

BAB II

TINJAUAN PUSTAKA

2.1 Inflasi

2.1.1 Pengertian Inflasi

Menurut KBBI, “Inflasi dapat diartikan sebagai penurunan nilai uang kertas karena peningkatan jumlah dan laju peredaran uang kertas dengan cepat. Hal ini menyebabkan kenaikan harga barang-barang”. Sedangkan menurut Bank Indonesia, “Inflasi merupakan kenaikan harga terhadap barang dan jasa yang berlangsung secara umum dan terus-menerus dalam kurun waktu tertentu”. Senada dengan Pengertian inflasi dari Bank Indonesia. Menurut Badan Pusat Statistik (BPS), “Inflasi adalah kondisi ekonomi suatu negara di mana terjadi kecenderungan naiknya harga-harga barang dan jasa dalam jangka waktu yang lama”(Bank Indonesia; Ikasari Heniyatun, 2023).

Dari ketiga pengertian di atas terkait inflasi dapat diambil kesimpulan bahwa Inflasi adalah fenomena ekonomi di mana nilai uang menurun karena peningkatan jumlah uang beredar dengan cepat. Akibatnya, harga barang dan jasa cenderung terus naik dalam jangka waktu yang lama. Dengan kata lain, daya beli uang menurun, masyarakat perlu membayar lebih banyak uang untuk memperoleh barang dan jasa yang sama dan tidak didukung oleh ketersediaan pasokan sehingga menyebabkan kenaikan harga dan menurunkan daya beli masyarakat dan hal ini dapat menyebabkan ketidakstabilan ekonomi yang dapat merugikan negara

Berikut beberapa Teori terkait Inflasi, sebagai berikut (Simanungkalit, 2020):

1. Teori Kuantitas

Jumlah uang beredar mempengaruhi kenaikan harga. Hal ini berhubungan dengan ketersediaan jumlah barang tetap tetapi sedangkan permintaan jumlah uang bertambah menjadi dua kali lipat, hal ini akan menyebabkan kenaikan harga dua kali lipat

2. Teori Keynes

Inflasi dapat terjadi ketika keinginan yang berlebihan terhadap barang atau jasa yang tersedia. Ketika permintaan bertambah tetapi penawaran tetap akan terjadi kenaikan harga dan pemerintah akan mencetak uang untuk membeli barang dan jasa tersebut. contoh inflasi terjadi ketika pengusaha mendapatkan kredit untuk membeli barang dan jasa sehingga permintaan meningkat sedangkan penawaran tetap. Hal ini akan mengakibatkan kenaikan harga.

3. Teori Struktural

Pada hal ini produsen tidak dapat segera mengantisipasi ketika melonjaknya pertumbuhan penduduk yang menyebabkan meningkatnya permintaan dan menyebabkan tidak terpenuhinya permintaan tersebut.

Apabila kenaikan terjadi pada satu atau dua barang saja tidak dapat disebut sebagai inflasi dikarenakan inflasi terjadi kenaikan harga barang dan jasa secara umum dan menyebar. Seperti meningkatnya permintaan terhadap suatu barang atau jasa tetapi ketersediaan barang tersebut tidak ada dapat terpenuhi, hal ini dapat mengakibatkan kenaikan harga yang disebut sebagai inflasi. Bank Indonesia (BI) merupakan Lembaga yang bertanggung jawab dalam menjaga kestabilan tingkat inflasi di Indonesia(Savitri *et al.*, 2021).

Dalam memantau perubahan harga barang dan jasa yang menjadi konsumsi pokok Masyarakat ditetapkan Alat pengukur inflasi menggunakan IHK atau indeks harga konsumen yang dibagi menjadi 11 (sebelas) kategori Bank Indonesia, antara lain:

1. Makanan, minuman dan tembakau
2. Pakaian dan alas kaki
3. Perumahan, air rumah tangga, listrik dan pasokan bahan bakar
4. Peralatan rumah tangga, peralatan dan perawatan rutin
5. Kesehatan
6. Angkutan

7. Jasa informasi, komunikasi dan keuangan
8. Rekreasi, olah raga dan budaya
9. Pendidikan
10. Kegiatan pelayanan makanan
11. Perawatan pribadi dan layanan lainnya

Adanya peningkatan dari IHK menunjukkan bahwa adanya inflasi, sebaliknya penurunan dari IHK disebut dengan deflasi. IHK ini sering menjadi acuan oleh pemerintah, bank sentral, dan analisis ekonomi guna mendukung pengambil kebijakan ekonomi. Inflasi sangat berhubungan erat dengan IHK, perubahan pada IHK ini bertujuan untuk mengukur perubahan biaya hidup rumah tangga. Yang Dimana perubahan biaya hidup rumah tangga ini berkaitan dengan kemampuan pendapatan seseorang. Rendahnya penghasilan seseorang dapat menghabiskan lebih banyak anggaran untuk kebutuhan dasarnya. IHK digunakan sebagai alat ukur inflasi dan deflasi dalam perekonomian(Cristanti, Ismanto and Sitorus, 2020)

Berdasarkan IHK berdasarkan kelompok pengeluaran barang dan jasa, IHK pun terbagi menjadi tiga kelompok penilaian guna mempermudah pemerintah dan pemerintah Indonesia dalam memberikan penentuan kebijakan dari hasil pengukuran IHK dan perhitungan tingkat inflasi. Tiga kelompok penilaian tersebut adalah (Bank Indonesia; Dewi, Adikara and Adinugroho, 2018):

1. Inflasi Inti

Bagian dari rantai inflasi yang terus-menerus dan dipengaruhi oleh elemen ekonomi fundamental seperti interaksi penawaran dan permintaan dari eksternal, Contohnya seperti Nilai tukar rupiah ke dolar dan harga komoditas internasional

2. Inflasi Komponen bekejolak (*volatile food inflation*)

Guncangan yang terjadi pada kelompok bahan pangan. Salah satu pemicu inflasi ini biasanya karena faktor yang mempengaruhi produksi,

distribusi dan harga makanan terkena dampak perubahan musiman atau faktor eksternal. Contohnya seperti gangguan alam dikarenakan cuaca ekstrim yang mengakibatkan banjir, perubahan harga komoditas bahan baku minyak yang naik tajam, dan permintaan meningkat secara signifikan dikarenakan perubahan pola konsumsi.

3. Inflasi komponen harga yang diatur pemerintah (*Administered inflation*)

Kebijakan harga yang ditentukan oleh pemerintah yang mempengaruhi inflasi. Contohnya seperti kenaikan harga bahan bakar bersubsidi, tarif listrik dan tarif BPJS Kesehatan.

Kestabilan pertumbuhan ekonomi secara berkelanjutan ditunjukkan oleh laju inflasi yang terpantau dan rendah karena kestabilan inflasi ini sangat mempengaruhi kesejahteraan Masyarakat. Oleh karena itu perlu adanya tim pengendali inflasi. Pembentukan tim pengendali inflasi sudah di bentuk pada tingkat pemerintah daerah dan pemerintah pusat (Estiko and Wahyuddin, 2019). Disamping bertanggung jawab dalam merancang dan melaksanakan kebijakan dalam pengendalian tingkat inflasi di dalam suatu wilayah, tim ini memantau ketersediaan barang dan jasa dan juga memantau penimbunan bahan pokok yang dilakukan oleh beberapa oknum yang memanfaatkan beberapa moment hari kebesaran. Tim pengendali inflasi pemerintah daerah dan pusat membutuhkan koordinasi yang baik dengan pendekatan yang holistic dan berkelanjutan.

