *fitur* X_1, X_2, X_3, X_4 , dan ditambah variabel *target* (T). Pada setiap neuron lapisan *input* yang terbentuk saling terhubung dengan *neuron* lapisan tersembunyi yang dihubungkan oleh variabel *bobot* dan *bias* dengan nilai yang didapatkan secara random.



Gambar 3.3 Arsitektur jaringan metode ELM

Pada Gambar 3.3 di atas dapat dijelaskan bahwa proses metode ELM terdiri dari lapisan *input* dan lapisan *output* yang terhubung melalui lapisan tersembunyi yang biasa disebut *hidden layer*. Pada lapisan *input*, selain memasukkan dataset yang digunakan ada beberapa proses yang dilakukan didalamnya yaitu *pre-processing* yang mana proses ini merupakan tahapan awal untuk mengolah data mentah pada data mining agar mudah diproses oleh sistem. *Pre-processing* pada metode ELM adalah melakukan pembentukan *fitur* dan proses normalisasi data. Pembentukan *fitur* merupakan pengelompokkan data sesuai dengan inputan data jumlah *fitur*. Pengelompokkan data input tersebut selalu disertai nilai *target*. Setelah itu, dilanjutkan pada proses normalisasi data. Adapun persamaan yang digunakan dalam proses normalisasi data sebagai berikut :

$$v' = \frac{v - \min}{\max - \min} \quad (3.1)$$

Keterangan :

v' = Nilai dari hasil normalisasi data

v = Nilai asli data (nilai data index ke-i pada setiap fitur)

min = Nilai minimum dataset fitur X

max = Nilai maksimal dataset fitur X

Pada lapisan tersembunyi (*hidden layer*) proses yang terjadi adalah proses dengan tujuan untuk mendapatkan pola atau formula untuk *output* dari *learning*

metode ELM. *Output* tersebut disebut *output weight* (β). Adapun tahapan proses dalam mendapatkan *output weight* sebagai berikut :

1. Setelah input telah ditentukan dengan beberapa *fitur*, Langkah selanjutnya adalah menginisialisasi nilai input *bobot* (w) dan *bias* (b) secara acak dengan nilai antara -1 dan +1 atau 0 dan 1. Nilai *bobot* dan *bias* ini merupakan nilai yang menghubungkan nilai input dengan nilai keluaran *hidden neuron*.
2. Langkah kedua, proses perhitungan nilai keluaran *hidden neuron* (H_{init}) dibutuhkan nilai *bobot* dan *bias* yang telah ditentukan secara acak sebelumnya. Persamaan yang digunakan dalam proses perhitungan H_{init} sebagai berikut :

$$H_{init\ ij} = (\sum_{k=1}^n w_{jk} \cdot x_{ik}) + b_j \quad (3.2)$$

Keterangan :

H_{init} = Matriks keluaran *hidden neuron*

$i = [1,2 \dots , N)$ dimana N adalah keseluruhan jumlah data

$j = [1,2 \dots , N)$ dimana N adalah keseluruhan jumlah *hidden neuron*

$k = [1,2 \dots , N)$ dimana N adalah keseluruhan jumlah fitur

w = Bobot input (bobot awal)

x = Data input fitur

b = Nilai *bias*

3. Selanjutnya proses menghitung fungsi aktivasi dari hasil H_{init} . Hasil keluaran nilai fungsi aktivasi dilambangkan $H_{(x)}$. Persamaan fungsi aktivasi yang digunakan adalah fungsi aktivasi sigmoid biner dengan menggunakan persamaan sebagai berikut :

$$H_{(x)} = \frac{1}{1+e^{-H_{init}}} \quad (3.3)$$

Keterangan :

$H_{(x)}$ = Fungsi aktivasi sigmoid biner

H_{init} = Nilai keluaran *hidden neuron* sesuai baris ke-i dan kolom ke-j

4. Setelah memperoleh nilai fungsi aktivasi ($H_{(x)}$), selanjutnya melakukan *transpose* matriks hasil keluaran *hidden layer* (H_{init}) dengan fungsi aktivasi *sigmoid* ($H_{(x)}$), hasil keluaran *transpose* ini dilambangkan H^T .
5. Dilanjutkan dengan melakukan perkalian antara matriks hasil *transpose* (H^T) tersebut dengan matriks hasil keluaran *hidden layer* dengan fungsi aktivasi *sigmoid* ($H_{(x)}$).
6. Melakukan proses *invers* matriks pada hasil perkalian matrik H^T dan $H_{(x)}$. Perhitungan matriks $(H^T H)^{-1}$ menggunakan metode *Operasi Baris Elementer* (OBE). Dimana metode OBE dilakukan dengan cara mengganti elemen matriks dengan elemen matriks *identitas*. Sehingga akan menghasilkan matriks *identitas* yang baru. Setelah hasil perhitungan *invers* didapatkan, dilanjutkan pada perkalian antara nilai hasil *invers* dengan nilai

hasil keluaran *hidden layer* yang telah di *transpose*. Adapun persamaan yang digunakan dalam perhitungan invers ini yaitu :

$$H^+ = (H^T H_{(x)})^{-1} H^T \quad (3.4)$$

Keterangan :

H^+ = Moore-Penrose Generalized Invers

$H_{(x)}$ = Matriks keluaran *hidden layer* dengan fungsi aktivasi sigmoid

H^T = Matriks keluaran *hidden layer* dengan fungsi aktivasi sigmoid yang telah di transpose

7. Proses terakhir yaitu perolehan nilai *output* metode ELM dengan cara menghitung *Output Weight* (β) menggunakan nilai dari proses *Moore-Penrose Generalized Invers* dikalikan dengan nilai target. Nilai *Output Weight* (β) ini merupakan penghubung antara *hidden layer* dengan *output layer*. Nilai *output layer* akan dihasilkan dan diproses pada proses selanjutnya. Adapun persamaan yang digunakan dalam perhitungan *Output Weight* yaitu :

$$\beta = H^+ T \quad (3.5)$$

Keterangann :

β = Matriks Output Bobot

H^+ = Matriks Moore-Penrose Generalized Invers

T = Matriks Target

BAB IV

UJI COBA DAN PEMBAHASAN

Bab ini menjelaskan tentang uji coba dan analisa sistem pada implementasi sistem yang telah dibangun. Pada penelitian ini, mengimplementasikan metode Extreme Learning Machine untuk membangun sistem prediksi yang menghasilkan data prediksi jumlah penjualan setiap harinya di bulan mendatang dengan menggunakan data bulan sebelumnya sebagai bahan uji coba yang diproses perhari dari setiap bulan.

4.1 Data Uji

Data uji yang digunakan dalam penelitian ini didapatkan dari hasil interview kepada karyawan kedai Kopi Janji Jiwa. Data yang digunakan sebagai bahan uji coba adalah data jumlah penjualan perhari selama sebulan. Data tersebut akan dijadikan sebagai data input.

Dalam pengujian yang telah dilakukan, data yang digunakan untuk penelitian ini menggunakan 215 sampel data. Data jumlah penjualan perhari pada kedai Kopi Janji Jiwa yang digunakan adalah data penjualan pada bulan Juli-Januari tahun 2020. Data tersebut digunakan sebagai dataset seperti yang ditunjukkan pada Tabel 4.1.

Tabel 4.1 Data penjualan bulan Juli 2020-Januari 2021

No	Tanggal	Jumlah
1	07/01/2020	53
2	07/02/2020	38
3	07/03/2020	45
4	07/04/2020	71
5	07/05/2020	77
6	07/06/2020	27

7	07/07/2020	73
8	07/08/2020	51
...
215	01/31/2021	72

Setelah data terkumpul, dilanjutkan untuk proses pembentukan *fitur*. Data yang digunakan sebagai *dataset* adalah data pada bagian kolom *jumlah* saja. Pembentukan *fitur* merupakan lapisan input yang dilambangkan X. Pembentukan *fitur* juga selalu disertai nilai Target. Data pada kolom *jumlah* tersebut akan diproses dalam pembentukan *fitur* dengan hasil yang ditunjukkan pada Tabel 4.2.

Tabel 4.2 Pembentukan Fitur

No	X1	X2	X3	X4	Target
1	53	38	45	71	77
2	38	45	71	77	27
3	45	71	77	27	73
4	71	77	27	73	51
5	77	27	73	51	59
6	27	73	51	59	63
7	73	51	59	63	71
8	51	59	63	71	90
...
211	38	36	41	63	72

Keterangan untuk setiap parameter dari tabel diatas sebagai berikut :

- Pada tabel diatas, penguji menggunakan 4 fitur yaitu *fitur* X1 sampai X4 yang menunjukkan *fitur* X1 adalah jumlah penjualan hari pertama di bulan Juli, *fitur* X2 adalah jumlah penjualan hari kedua di bulan Juli, begitupun X3 dan X4.

- Setiap pembentukan *fitur* selalu disertai nilai *Target*. Nilai *target* merupakan *target* penjualan perhari.
- Data pada Tabel 4.2 menunjukkan 211 jumlah data. Hal itu dikarenakan *target* pertama menggunakan data input (*fitur*) dari 4 data sebelumnya (sesuai dengan banyaknya *fitur* yang diinisialisasi). Jadi data *target* pertama adalah data pada tanggal 5 Juli 2020. Sehingga, data pada tanggal 1-4 Juli 2020 digunakan untuk data input X1-X4.

Data pada Tabel 4.2 merupakan data sekunder yang akan dilanjutkan lagi dalam pengolahan proses normalisasi data dengan menggunakan pengolah data *min-max normalization*. Sebelum dilakukannya normalisasi data, terlebih dahulu membagi data antara data *training* dan *testing* dengan perbandingan 90%:10%. Pembagian data dilakukan sebelum proses normalisasi bertujuan untuk mendapatkan nilai kesalahan (*error*) yang lebih optimal. Berikut tabel yang menunjukkan pembagian data *training* dan *testing*.

Tabel 4.3 Data Training

No	X1	X2	X3	X4	Target
1	53	38	45	71	77
2	38	45	71	77	27
3	45	71	77	27	73
4	71	77	27	73	51
5	77	27	73	51	59
6	27	73	51	59	63
7	73	51	59	63	71

8	51	59	63	71	90
...
190	38	36	41	63	72

Tabel 4.4 Data Testing

No	X1	X2	X3	X4	Target
191	53	38	45	71	77
192	38	45	71	77	27
193	45	71	77	27	73
194	71	77	27	73	51
195	77	27	73	51	59
196	27	73	51	59	63
197	73	51	59	63	71
198	51	59	63	71	90
...
211	38	36	41	63	72

Setelah pembagian data, dilanjutkan pada proses normalisasi dengan langkah-langkah sebagai berikut :

Langkah pertama : mencari nilai minimal dan maksimal dari dataset (data keseluruhan). Pencarian nilai minimal dan maksimal data *training dan testing* terdapat pada Tabel 4.5 dan 4.6.