2.1.2 Variabel Yang Mempengaruhi Inflasi

Inflasi merupakan pertanda meningkatnya komoditi yang dipengaruhi beberapa faktor yang dapat menyebabkan naiknya harga barang lain (Salim, Fadilla and Purnamasari, 2021). Model ekonomi dapat membantu para ekonom untuk menganalisis dan memahami cara berbagai faktor ekonomi saling berhubungan dalam suatu sistem. Hal ini membantu mereka dalam meramalkan hasil dan dampak dari kebijakan tertentu yang diterapkan dalam

lingkungan ekonomi. Model Ekonomi merujuk pada dua faktor atau variabel (Lleras, 2005), yaitu:

1. Variabel Endogen

Variabel yang dipengaruhi oleh satu atau lebih variabel lain dalam model analisis. Dalam konteks model, variabel endogen dianggap sebagai hasil atau dampak dari variabel lain di dalam sistem yang sedang dianalisis.

Contohnya: tingkat inflasi dan tingkat konsumsi masyarakat.

2. Variabel Eksogen

faktor dari luar model yang mempengaruhi atau menjelaskan variabel lain dalam model tersebut. Variabel ini dianggap sebagai penyebab dari luar yang tidak dipengaruhi oleh variabel lain dalam analisis.

Contohnya: harga minyak dunia atau suku bunga global

Dengan pemahaman ini, kita bisa menggambarkan bagaimana perubahan dalam variabel eksogen seperti harga minyak dunia dapat memengaruhi tingkat inflasi (variabel endogen) dalam suatu model ekonomi. Selain harga minyak dunia dan suku bunga ada beberapa yang termasuk dalam predictor penting inflasi antara lain: kelambatan pertama inflasi, produksi industri, harga impor dan ekspor, harga pangan global, harga bahan baku pertanian global, jumlah uang beredar, nilai tukar antara rupiah Indonesia (IDR) dan dolar AS (USD), pengeluaran konsumsi, dan tingkat pengangguran (Juhro and Njindan Iyke, 2019).

2.2 Peramalan

Peramalan merupakan proses memperkirakan permintaan di masa mendatang, hal ini termasuk kualitas, kuantitas, waktu dan kebutuhan lokasi yang dibutuhkan untuk memenuhi permintaan terhadap barang dan jasa. Dalam menentukan perkiraan yang akan datang tentunya didukung dengan penyusunan rencana terlebih dahulu, Dimana rencana tersebut dibuat berdasarkan kapasitas dan permintaan/kapasitas produksi yang telah dicapai

Perusahaan (Lusiana and Yuliarty, 2020). Metode peramalan *time series* merupakan teknik yang paling sering digunakan untuk memprediksi data (Pongdatu and Putra, 2018).

Namun ada beberapa pengertian peramalan menurut para ahli. Menurut Makridakis, dkk (1988) Peramalan atau *forecasting* adalah prediksi nilai-nilai suatu variabel berdasarkan nilai yang sudah diketahui dari variabel tersebut atau variabel terkait. Meramal juga dapat didasarkan pada keahlian *judgment*, yang pada gilirannya didasarkan pada data kejadian sebelumnya dan pengalaman. Sedangkan menurut Elwood (1996) Peramalan atau *forecasting* merupakan teknik statistik yang digunakan dalam bentuk gambaran masa akan datang berdasarkan pengolahan angka-angka historis atau kejadian sebelumnya. x (Syakura, Hendaryani and Ramadhan, 2016).

Peramalan atau *forecasting* mempunyai peran penting dalam proses pengambilan Keputusan dan berpengaruh terhadap keefektifitasannya (Vercellis, 2009).

2.2.1 Jenis- Jenis Metode Peramalan

Secara umum terdapat 2 macam kategori utama metode peramalan, antara lain metode kuantitatif dan metode kualitatif. Yang termasuk dalam metode kuantitatif adalah deret berkala atau runtut waktu (*timeseries*) dan metode kasual, sedangkan yang termasuk dalam metode kualitatif adalah metode eksploratoris dan pendekatan normatif.

Berikut penjelasan lebih rinci terkait metode peramalan:

1. Metode kuantitatif: Metode dengan pertimbangan, artinya belum tersedianya mata di masa lampau atau sulit didapatkan. *Trend* data masa lalu dibuatkan perkiraan. Metode ini menggunakan pendekatan eksploratoris dan pendekatan normatif.
2. Metode kualitatif: Metode dengan melakukan beberapa persyaratan, artinya data masa lalu tersedia dan dapat dikuantifikasikan. Data masa lalu diperkirakan memiliki *trend* yang sama dengan data masa

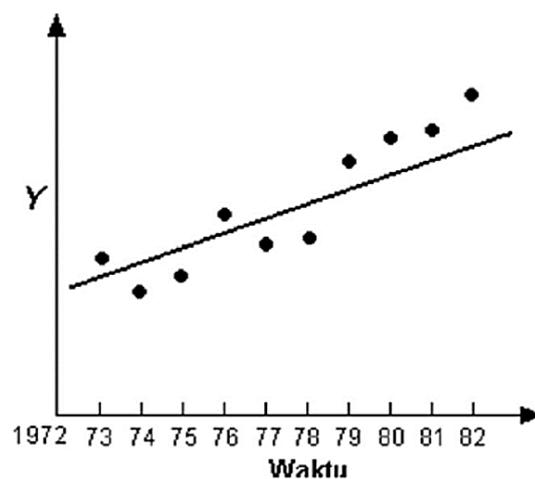
mendatang. Metode ini menggunakan metode *constan*, *linear trend*, *exponential*, *movingaverage* dan *esponentialssmoothing*.

2.2.2 Jenis Pola Data Peramalan

Pemahaman mendalam tentang data dan konteksnya sangat penting untuk mencermati semua faktor ketika akan menerapkan peramalan yang sesuai karena berpengaruh dalam membantu penentuan pola dan menghasilkan perkiraan yang akurat. Pola data peramalan ditentukan oleh berbagai faktor dan kondisi yang bervariasi tergantung dengan jenis data, konteks, dan metode peramalan yang akan digunakan. Pola Data Peramalan mempunyai 4 pola (Lusiana and Yuliarty, 2020), antara lain:

1. Pola *Trend* (T)

Pola ini terjadi apabila ada kenaikan atau penurunan dari data secara gradual dari laju datanya dalam kurun waktu panjang. contohnya data penjualan Perusahaan, GNP dan berbagai ukuran ekonomi dan bisnis lainnya. Pola *Trend* ini dapat dilihat pada gambar 2.1 dibawah ini