Tabel 4.5 Nilai minimal dan maksimal data *training*

Minimal	20
---------	----

Maksimal	111
----------	-----

Tabel 4.6 Nilai minimal dan maksimal data *testing*

Minimal	34
Maksimal	93

Langkah kedua : menghitung nilai yang akan dinormalisasikan dengan menggunakan Persamaan 3.1. Dari perhitungan tersebut akan menghasilkan nilai range antara 0-1 dan membentuk pola dari proses *fitur* sebelumnya. Hasil normalisasi ini akan digunakan sebagai nilai inputan X1, X2, X3, X4, dan disertai nilai Target. Berikut hasil normalisasi data yang telah dilakukan.

Tabel 4.7 Normalisasi data *training*

No	X1	X2	X3	X4	Target
1	0,3626	0,1978	0,2747	0,5604	0,6263
2	0,1978	0,2747	0,5604	0,6263	0,0769
3	0,2747	0,5604	0,6263	0,0769	0,5824
4	0,5604	0,6263	0,0769	0,5824	0,3406
5	0,6263	0,0769	0,5824	0,3406	0,4285
6	0,0769	0,5824	0,3406	0,4285	0,4725
7	0,5824	0,3406	0,4285	0,4725	0,5604
8	0,3406	0,4285	0,4725	0,5604	0,7692
...
190	0,4285	0,4065	0,6263	0,6153	0,4835

Tabel 4. 8 Normalisasi data *testing*

No	X1	X2	X3	X4	Target
191	0,4065	0,6263	0,6153	0,4835	0,6483

192	0,6263	0,6153	0,4835	0,6483	0,4725
193	0,6153	0,4835	0,6483	0,4725	0,6263
194	0,4835	0,6483	0,4725	0,6263	0,3956
195	0,6483	0,4725	0,6263	0,3956	0,8021
196	0,4725	0,6263	0,3956	0,8021	0,4725
197	0,6263	0,3956	0,8021	0,4725	0,5934
198	0,3956	0,8021	0,4725	0,5934	0,2527
...
211	0,1978	0,1758	0,2307	0,4725	0,5714

Pada Tabel 4.7 dan 4.8 menunjukkan hasil proses normalisasi data, dimana hasilnya akan berada di range nilai 0-1. Dari hasil normalisasi data tersebut dilanjutkan pada pembagian data yaitu data *training* dan *testing*. Pembagian data *training* dan *testing* sesuai dengan kebutuhan. Pada penelitian ini, penguji menggunakan pembagian data dengan perbandingan 90:10.

4.2 Training

Proses *training* dilakukan dengan tujuan mendapatkan *output weight*. Nilai *output weight* ini yang akan digunakan pada proses *testing* untuk mendapatkan nilai *output layer (prediksi)*. Data yang digunakan pada proses *training* adalah hasil dari pembagian data normalisasi dengan perbandingan 90:10 untuk data *training* dan data *testing*. Hasil pembagian data *training* ditunjukkan pada Tabel 4.7.

Data *training* diproses untuk melakukan pelatihan agar dapat menghasilkan nilai *output weight* atau bobot akhir pada proses *training*. Adapun tahapan dari proses *training* sebagai berikut :

1. Memasukkan data *input* yaitu data hasil pembagian dari data normalisasi untuk proses *training*.
2. Dilanjutkan memproses data *training* dengan nilai *input weight* atau nilai *bobot* awal dan *bias* yang didapatkan dari inialisasi nilai *input weight* dan *bias* secara random dengan nilai antara 0 dan 1. Berikut nilai *input weight* atau bobot awal dan bias yang digunakan dalam pengujian data ini.

Tabel 4. 9 Nilai input weight (bobot awal)

No.	w1	w2	w3
1	0,27	0,22	0,73
2	0,86	0,34	0,48
3	0,19	0,75	0,03
4	0.44	0,21	0,81

Tabel 4.10 Nilai bias

No.	b1	b2	b3
1	0,2	0,18	0,44

3. Perhitungan nilai keluaran *hidden layer* dengan menggunakan fungsi H_{init} sesuai Persamaan 3.2. Adapun hasil dari perhitungan H_{init} ditunjukkan pada tabel di bawah.

Tabel 4.11 Hasil H_{init}

No	Hinit1	Hinit2	Hinit3
1	0,6878	1,1263	0,8372
2	0,7618	1,2338	0,8633
3	0,5090	1,1211	0,9409
4	0,8745	1,5967	1,1009
5	0,6571	1,1685	1,0979

6	0,6298	1,1602	0,7392
...
190	0,8974	1,5472	1,1425

4. Perhitungan nilai *fungsi aktivasi sigmoid biner* keluaran *hidden layer* dengan menggunakan fungsi H_x sesuai Persamaan 3.3. Adapun hasil dari perhitungan *fungsi aktivasi* ditunjukkan pada tabel di bawah.

Tabel 4.12 Hasil fungsi aktivasi sigmoid biner

No	H(x)1	H(x)2	H(x)3
1	0,6654	0,7551	0,6978
2	0,6817	0,7744	0,7033
3	0,6245	0,7541	0,7193
4	0,7056	0,8315	0,7504
5	0,6586	0,7628	0,7498
6	0,6524	0,7613	0,6768
...
190	0,7104	0,8245	0,7581

5. Melakukan *transpose* matriks *fungsi aktivasi* keluaran *hidden layer* yang hasilnya dilambangkan dengan H^T . Adapun hasil dari proses *transpose* data ditunjukkan pada tabel di bawah.

Tabel 4.13 Hasil transpose data

Simbol	1	2	3	4	5	...	190
H(x)1	0,6654	0,6817	0,6245	0,7056	0,6586	0,7104
H(x)2	0,7551	0,7744	0,7541	0,8315	0,7628	0,8245
H(x)3	0,6978	0,7033	0,7193	0,7504	0,7498	0,7581

6. Menghitung perkalian data *fungsi aktivasi* H_x dengan data *transpose* H^T .

Hasil perkalian H_x dan H^T tersebut ditunjukkan pada tabel di bawah ini.

Tabel 4. 14 Hasil perkalian H_x dengan H^T

109,526	123,363	114,739
123,363	139,016	129,247
114,739	129,247	120,242

7. Mencari nilai invers dari hasil perkalian nilai *transpose* dan *fungsi aktivasi sigmoid biner*. Adapun hasil dari perhitungan *invers* data ditunjukkan pada tabel di bawah.

Tabel 4.15 Hasil invers

13,8195	-4,9069	-7,9126
-4,9069	5,9229	-1,6842
-7,9126	-1,6842	9,3639

8. Menghitung perkalian hasil dari nilai *invers* dan *transpose*, yang mana hasil ini disebut hasil *Moore-Penrose Generalized Invers* (H^+). Adapun hasil dari perhitungan *Moore-Penrose Generalized Invers* data ditunjukkan pada gambar di bawah.

Tabel 4.16 Hasil *Moore-Penrose Generalized Invers*

Simbol	1	2	3	4	5	...	190
H(x)1	-0,2998	-0,1221	0,3210	-0,2562	0,0037	-0,0256
H(x)2	0,1453	0,2234	-0,0539	-0,0038	-0,0281	0,0846
H(x)3	0,1322	-0,1214	-0,2461	0,2511	0,0289	-0,0640

9. Proses terakhir menghitung nilai *output weight* sesuai Persamaan 3.5. Adapun hasil dari perhitungan *output weight* data ditunjukkan pada gambar di bawah.

Tabel 4.17 Hasil output weight

0,7471
0,3160
0,6148

4.3 Testing

Nilai *output weight* yang telah didapatkan pada proses sebelumnya, akan digunakan kembali pada proses *testing* untuk mendapatkan nilai prediksi. Pada proses *testing*, tentunya membutuhkan data *testing* yang telah dinormalisasikan. Hasil pembagian data *testing* yang telah dinormalisasikan ditunjukkan pada Tabel 4.8.

Data *testing* digunakan sebagai data penguji untuk menentukan hasil dari *output layer* (*hasil prediksi*) dan dilanjutkan ke proses mengubah data hasil prediksi yang ada pada range 0-1 ke data asli. Langkah-langkah dalam proses *testing*, sebagai berikut :

1. Langkah-langkah proses *testing* hampir sama dengan proses *training*. Perbedaannya adalah proses *testing* tidak lagi mencari nilai random *bobot awal* dan *bias* lagi, melainkan menggunakan nilai yang telah didapatkan pada proses *training*. Langkah pertama dari proses *testing* yaitu mencari H_{init} . Persamaan yang digunakan dalam mencari H_{init} pada proses *testing* sama dengan persamaan yang digunakan proses *training* dalam mencari hasil H_{init} . Berikut hasil H_{init} yang didapatkan dari proses *testing*.

Tabel 4.18 Hasil H_{init} proses *testing*

No	Hinit1	Hinit2	Hinit3
191	1,5701	2,1205	1,5568
192	1,6575	2,1274	1,6646
193	1,6165	2,0850	1,6601
194	1,5821	2,0979	1,5663
195	1,6007	2,0341	1,6284
...
211	0,9187	1,3826	0,9574

2. Langkah kedua mencari nilai *fungsi aktivasi* dari data *testing*. Persamaan yang digunakan sama dengan proses *training*. Berikut hasil dari *fungsi aktivasi* proses *testing*.

Tabel 4.19 Hasil fungsi aktivasi proses *testing*

No	H(x)1	H(x)2	H(x)3
191	0,8278	0,8928	0,8259
192	0,8399	0,8935	0,8408
193	0,8343	0,8894	0,8402
194	0,8295	0,8907	0,8272
195	0,8321	0,8843	0,8359
....
211	0,7148	0,7994	0,7226

3. Setelah mendapatkan hasil *fungsi aktivasi*. Selanjutnya, menghitung nilai prediksi (lapisan *output*). Persamaan yang digunakan dalam menghitung lapisan *output* sebagai berikut :

$$Y = H\beta \quad (4.1)$$

Keterangan :

β = Matriks Output Bobot

H = Matriks Keluaran Hidden Fungsi Aktivasi

Perhitungan nilai prediksi (*output layer*) melibatkan hasil *output weight* yang didapatkan dari proses *training*. Tabel berikut adalah hasil yang menunjukkan dari perhitungan nilai prediksi.

Tabel 4.20 Hasil *output layer* (prediksi)

No	Result
1	0,4221
2	0,6254
3	0,2823
4	0,7644
5	0,3257
6	0,5896
7	0,2343
8	0,3592
9	0,5103
....
21	0,6923

4. Hasil dari *output layer* dirubah ke data asli dengan perhitungan denormalisasi data. Persamaan denormalisasi data yang digunakan sebagai berikut :

$$v = v'(max - min) + min \quad (4.2)$$

Keterangan :

v' = Nilai dari hasil normalisasi data

v = Nilai asli data (nilai data index ke-i pada setiap fitur)

min = Nilai minimum dataset fitur X

\max = Nilai maksimal dataset fitur X

Hasil dari proses denormalisasi data ditunjukkan pada tabel di bawah ini.