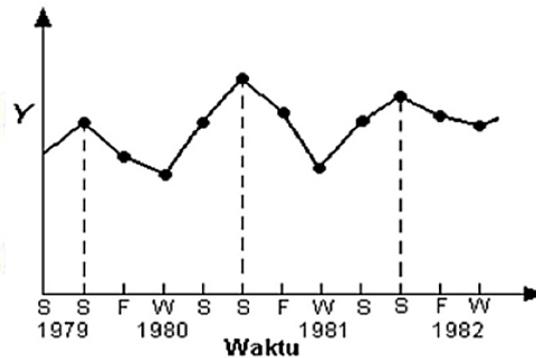


Gambar 2. 1 Contoh Pola Data Trend (Raharja, Angraeni and Vinarti, 2010)

2. Pola *Seasonality* / musiman (S)

Pola ini terjadi apabila datanya secara berulang sesudah suatu periode tertentu dalam kurun waktu, hari, mingguan, bulanan, triwulan bahkan tahunan. Jenis pola ini terlihat dalam penjualan barang seperti minuman ringan, es krim, dan bahan bakar pemanas

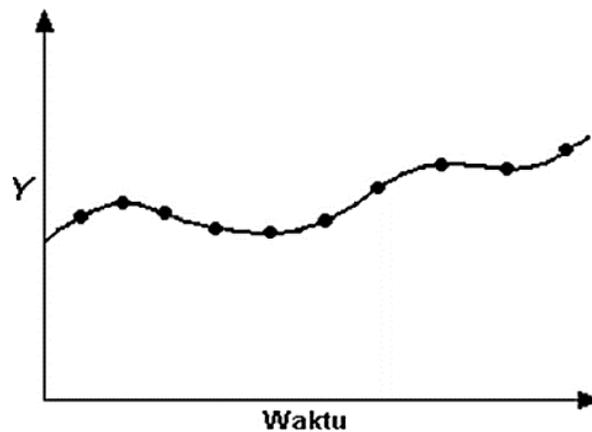
ruang. Pola *Seasonality* ini dapat dilihat pada gambar 2.3 dibawah ini



Gambar 2. 2 Contoh Pola Seasonality (Raharja, Angraeni and Vinarti, 2010)

3. Pola Cycles / Siklis (C)

Pola ini terjadi apabila setiap beberapa tahun, hal ini biasanya dipengaruhi oleh fluktuasi ekonomi jangka panjang yang berhubungan dengan siklus bisnis. Contoh: Penjualan barang-barang seperti mobil, baja, dan peralatan penting lainnya. Pola *Cycles* ini dapat dilihat pada gambar 2.3 dibawah ini:

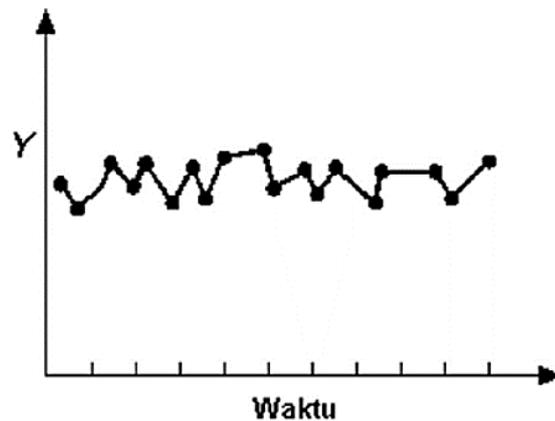


Gambar 2. 3 Contoh Pola Cycles (Raharja, Angraeni and Vinarti, 2010)

4. Pola Horizontal (H)

Pola ini disebut juga stasioner yang akan terjadi apabila nilai data berfluktuasi di sekitar nilai rata-rata yang tetap, stabil atau disebut

juga stasioner terhadap nilai rata-ratanya. Pola *Horizontal* ini dapat dilihat pada gambar 2.4 dibawah ini:



Gambar 2. 4 Contoh Pola Horizontal (Raharja, Angraeni and Vinarti, 2010)

2.2.3 Jangka Waktu Peramalan

Menurut (Herjanto, 2008:78) jangka waktu peramalan berdasarkan horizon waktu, peramalan atau *forecasting* dibagi menjadi tiga macam (Faqih, Nurlenawati and Triadinda, 2022), antara lain:

1. Peramalan jangka panjang
mencakup periode yang lebih lama dari 18 bulan, misalnya, proyeksi yang dibutuhkan dalam hal penanaman modal, perencanaan fasilitas, dan perencanaan kegiatan penelitian dan pengembangan.
2. Peramalan jangka menengah
Peramalan untuk perencanaan penjualan, produksi, dan tenaga kerja tidak tetap, yang berlangsung antara 3 dan 18 bulan.
3. Peramalan jangka pendek
Mencakup waktu kurang dari 3 bulan, misalnya, perencanaan pembelian material, penjadwalan kerja, dan penugasan karyawan.

2.3 Deret Waktu (*Time series*)

Deret waktu, juga disebut sebagai *time series*, adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan kejadiannya dengan interval waktu yang tetap (Putri, Hendayanti and Nurhidayati, 2017).

Deret waktu adalah rangkaian kejadian atau peristiwa yang dicatat secara berurutan dari waktu ke waktu dan kemudian disusun sebagai data; waktu yang digunakan biasanya adalah minggu, bulan, tahun, atau lainnya. Analisis rangkaian waktu digunakan untuk meramalkan peristiwa yang akan datang (Ulfa, Dewi and Darmawan, 2023).

Data deret waktu dapat memiliki banyak pola dan menggambarkan berbagai proses yang ditentukan secara acak dalam model dasar (Supatmi, Huo and Sumitra, 2019). Analisis deret waktu dapat digunakan di banyak bidang, seperti dalam ekonomi untuk memprediksi inflasi atau harga saham, dalam ilmu pengetahuan untuk memantau cuaca dan lingkungan, dan dalam industri untuk meramalkan penjualan dan pengelolaan. Analisis deret waktu juga melibatkan teknik matematika dan statistik untuk menemukan pola-pola ini dan memahami dinamika atau perilaku dari fenomena yang diamati.

2.4 *Univariat Time Series*

Analisis *univariat* digunakan untuk melihat bagaimana setiap atribut bertindak, yang dianggap sebagai entitas independen dari variabel lain dalam dataset. Analisis ini memiliki tujuan, yaitu mengevaluasi kecenderungan nilai atribut untuk berkumpul di sekitar nilai pusat tertentu (lokasi), mengevaluasi kecenderungan variabel untuk mengambil rentang nilai yang lebih atau kurang luas (dispersi), dan mengumpulkan data tentang distribusi probabilitas dasar (Vercellis, 2009).

Analisis univariat sering digunakan untuk memahami distribusi atau karakteristik dasar dari satu variabel tertentu, Contohnya seperti Data univariat adalah pengukuran tunggal, seperti tinggi seseorang, nilai ujian

matematika sekelompok siswa, atau suhu harian di satu tempat(William W. S. Wei, 2006).