Tabel 4.21 Hasil denormalisasi data

No	Result
1	58.9095
2	70.8946
3	50.5253
4	80.4623
5	56.7110
6	69.7519
7	50.7702
8	57.3788
9	69.0476
...
21	77,5808

4.4 Hasil dan Analisis Pembahasan

Hasil prediksi yang didapatkan dari proses *testing* dievaluasi kinerjanya untuk mengetahui nilai kesalahan (*error*) beserta nilai akurasi. Pengukuran nilai kesalahan (*error*) yang digunakan dalam penelitian ini adalah *Mean Absolut Persen Error* (MAPE).

4.4.1 Hasil dan Analisis Nilai Error Menggunakan Metode MAPE

Metode MAPE merupakan pengukuran pada suatu metode yang diimplementasikan untuk dievaluasi nilai kesalahan (*error*) dibandingkan dengan hasil prediksi yang didapatkan. Perhitungan nilai *error* dilakukan dalam persamaan sebagai berikut :

$$MAPE = \sum_{t=1}^n \frac{|x_t - y_t|}{x_t} \times 100\% \quad (4.3)$$

Keterangan :

n = Jumlah data

$t = [1, 2, \dots, n]$, n adalah keseluruhan jumlah data

x_t = Nilai aktual (asli)

y_t = Nilai hasil prediksi

Dengan hasil akhir dari nilai MAPE berbentuk persentase. Metode MAPE ini sangat membantu dalam pengujian suatu metode peramalan, apakah metode tersebut menghasilkan hasil prediksi yang baik dan akurat atau tidak. Hasil dari nilai *error* ini pun dapat dijadikan perbandingan dengan metode-metode peramalan yang lain.

Tabel 4.22 Hasil evaluasi nilai kesalahan (error)

No	Nilai Error
1	6.4927%
2	7.9290%
3	9.7761%
4	13.4813%
5	9.9825%
6	5.7405%
...
21	7,7512%

Dari keseluruhan data yang telah didapatkan dalam mencari nilai *error* di atas, dapat disimpulkan bahwa rata-rata dari data nilai *error* adalah 8,2751%.

4.4.2 Hasil dan Uji Coba Kombinasi Variasi Jumlah Fitur Data, Jumlah Hidden Neuron, dan Jumlah Epoch

Berdasarkan pengujian yang telah dilakukan digunakan untuk menentukan jumlah *fitur* data terbaik dan paling cocok agar menghasilkan nilai *error* terkecil pada sistem prediksi jumlah penjualan minuman kopi. Penentuan *fitur* menggunakan jumlah penjualan sehari sebelumnya disetiap *fitur* yang terbentuk. Pengujian jumlah *fitur* data dan *hidden neuron* ini menggunakan parameter *bobot* awal (*input weight*) dan *bias* secara random dalam range [0, 1], menggunakan fungsi aktivasi *sigmoid biner*, serta menggunakan perbandingan data *training* dan *testing* sebesar 90%:10%. Hasil pengujian variasi jumlah *fitur* data dan jumlah *hidden neuron* ditunjukkan dalam nilai rata-rata MAPE dalam persen pada tabel berikut.

Tabel 4.23 Nilai rata-rata MAPE kombinasi variasi jumlah *fitur* data, jumlah *hidden neuron*, dan jumlah *epoch*

Jumlah Fitur	Jumlah Hidden Neuron (%)													
	2		3		4		5		6		7		8	
	error	ep	error	ep	error	ep	Error	ep	error	ep	error	ep	error	ep
1	6,363	2	9,622	3	9,593	4	15,123	5	17,277	6	12,435	7	12,542	8
2	9,622	4	9,319	6	7,674	8	17,233	10	13,829	12	28,184	14	26,163	16
3	9,538	6	6,791	9	11,012	12	15,345	15	27,324	18	15,126	21	22,241	24
4	9,539	16	8,395	12	8,275	16	17,345	20	11,345	24	17,675	28	11,234	32

5	10,234	10	6,323	15	14,532	20	17,454	25	13,234	30	21,345	35	27,452	40
6	11,234	12	5,651	18	7,874	24	13,233	30	17,435	36	14,876	42	21,234	48
7	13,324	14	9,022	21	6,300	28	14,134	35	12,324	42	24,657	49	12,248	54
8	7,213	16	8,498	24	18,449	32	16,342	40	19,453	48	12,453	54	22,859	64

Pada Tabel 4.23 di atas menjelaskan bahwa nilai terbaik terletak pada tabel tersebut yaitu pada baris ke-6 sebagai jumlah *fitur* data terbaik dan pada kolom ke-3 sebagai jumlah *hidden neuron* terbaik dan telah melakukan *epoch* sebanyak 18 kali. Hal itu dikarenakan nilai tersebut memiliki nilai *error* MAPE terkecil yaitu 5,6518%.

4.4.3 Pembahasan Hasil dan Uji Coba Kombinasi Variasi Jumlah Fitur

Data, Jumlah Hidden Neuron, dan Jumlah Epoch

Pada Tabel 4.23 telah ditunjukkan bahwa jumlah *fitur* terbaik berada pada angka ke-6 dan jumlah *hidden neuron* terbaik berada pada angka ke-3 serta berhenti pada *epoch* ke-18. Hal tersebut dapat disimpulkan bahwa jumlah *fitur*, jumlah *hidden neuron*, dan jumlah *epoch* mempengaruhi hasil prediksi yang didapatkan. Pada data diatas ditunjukkan pula bahwa semakin banyak *hidden neuron* nilai *error* yang dihasilkan semakin besar. Hal tersebut dikarenakan mengalami *overfitting*, yaitu pembentukan pola yang terlalu banyak dengan dataset yang kecil (sederhana) menyebabkan pembentukan sulit diidentifikasi akhirnya mengalami kenaikan nilai kesalahan yang cukup tinggi.

Berdasarkan dari hasil pengujian pencarian jumlah terbaik dari *fitur*, *hidden neuron*, dan *epoch* di atas. Dapat dijadikan acuan dalam pencarian nilai

prediksi terbaik atau paling mendekati nilai aslinya dan menghasilkan nilai *error* MAPE paling kecil pada penelitian ini. Oleh karena itu, peneliti menguji data jumlah penjualan sebagai data prediksi untuk mencari nilai prediksi menggunakan jumlah *fitur* dan *hidden neuron* terbaik yaitu X6 dan 3 dengan jumlah *epoch* ke-18. Hasil dari pengujian tersebut dapat dilihat dalam tabel di bawah ini.

Tabel 4.24 Perbandingan data asli dan data prediksi

Data ke-	Nilai Asli	Nilai Prediksi	MAPE (%)
1	63	60,9091	3,3190
2	77	70,8942	7,9298
3	56	50,5253	9,7767
4	93	90,4625	2,7290
5	63	60,7112	3,6333
6	74	70,7521	4,3891
7	43	40,7716	5,1860
8	64	60,3787	5,6593
9	77	70,0475	9,0298
10	51	49,6936	2,5627
11	34	35,8937	5,5676
12	85	78,9913	7,0705
13	62	59,9285	3,3419
14	54	49,8321	7,7185
15	56	59,3213	5,9285
16	38	36,1225	4,9421
17	36	34,6994	3,6138
18	41	43,5593	6,2414
19	63	67,1871	6,6460
20	72	77,5815	7,7512

Pada Tabel 4.24 menunjukkan hasil prediksi yang menggunakan jumlah *fitur* terbaik yaitu 6 dan jumlah *hidden neuron* terbaik yaitu 3. Dari hasil yang didapatkan,

nilai rata-rata dari nilai *error* MAPE dari jumlah *fitur* dan *hidden neuron* terbaik adalah 5,6518%.

Dalam menjalani kehidupan di dunia, manusia tidak akan jauh dengan peramalan. Ramalan dalam hukum islam ada yang diperbolehkan dan ada juga yang dilarang oleh syariat islam karena mendekati kesyirikan. Ketika seseorang mempercayai ramalan yang dibuat sendiri atau dari orang lain, maka hal tersebut sama halnya dengan menduakan Allah SWT. Dengan firman Allah dalam Al-quran :

قُلْ لَا يَعْلَمُ مَنْ فِي السَّمٰوٰتِ وَالْاَرْضِ الْغَيْبَ اِلَّا اللّٰهُ ۗ وَمَا يَشْعُرُوْنَ اَيَّٰنَ يُّبْعَثُوْنَ

“Katakanlah (Muhammad), “Tidak ada sesuatu pun di langit dan di bumi yang mengetahui perkara yang gaib, kecuali Allah. Dan mereka tidak mengetahui kapan akan dibangkitkan.” (QS. An-naml: 65)

Namun, jika ramalan tersebut berlandaskan ilmu pengetahuan dan hasil dari ramalan tersebut adalah perkiraan bukan ketetapan yang dijadikan pegangan hidup, maka ramalan seperti itu diperbolehkan oleh syariat islam. Allah SWT telah memerintahkan kita untuk selalu mengikuti pengetahuan bukan dari hawa nafsu kita, dengan firman Allah sebagai berikut :

بَلِ اتَّبَعَ الَّذِيْنَ ظَلَمُوْا عَنْهُمْ بِعَبْرِ عَيْمٍ ۗ فَمَنْ يُّهْدِيْ مَنْ اَضَلَّ اللّٰهُ ۗ وَمَا لَهُمْ مِّنْ تُصْرِيْنَ

“Tetapi orang-orang yang dzalim, mengikuti keinginannya tanpa ilmu pengetahuan; maka siapakah dapat memberi petunjuk kepada orang yang telah disesatkan Allah. Dan tidak ada seorang penolong pun bagi mereka.” (QS. Ar-rum: 29)

Hal yang menunjukkan keesaan dan kekuasaan Allah sudah sangat jelas. Akan tetapi, karena pada dasarnya para hambanya ingin menolak hal itu, maka orang-orang yang dzalim hanya mengikuti keinginannya (hawa nafsu) yang tidak berlandaskan ilmu pengetahuan yang benar dan logis. Secara tidak langsung, hamba-hamba itu memilih jalan kesesatan. Dan siapakah yang yang dapat memberi petunjuk untuk menolong hamba tersebut menuju jalan yang benar, jawabannya tidak ada. Karena tidak akan ada satu orangpun yang akan menolong orang-orang dzalim dan syirik kepada Allah di akhirat nanti.

BAB V

PENUTUP

Bab ini menjelaskan tentang kesimpulan dari hasil penelitian yang telah dilakukan dengan pembahasan dari pernyataan masalah, serta saran yang dapat dijadikan sebagai acuan untuk peneliti lainnya agar menghasilkan sistem yang lebih baik.