2.5 *Bivariate Time Series*

Analisis bivariat berkonsentrasi pada bagaimana sepasang atribut numerik dan kategorikal berhubungan satu sama lain untuk memahami pola dan intensitas hubungan. Ketika pasangan atribut dipertimbangkan untuk mengukur intensitas hubungan yang ada di antara mereka, ini disebut analisis bivariat. Ini terutama penting untuk model pembelajaran terbimbing, di mana sangat menarik untuk menganalisis hubungan antara atribut penjelas dan variabel target. Beberapa teknik analisis bivariat, antara lain (Vercellis, 2009):

- a. Analisis korelasi: Untuk mengetahui kekuatan dan arah hubungan linear antara dua atribut numerik, Anda harus menghitung koefisien korelasi linear, juga dikenal sebagai korelasi Pearson.
- b. Scatter plot: Grafik dua dimensi dengan atribut numerik pada sumbu horizontal dan sumbu vertikal. Ini menunjukkan pola hubungan antara dua atribut.
- c. Plot loess adalah evolusi dari plot dispersi yang menambahkan kurva tren untuk menunjukkan hubungan fungsional antara dua atribut numerik.
- d. Tabel kontingensi adalah matriks yang menunjukkan frekuensi munculnya kombinasi nilai-nilai antara dua karakteristik.

2.6 *Multivariate Time Series*

Analisis multivariat bertujuan untuk mengeksplorasi struktur dan hubungan antara lebih dari dua atribut secara bersamaan untuk mendapatkan pemahaman yang lebih komprehensif tentang karakteristik dataset. Analisis rangkaian waktu multivariat memungkinkan analisis pola, tren, dan korelasi antara berbagai variabel yang diukur dalam urutan waktu(Vercellis, 2009).

Multivariate Time Series merupakan metode regresi berganda, analisis faktor, dan analisis kluster digunakan untuk mempelajari data yang kompleks.

Ini memungkinkan penelitian pada lebih dari dua variabel sekaligus, yang memungkinkan untuk menganalisis pengaruh beberapa variabel terhadap variabel lain secara bersamaan. Contohnya seperti pengukuran variabel tertentu, seperti tinggi dan berat badan seseorang, hasil ujian tertentu, atau data terkait penjualan, seperti harga, jumlah produk, dan biaya pemasaran (William W. S. Wei, 2006).

2.7 *Deep Learning*

Deep Learning yaitu sebuah algoritma yang memproses dalam pengolahan data menggunakan sejumlah *hidden layer* dan menggunakan transformasi linier dalam memproses perhitungan nilai *output*. *Deep learning* merupakan bagian dari *machine learning* dan juga berkesinambungan dengan *artificial neural networks*. Dalam hal ini algoritma yang dirancang sedemikian rupa meniru cara belajar dan berfikir manusia (Ningrum *et al.*, 2021).

Neural networks memungkinkan dalam mempelajari sejumlah data besar dan mencoba meniru perilaku otak manusia. Model *deep learning* biasanya diperuntukan dalam mengenali pola yang kompleks seperti dalam mengenali data dalam bentuk gambar, teks, suara dan juga data lainnya untuk menghasilkan informasi dan wawasan untuk prediksi yang akurat. Hal ini dapat memudahkan manusia dalam beberapa tugas manusia dalam mendeskripsikan gambar, mengkonversi data dalam bentuk suara menjadi data bentuk teks tanpa memerlukan campur tangan manusia.

Deep learning merupakan metode dalam kecerdasan buatan (AI) yang melatih komputer dalam berfikir dan mempelajari hal seperti yang dilakukan manusia yang dapat membantu segalanya menjadi lebih praktis dan efisien. Beberapa manfaat teknologi *deep learning* yang memberikan manfaat dalam kehidupan sehari-hari, seperti (Primakara University, 2024):

- a. Menghasilkan Fitur Otomatis tanpa campur tangan manusia dalam melakukan tugas-tugas yang kompleks dan rumit.

- b. Dalam sektor manufaktur dan ritel dalam pemanfaatan teknik *deep learning* ini dapat mengurangi resiko dengan mendeteksi sejak dini cacat produk dan memprediksi biaya dengan lebih akurat.
- c. Dapat mengelola dengan baik data yang tidak terstruktur seperti mengolah data gambar, suara dan teks.
- d. Dalam ilmu data penerapan *deep learning* memungkinkan dalam memproses data menjadi lebih efektif dan mampu meningkatkan hasil yang akurat secara terus menerus tanpa memerlukan pengawasan.
- e. Algoritma paralel dan terdistribusi dengan skala yang relative besar dengan model *deep learning* dapat meringankan pekerjaan yang biasanya dikerjakan dalam waktu sehari-hari.

Dalam menentukan algoritma yang cocok sesuai dengan kebutuhan, perlu mengetahui jenis-jenis deep learning, sebagai berikut:

- a. *Self-Organizing Maps* (SOM)
Algoritma *Self Organizing Maps* (SOM) ini digunakan model dalam mengidentifikasi data *visualitation* secara mandiri dengan memecahkan masalah yang sulit di pecahkan oleh manusia dan pemahaman informasi berdimensi.
- b. *Convolutional Neural Network* (CNN)
Jenis deep learning CNN biasanya digunakan dalam mendeteksi objek atau memproses gambar. Penerapan CNN ini berkembang lebih canggih dengan memproses citra satelit, mendeteksi anomaly, prediksi deret waktu dan citra medis. Keunggulan CNN yaitu dalam memindai bagian terkecil pada gambar sebagai node.
- c. *Recurrent Neural Network* (RNN)
Algoritma RNN ini digunakan untuk memproses data berurutan dan bersambung, hal ini karena dilatar belakanginya oleh koneksi yang terdapat pada RNN mempunyai bentuk yang searah.

d. LSTM (*Long Short-Term Memory*)

Algoritma LSTM ini mempelajari dan menghafal ketergantungan pada pola dengan jangka panjang hal ini dikarenakan Informasi LSTM dapat mempelajari kembali ke masa lalu dengan sangat baik dari history data sebelumnya.

Beberapa Perusahaan besar sudah menerapkan *deep learning* dalam kehidupan sehari-hari, antara lain:

a. Mobil tanpa kemudi

Dalam hal ini model ini mempelajari objek dalam gambar seperti kendaraan yang melintas dijalanan, situasi lalu lintas, objek pejalan kaki dan peta jalan ini dapat mendukung diterapkannya mobil tanpa kemudi dengan mengandalkan sensor yang memungkinkan mobil untuk bergerak berdasarkan pembelajaran dari objek sekitar dan membuat keputusan pergerakan yang tepat. Perusahaan yang sudah mengembangkan mobil tanpa kemudi yaitu Uber, Waymo dan Tesla.

b. *E-commerce* dan Marketplace

Beberapa *E-commerce* dan Marketplace yang sudah menerapkan *deep learning* dalam meningkatkan omset penjualan dengan menggunakan algoritma yang dapat merekomendasikan beberapa produk sejenis yang relevan sesuai dengan data pencarian konsumen. Tokopedia, Shopee, amazon dan Lazada merupakan beberapa *E-commerce* dan Marketplace yang menerapkan teknologi ini.

c. Layanan Pelanggan Otomatis dan Chatbots

Dalam melayani konsumen pelanggan agar lebih mudah dalam berkomunikasi beberapa sektor industri sudah menggunakan layanan ini. Salah satunya dengan menggunakan chatbots dan layanan pelanggan otomatis. Teknologi ini mempelajari pola dalam bahasa manusia untuk merespon beberapa pertanyaan dari pelanggan secara informatif dan natural. Beberapa penerapan *chatbots* pada *Google assistant*, *Fandango Chat* dan *Qwords Chat*.