5.1 Kesimpulan

Berdasarkan hasil dari pengujian dan pembahasan yang telah diuraikan pada bab-bab sebelumnya mengenai prediksi penjualan minuman kopi menggunakan metode *Extreme Learning Machine* (ELM), maka didapatkan kesimpulan sebagai berikut :

1. Metode *Extreme Learning Machine* (ELM) yang digunakan dalam penelitian perancangan sistem prediksi penjualan minuman kopi menghasilkan nilai *error* yang kecil yaitu 8,2751% pada jumlah *fitur* ke-4 dan jumlah *hidden neuron* ke-3.
2. Hasil dari percobaan yang telah dilakukan sebanyak 8 kali menggunakan perbandingan jumlah data 90%:10% untuk data *training* dan data *testing*, menggunakan fungsi aktivasi sigmoid biner dalam pencarian jumlah *hidden layer* dan *fitur* terbaik didapatkan jumlah terbaik dari *hidden layer* adalah 3 dan jumlah terbaik dari *fitur* adalah 6 serta jumlah *epoch* berhenti pada angka 18. didapatkan tingkat kesalahan (*error*) yang diuji dengan perhitungan

MAPE yaitu sebesar 5,6518%. Jumlah *hidden layer* mempengaruhi hasil perhitungan, serta pada lapisan *input* terdapat pembentukan *fitur* yang juga jumlahnya dapat mempengaruhi hasil perhitungan.

5.2 Saran

Berdasarkan penelitian yang telah dilakukan, adapun beberapa saran yang dapat dikembangkan untuk penelitian selanjutnya yaitu :

1. Untuk penelitian selanjutnya, peneliti dapat menambahkan pengujian variasi perbandingan jumlah data dan variasi penggunaan fungsi aktivasi sebagai faktor-faktor yang dapat mempengaruhi nilai tingkat kesalahan agar dapat menghasilkan nilai yang lebih baik lagi dari metode ELM.
2. Perbandingan metode ELM dengan metode lain dapat dijadikan sebagai penelitian selanjutnya untuk menambah referensi keakuratan metode ELM.

DAFTAR PUSTAKA

- Ahmad, I., Basher, M., Iqbal, M. J. & Rahim, A. A., 2018. Performance Comparison of Support Vector Machine, Random Forest, and Extreme Learning Machine for Intrusion Detection. *IEEE*.
- Alfiyatin, A. N., Mahmudy, W. F., Ananda, C. F. & Anggodo, Y. P., 2019. Penerapan Extreme Learning Machine (ELM) Untuk Peramalan Laju Inflasi Di Indonesia. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 6(2), pp. 179-186.
- Ali, P. J. M. & Faraj, R. H., 2014. Data Normalization and Standardization: A Technical Report. *Machine Learning Technical Reports*.
- asy-Syaqawi, S. A. b. A., 2014. *Tafsir Surat al-Insyirah*. [Online] Available at: https://d1.islamhouse.com/data/id/ih_articles/single3/id_Tafsir_Surat_al-Insyirah.pdf [Accessed 18 Februari 2021].
- Burhanudin, T., 2020. *Kopi Janji Jiwa, Tetap Tegar Meski Dihadang Pandemi*. [Online] Available at: <https://marketing.co.id/kopi-janji-jiwa-tetap-tegar-meski-dihadang-pandemi/> [Accessed 09 Februari 2021].
- Chatfield, C., 2000. *Time-Series Forecasting*. United States of America: CRC Press.
- Ding, S., Zhao, H. & Zhang, Y., 2013. Extreme learning machine: algorithm, theory and applications. *Artificial Intelligence Review*.
- Fardani, D. P., Wuryanto, E. & Werdiningsih, I., 2015. Sistem Pendukung Keputusan Peramalan Jumlah Kunjungan Pasien Menggunakan Metode Extreme Learning Machine (Studi Kasus : Poli Gigi RSUD. Wahidin Sudiro Husodo Mojokerto). *Journal of Information Systems Engineering and Business Intelligence*.
- Fitriati, D., 2016. Perbandingan Kinerja CNN LeNet 5 dan Extreme Learning Machine Pada Pengenalan Citra Tulis Tangan Angka. *Jurnal Teknologi Terpadu*.
- Gencal, T. G., 2019. Analisis Manajemen Persediaan Bahan Baku Pada Kedai Kopi JJ Jilid 138 Di Kabupaten Purwakarta.
- Hafni, R. D., Azzahra, A. A. & Rosdiani, K., 2020. Pandangan Citra Brand Kopi Janji Jiwa di Kalangan Mahasiswa. *Jurnal Ilmiah Komunikasi Makna*, 8(1), pp. 12-21.