2.8 Jaringan Saraf Tiruan (*Neural Network* atau *NN*)

Jaringan saraf bertujuan untuk mensimulasikan perilaku sistem biologis yang terdiri dari neuron. Sejak tahun 1950-an, ketika model-model sederhana pertama kali diusulkan, jaringan saraf telah digunakan untuk tujuan prediksi, tidak hanya dalam klasifikasi tetapi juga dalam regresi untuk atribut target yang bersifat kontinu (Vercellis, 2009). Dengan kata lain, *Neural Network* adalah konsep umum yang mengacu pada struktur matematis terinspirasi oleh cara kerja otak manusia.

Jaringan Saraf Tiruan (*Neural Network* atau *NN*) adalah model komputasi yang didasarkan pada anatomi dan fitur jaringan saraf biologis manusia. *Neural Network* secara sederhana berusaha meniru cara otak manusia memproses data. Neuron atau node, unit pemrosesan kecil, terdiri dari jaringan ini dan disusun dalam lapisan-lapisan.

Neural Network sebagai sebuah metode analitik dalam data science memiliki kemampuan pada bidang:

1. Klasifikasi (*Classification*)

Dalam hal ini *Neural Networks* mampu mengklasifikasikan data berdasarkan kategori dengan output berupa kategori/kelompok

Contohnya: mengklasifikasikan email yang termasuk spam dan bukan spam

2. Prediksi (*Prediction*)

Dalam hal ini *Neural Networks* mampu memprediksi dalam memperkirakan suatu nilai dengan output sebuah nilai/bilangan prediksi

Contohnya: memprediksi inflasi 3 bulan kedepan

3. Pengelompokan (*clustering*)

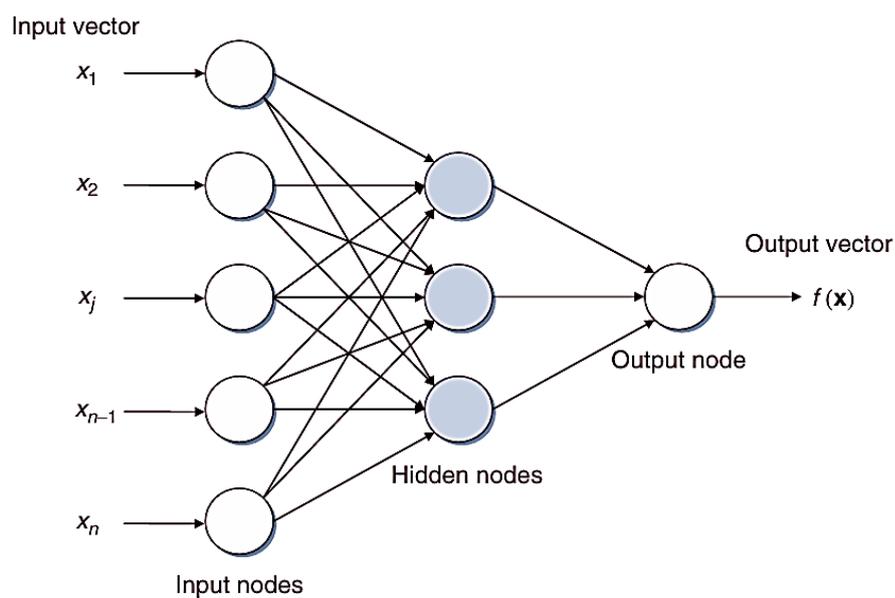
Dalam hal ini *Neural Networks* mampu mengelompokkan data berdasarkan kesamaan fitur atau pola tertentu.

Contohnya mengelompokkan konsumen berdasarkan jumlah pembelian.

Prinsip dasar jaringan saraf tiruan adalah pembentukan koneksi antar neuron dan pembobotan pada setiap koneksi. Dengan menggunakan data

pelatihan untuk menyesuaikan bobot koneksi, jaringan dapat mengenali pola, membuat prediksi, atau mengambil Keputusan. Deep Learning adalah evolusi dari teknik *Neural Network*, yang memiliki kemampuan untuk mempelajari pola data yang lebih kompleks(Savitri *et al.*, 2021).

Struktur *Neural Network* terdiri dari layer input layer, hidden layer dan output layer seperti gambar dibawah ini



Gambar 2. 5 Struktur Neural Network (Vercellis, 2009)

Dimana, input layer ($x_1, x_2, x_3, \dots, x_n$), terdiri dari unit-unit input. Unit-unit input menerima pola inputan data dari luar yang menggambarkan suatu permasalahan. *Hidden Layer* (h_1, h_2, \dots, h_n), terdiri dari unit-unit tersembunyi. Dimana outputnya tidak dapat secara langsung diamati. Sedangkan Output Layer (y_1, \dots, y_n) terdiri dari unit-unit output yang merupakan solusi *Neural Network* terhadap suatu permasalahan(Raharjo, 2013).

Fungsi Aktivasi di *Neural Network* dapat berupa fungsi tangga biner yang mengkonversikan input dari suatu variabel yang bernilai kontinu ke suatu output biner (0 atau 1); atau dapat berupa fungsi linear (identitas) yang memiliki nilai output sama dengan nilai inputnya. Fungsi linear dirumuskan sebagai, $y = x$; atau fungsi sigmoid biner yang mempunyai nilai pada range 0

sampai 1; ataupun fungsi sigmoid bipolar yang mempunyai nilai padarange antara -1 sampai 1 .

2.8.1 Tahapan Pemosresan Informasi *Neural Network*

Neural network terdapat dua tahapan dalam memproses informasi, sebagai berikut (Warsito, 2009):

1. Tahap pelatihan

Tahap ini pelatihan, pola-pola latihan (data pelatihan) dimasukkan ke dalam jaringan saraf. Jaringan menggunakan pola-pola ini untuk memodifikasi bobot yang menghubungkan antar node atau neuron. Setiap iterasi, yang dikenal sebagai epoch dalam *Neural Network* (NN), melibatkan evaluasi bobot yang sesuai, di mana nilai error atau jumlah iterasi yang telah mencapai batas yang ditetapkan sebelumnya dievaluasi. Proses ini berulang hingga kriteria penghentian pelatihan terpenuhi.

Pelatihan dikategorikan menjadi 2 macam, yaitu:

a) Pelatihan Terawasi (*Supervised training*)

Proses pelatihan pada jaringan saraf bertujuan untuk mengenali pola dalam data latih dan memetakan input ke output yang diinginkan. Metode pelatihan ini berfokus pada penyesuaian bobot dan nilai output agar sesuai dengan target yang diinginkan. Proses ini melibatkan perbandingan antara output yang dihasilkan dengan target, diikuti oleh pengembalian error ke dalam jaringan untuk penyesuaian bobot. Iterasi terus berlanjut hingga jaringan mampu menghasilkan output yang mendekati target dengan sedikit error. Proses ini dapat diterapkan pada berbagai tugas seperti regresi, klasifikasi, dan model-model statistika.

b) Pelatihan Tak Terawasi (*Unsupervised Training*)

Pelatihan tak terawasi digunakan dalam masalah-masalah di mana pola tidak diketahui sebelumnya. Metode ini melibatkan penyesuaian bobot berdasarkan output yang dihasilkan, tanpa

memerlukan vektor target. Jaringan mengelompokkan unit-unit dengan ciri-ciri serupa tanpa perbandingan langsung dengan target sebelumnya. Input dikelompokkan, dan karakteristik kelompok ditentukan, memungkinkan jaringan menempatkan input baru ke dalam kelompok yang sesuai. Bobot koneksi antar neuron disesuaikan sehingga pola input serupa ditempatkan dalam kelompok yang sama. Hasilnya, jaringan menghasilkan representasi kelompok untuk setiap pola input, dengan salah satu aplikasinya pada analisis cluster dalam statistika.

2. Tahap Pengujian

Tahap pengujian dilibatkan dalam evaluasi kinerja jaringan pada pola masukan yang tidak pernah ditemui sebelumnya, yaitu data uji. Bobot-bobot yang diperoleh dari tahap pelatihan digunakan untuk mengolah data uji ini. Harapannya, bobot yang telah dihasilkan dengan minimnya *error* pada tahap pelatihan akan memberikan hasil yang minim error pula pada tahap pengujian. Proses ini bertujuan untuk mengukur sejauh mana jaringan dapat menggeneralisasi dan memberikan prediksi yang akurat untuk data yang belum pernah dilihat sebelumnya.

Dalam pemodelan Neural Network, keberhasilan jaringan dipengaruhi oleh beberapa faktor, antara lain:

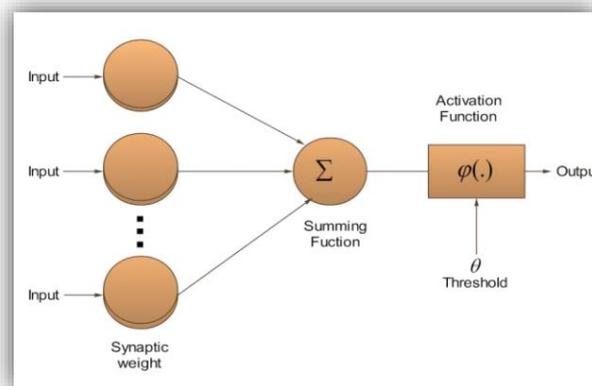
- a) **Arsitektur Jaringan:** Struktur dan jumlah neuron dalam setiap lapisan memainkan peran penting dalam kemampuan jaringan untuk memodelkan data.
- b) **Fungsi Aktivasi:** Pemilihan fungsi aktivasi pada lapisan tersembunyi dan keluaran memengaruhi cara jaringan belajar dan menghasilkan output.
- c) **Metode Pembelajaran:** Metode seperti Stochastic Gradient Descent (SGD) memengaruhi kecepatan dan ketepatan pembelajaran jaringan.

- d) Input Jaringan: Kualitas dan representasi input juga berdampak pada performa jaringan.

2.8.2 *Artificial Neural Network (ANN)*

Perkembangan terakhir bahwa peramalan menggunakan *Artificial Neural Network (ANN)* ini merupakan salah satu model yang banyak digunakan dalam prediksi ekonomi, keuangan, bisnis dan industri. ANN dapat mengenali input yang berbeda dari histori sebelumnya dan dapat tetap terlaksana apabila ada beberapa neuron tidak efektif bekerja maksimal. Jika ada neuron satu yang rusak dapat diganti dengan neuron lain yang akan dilatih untuk membackup neuron yang rusak sebelumnya (Raharjo, 2013). Model ANN terdiri dari

1. Fungsi penjumlahan (*summing function*)
2. Fungsi aktivitas (*Activation function*)
3. Keluaran (*Output*)



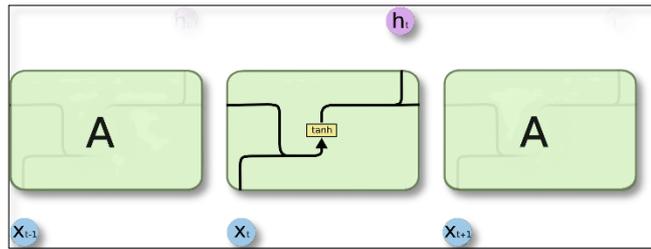
Gambar 2. 6 Model Neuron (Raharjo, 2013)

Dari gambar model neuron diatas, Cara kerja Neural Network (ANN) mirip dengan pemrosesan informasi dalam otak manusia. Informasi masuk ke neuron dengan bobot tertentu, dan diolah dengan menjumlahkan bobot input. Hasilnya dibandingkan dengan ambang tertentu menggunakan fungsi aktivasi pada setiap neuron. Jika nilai melewati ambang, neuron diaktifkan; jika tidak, tetap tidak aktif. Neuron yang aktif mengirimkan outputnya melalui bobot-

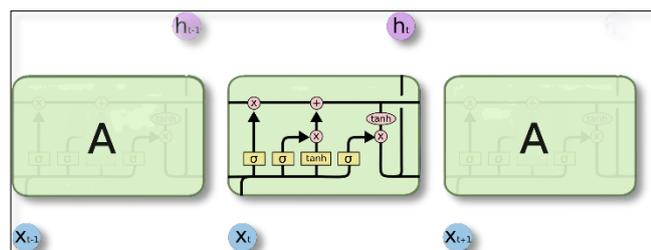
bobot output ke neuron terhubung, memungkinkan aliran informasi melalui lapisan jaringan saraf. Ini menciptakan model matematis yang dapat mempelajari dan membuat prediksi dari data. Model Artificial Neural Network (ANN) memiliki beberapa kelebihan dibandingkan dengan metode lain. Misalnya, ANN dapat menghasilkan hasil yang dapat mengenali pola dengan baik dan mudah diubah menjadi berbagai variasi yang sesuai dengan masalah atau parameter saat ini (Jayadianti *et al.*, 2020).

2.9 LSTM (*Long Short-Term Memory*)

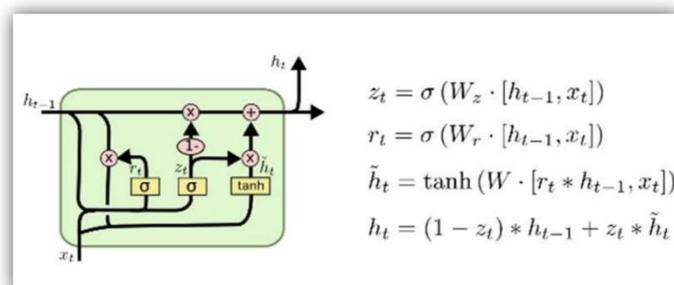
LSTM (*Long Short-Term Memory*) merupakan kelompok jaringan saraf rekuren (RNN). Jaringan saraf rekuren adalah jenis arsitektur yang dirancang untuk mengelola dan memproses data berurutan, di mana informasi dari langkah-langkah sebelumnya dapat dijadikan referensi dalam langkah-langkah berikutnya. Prinsip-prinsipnya diperkenalkan oleh Hochreiter & Schmidhuber pada tahun 1997 dan terus ditingkatkan serta menjadi populer melalui penelitian dan pengembangan lebih lanjut yang dilakukan oleh berbagai peneliti (colah's blog, 2015). LSTM yang menggunakan sel memori untuk menyimpan data rutin. Sel LSTM memiliki jaringan blok memori yang mampu mengelola data dengan ketergantungan yang lama karena terdiri dari kombinasi beberapa gerbang yang lebih kompleks. LSTM meledakkan gradien melalui tiga gerbang untuk memecahkan masalah hilangnya gradien. Jumlah keadaan sel yang harus disimpan diatur oleh gerbang-gerbang berikut: gerbang lupa, gerbang masukan, dan gerbang keluar. Yang terakhir mengatur jumlah informasi yang harus dihapus. Sel berikutnya harus menerima keadaan sel (Savitri *et al.*, 2021). LSTM tidak hanya dapat menggabungkan data terbaru dengan data lama, tetapi juga efisien dalam mencatat data yang panjang. Berikut Gambar Arsitektur Jaringan RNN, Arsitektur Jaringan LSTM dan Arsitektur Jaringan GRU.