- Huang, G.-B., Zhu, Q.-Y. & Siew, C.-K., 2004. Extreme Learning Machine: A New Learning Scheme of Feedforward Neural Networks. *Proceedings of International Joint Conference on Neural Networks*.
- Isna, T. D., 2020. *Startup Story: Janji Jiwa, Kopi yang Terjual Jutaan Gelas/Bulan*. [Online]
Available at: <https://www.wartaekonomi.co.id/read302577/startup-story-janji-jiwa-kopi-yang-terjual-jutaan-gelasbulan>
[Accessed 10 Februari 2021].
- Izati, N. A., Warsito, B. & Widiharih, T., 2019. Prediksi Harga Emas Menggunakan Feed Forward Neural Network Dengan Metode Extreme Learning Machine. *Jurnal Gaussian*, pp. 171-183.
- Koksoy, O., 2006. Multiresponse robust design: Mean square error (MSE) criterion. *Applied Mathematics and Computation*.
- Komarudin, 2020. *Cerita Perjuangan Janji Jiwa Bertahan Selama Pandemi Corona COVID-19*. [Online]
Available at: <https://www.liputan6.com/lifestyle/read/4237024/cerita-perjuangan-janji-jiwa-bertahan-selama-pandemi-corona-covid-19>
[Accessed 09 Februari 2021].
- Kusumawardhani, N. Q., 2019. *Kopi Janji Jiwa, Bertahan dengan Racikan Robusta Sumatra*. [Online]
Available at: <https://www.republika.co.id/berita/gaya-hidup/kuliner/19/06/26/ptois4414-kopi-janji-jiwa-bertahan-dengan-racikan-robusta-sumatra>
[Accessed 09 Februari 2021].
- Lesnussa, Y. A., Latuconsina, S. & Persulesy, E. R., 2015. Aplikasi Jaringan Saraf Tiruan Backpropagation untuk Memprediksi Siswa SMA (Studi kasus Prediksi Prestasi Siswa SMAN 4 Ambon). *Jurnal Matematika Integratif*.
- Lestari, A. A., 2020. Analisis Perbandingan Brand Equity Kopi Janji Jiwa dan Kopi Kenangan.
- Maricar, M. A., 2019. Analisa Perbandingan Nilai Akurasi Moving Average dan Exponential Smoothing untuk Sistem Peramalan Pendapatan pada Perusahaan XYZ. *Jurnal Sistem Dan Informatika*.
- Maricar, M. A. & Pramana, D., 2019. Perbandingan Akurasi Naïve Bayes dan K-Nearest Neighbor pada Klasifikasi untuk Meramalkan Status Pekerjaan Alumni ITB STIKOM Bali. *Jurnal Sistem Dan Informatika (JSI)*.
- Miftahuddin, 2020. *Tafsir Surat Al-Insyirah: Sebuah Seni Menyelesaikan Masalah*. [Online]

Available at: <https://islami.co/tafsir-surat-al-insyirah-sebuah-seni-menyelesaikan-masalah/tafsir-surat-al-insyirah-ayat-94-sebuah-seni-menyelesaikan-masalah/>
[Accessed 18 Februari 2021].

Mosabeth, C., Furqon, T. M. & Wihandika, R. C., 2018. Prediksi Harga Pasar Daging Sapi Di Kota Malang Dengan Menggunakan Metode Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*.

Nachrowi, N. D. & Usman, H., 2004. *Teknik Pengambilan Keputusan*. s.l.:Grasindo.

Pangaribuan, J. J., 2016. Mendiagnosis Penyakit Diabetes Melitus Dengan Menggunakan Metode Extreme Learning Machine. *Jurnal ISD*.

Park, D. C. et al., 1991. Electric Load Forecasting Using An Artificial Neural Network. *IEEE*.

Pratiwi, H. & Harianto, K., 2019. Perbandingan Algoritma ELM Dan Backpropagation Terhadap Prestasi Akademik Mahasiswa. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 3(2), pp. 282-294.

Saranya, C. & Manikandan, G., 2013. A Study on Normalization Techniques for Privacy Preserving Data Mining. *International Journal of Engineering and Technology (IJET)*.

Setiawan, K., 2019. *Cerita Kopi Janji Jiwa Punya 700 Outlet dalam 1,5 Tahun*. [Online]
Available at: <https://bisnis.tempo.co/read/1287267/cerita-kopi-janji-jiwa-punya-700-outlet-dalam-15-tahun/full&view=ok>
[Accessed 10 Februari 2021].

Sinha, S. K. & Wang, M. C., 2008. Artificial Neural Network Prediction Models for Soil Compaction and Permeability. *Geotechnical and Geological Engineering*.

Susila, D., 2020. *Al-Qur'an Digital*. [Online]
Available at: <https://kalam.sindonews.com/surah/94/al-insyirah>
[Accessed 18 Februari 2021].

Tandiono, C. M. & Sahetapy, W. L., 2020. Analisis Brand Personality Dari Franchise Kopi Janji Jiwa Di Surabaya. *AGORA*, 8(1).

Ulya, F. N., 2020. *Mau Bikin Franchise Sukses Seperti Janji Jiwa? Perhatikan 3 Hal Ini*. [Online]
Available at: <https://money.kompas.com/read/2020/06/17/150139826/mau-bikin-franchise-sukses-seperti-janji-jiwa-perhatikan-3-hal-ini?page=all>
[Accessed 10 Februari 2021].

- Wibawa, M. S., 2016. Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch. *Jurnal Sistem dan Informatika*.
- Widodo, A. P., Suhartono, Sarwoko, E. A. & Firdaus, Z., 2017. Akurasi Model Prediksi Metode Backpropagation Menggunakan Kombinasi Hidden Neuron Dengan Alpha. *Jurnal Matematika*, pp. 79-84.
- Wuryandari, M. D. & Afrianto, I., 2012. Perbandingan JST Backpropagation dan Learning Vector Quantization Pada Pengenalan Wajah. *Jurnal Komputer dan Informatika (KOMPUTA)*.
- Xu, Y. et al., 2011. Real-time transient stability assessment model using extreme learning machine. *IET generation, transmission & distribution*.
- Yang, Z., Ce, L. & Lian, L., 2017. Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods. *Applied Energy*.
- Yaseen, Z. M. et al., 2018. Predicting compressive strength of lightweight foamed concrete using extreme learning machine model. *Advances in Engineering Software*.