Gambar 2. 7 Arsitektur Jaringan RNN (colah's blog, 2015)



Gambar 2. 8 Arsitektur Jaringan LSTM (colah's blog, 2015)

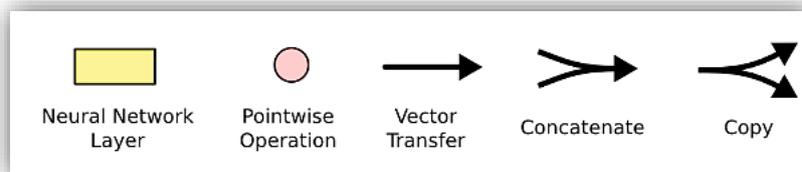


Gambar 2. 9 Arsitektur Jaringan GRU (Savitri et al., 2021)

Dari ketiga gambar diatas menjelaskan bahwa menunjukkan perbedaan antara RNN, GRU, dan LSTM. Arsitek jaringan GRU dan LSTM adalah pengembangan RNN, dan mereka memiliki beberapa perbedaan yang dapat dianggap sebagai kelebihan atau kelemahan masing-masing model. Sementara GRU hanya menggunakan dua gerbang, gerbang reset dan gerbang pembaruan, LSTM memecahkan masalah RNN dengan tiga gerbang, gerbang lupa, gerbang masukan, dan gerbang keluaran. Gerbang reset menghubungkan fungsi aktivasi sebelumnya dan kandidat berikutnya untuk menghapus data lama, dan gerbang pembaruan menentukan seberapa sering fungsi kandidat aktivasi digunakan untuk memperbarui status sel. GRU

menggunakan parameter pelatihan yang lebih sedikit daripada LSTM, yang berarti proses pelatihan menggunakan lebih sedikit memori daripada LSTM, sehingga prosesnya lebih cepat dibandingkan LSTM. Meskipun prosesnya lebih sederhana, LSTM masih dapat mengungguli GRU dengan menghasilkan model yang lebih akurat ketika menggunakan periode data yang lebih panjang.

LSTM memiliki struktur seperti rantai yang umumnya terdapat dalam Jaringan Saraf Rekuren (RNN), namun, modul berulangnya memiliki perbedaan signifikan. Sebagai alternatif dari satu lapisan jaringan saraf, LSTM terdiri dari empat lapisan yang berinteraksi secara sangat khusus (colah's blog, 2015). Pada gambar 2.6 di atas, setiap garis mengangkut vektor dari keluaran satu simpul ke masukan simpul lainnya. Lingkaran merah muda merepresentasikan operasi titik seperti penambahan vektor, sementara kotak kuning adalah lapisan jaringan saraf yang dapat dipelajari. Garis yang digabungkan menunjukkan proses penggabungan, sementara garis yang bercabang menunjukkan salinan konten yang dikirim ke lokasi berbeda.



Gambar 2. 10 Simbol Notasi Neural Network (colah's blog, 2015)

Gambar diatas menunjukkan operasi dasar pada *Neural Network* dengan penjelasan sebagai berikut:

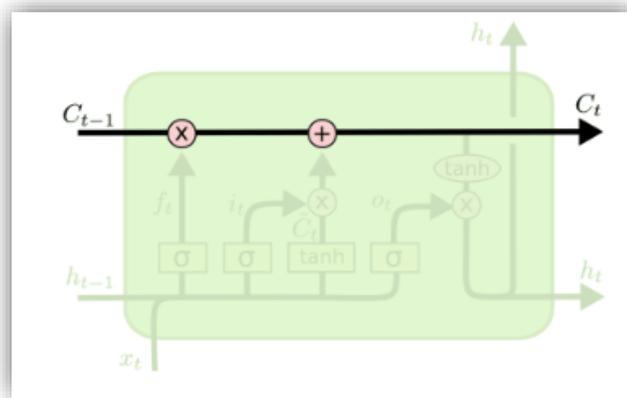
1. **Neural Network Layer (Lapisan Jaringan Saraf):** Bagian arsitektur jaringan saraf yang terdiri dari sekumpulan neuron yang berhubungan, misalnya, lapisan input, lapisan tersembunyi, dan lapisan output.

2. Pointwise Operation (Operasi Titik): Operasi yang dilakukan pada setiap elemen atau titik suatu vektor atau matriks secara independen, seperti penambahan atau fungsi aktivasi.
3. Vector Transfer (Transfer Vektor): Pengiriman vektor dari satu simpul (neuron) ke simpul lain dalam jaringan.
4. Concatenate (Konkatenasi): Operasi penggabungan dua atau lebih vektor atau matriks, umumnya digunakan untuk menggabungkan output dari lapisan-lapisan berbeda.
5. Copy (Salin): Operasi penggandaan data atau informasi, memungkinkan informasi disalin dan dikirim ke lokasi lain dalam jaringan

LSTM (*Long Short-Term Memory*) adalah jenis Jaringan Saraf Tiruan yang dirancang untuk menangani masalah kehilangan informasi pada data *time series*. Proses aliran informasi dalam LSTM dimulai dengan memasukkan data ke dalam hamparan input, diikuti oleh gerbang lupa yang menentukan informasi mana yang akan dihapus. Gerbang input menentukan informasi yang akan ditambahkan ke dalam sel memori, yang kemudian diperbarui. Gerbang keluaran mengontrol informasi yang dikirim ke lapisan output. Setiap langkah melibatkan operasi matematika dan fungsi aktivasi yang digunakan untuk mengontrol aliran dan pemrosesan informasi. Proses ini diulang dalam setiap langkah waktu, memungkinkan LSTM untuk memahami dan memproses informasi temporal dengan kemampuan mempertahankan konteks jangka panjang. LSTM adalah bagian dari metode RNN. Beberapa kelebihan metode LSTM dibandingkan dengan RNN adalah mereka dapat mengingat data yang bersifat rangkaian waktu atau data dengan ketergantungan jangka panjang. Selain itu, LSTM dapat menyimpan informasi terdahulu menggunakan sel yang terdapat pada LSTM (Lattifia, Buana and Rusjayanthi, 2022).

2.9.1 Ide Inti Dibalik LSTM

Kunci dari LSTM adalah keberadaan status sel, yang dapat diibaratkan sebagai garis horizontal yang melintasi bagian atas diagram. Keadaan sel ini mirip dengan sebuah ban berjalan yang bergerak secara vertikal melalui seluruh rantai, dengan hanya beberapa interaksi linier kecil. Analogi ini menggambarkan kemudahan bagi informasi untuk mengalir melalui status sel tanpa banyak perubahan.



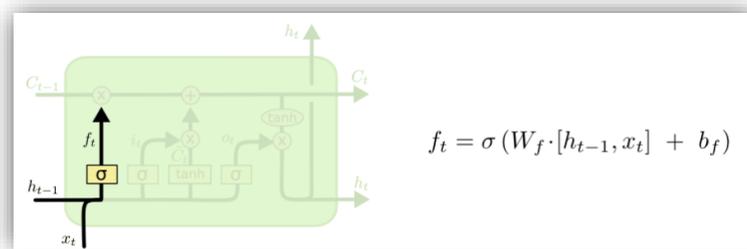
Gambar 2. 11 Diagram Status Sel (colah's blog, 2015)

LSTM memang memiliki kemampuan untuk menghapus atau menambahkan informasi ke dalam status sel, yang diatur dengan hati-hati oleh struktur yang disebut gerbang. Gerbang ini berfungsi sebagai cara opsional untuk memungkinkan informasi masuk. Gerbang tersebut terdiri dari lapisan jaringan saraf sigmoid dan operasi perkalian titik.

Lapisan sigmoid menghasilkan nilai antara nol dan satu, menentukan sejauh mana setiap komponen harus diizinkan untuk melewati. Nilai nol menunjukkan "tidak ada yang diizinkan melewati", sementara nilai satu menunjukkan "izinkan semuanya melewati". Dalam LSTM, terdapat tiga gerbang ini untuk menjaga dan mengatur status sel dengan cermat.

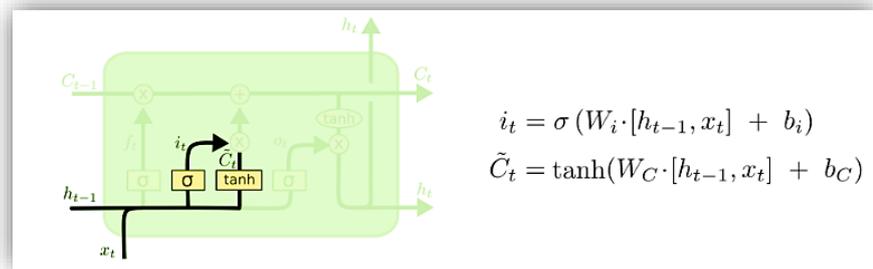
2.9.2 Langkah-Langkah LSTM (*Long Short-Term Memory*)

1. LSTM membuat keputusan dalam menentukan informasi yang akan di buang dari status sel. Keputusan ini diambil oleh lapisan sigmoid yang disebut "lapisan gerbang lupa," yang mempertimbangkan informasi dari $H_t - 1$ dan X_t untuk menentukan sejauh mana setiap elemen dalam status sel $C_t - 1$ harus diingat atau diabaikan. Nilai 1 menunjukkan "simpan sepenuhnya," sedangkan nilai 0 menunjukkan "lupakan sepenuhnya." Dalam konteks model bahasa, ini bisa diartikan sebagai kemampuan model untuk memilih mengingat atau melupakan informasi berdasarkan konteks yang sedang dihadapi.



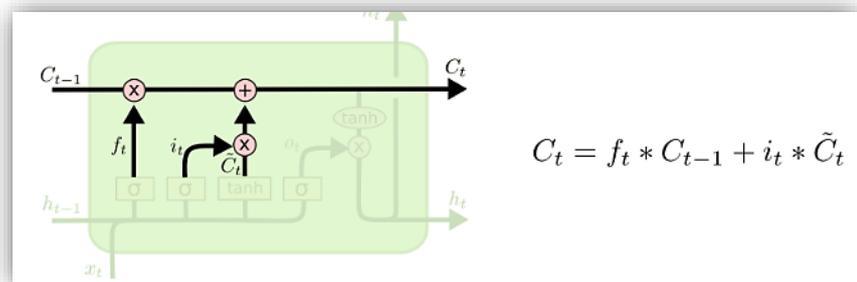
Gambar 2. 12 Proses Penentuan Informasi pada sel (colah's blog, 2015)

2. Langkah berikutnya adalah memutuskan informasi baru yang akan disimpan dalam status sel. Ini melibatkan dua langkah. Pertama, lapisan sigmoid "gerbang masukan" memutuskan nilai mana yang akan diperbarui. Selanjutnya, vektor nilai kandidat baru, \hat{C}_t , dibuat oleh lapisan tanh untuk ditambahkan ke status sel. Pada langkah selanjutnya, keduanya digabungkan untuk menghasilkan pembaruan pada status. Dalam konteks model bahasa, langkah ini menunjukkan penambahan informasi baru untuk menggantikan informasi lama yang telah dilupakan.



Gambar 2. 13 Pemilihan Informasi Baru yang akan disimpan (colah's blog, 2015)

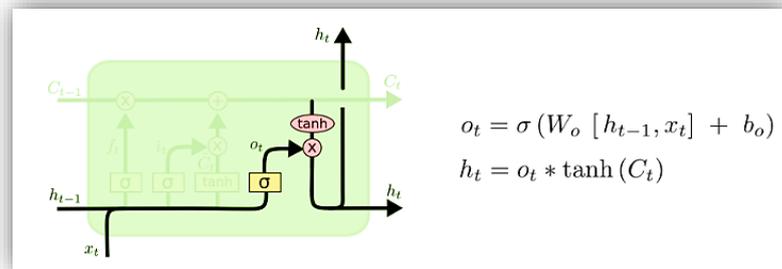
- Langkah selanjutnya adalah memperbarui status sel lama, C_{t-1} , ke dalam keadaan sel baru, C_t . Proses ini melibatkan perkalian negara bagian lama dengan f_t , untuk melupakan informasi yang telah kita pilih untuk dilupakan sebelumnya. Selanjutnya, kita menambahkan $i_t * \hat{C}_t$, di mana \hat{C}_t adalah nilai kandidat baru yang telah dinormalkan berdasarkan keputusan sebelumnya. Dalam konteks model bahasa, tahap ini menghapus informasi tentang jenis kelamin subjek lama dan menambahkan informasi baru yang telah kita tentukan sebelumnya.



Gambar 2. 14 Proses Memperbaharui Status Sel Lama ke Status Sel Baru (colah's blog, 2015)

- Terakhir, kita perlu menghasilkan output berdasarkan status sel, disaring oleh lapisan sigmoid. Status sel diproses oleh fungsi tanh dan dikombinasikan dengan keluaran gerbang sigmoid untuk menampilkan

informasi yang kita pilih. Dalam model bahasa, output dapat menyoroti detail relevan untuk kata kerja berdasarkan subjek yang diamati, seperti apakah subjeknya tunggal atau jamak, memberikan petunjuk untuk konjugasi kata kerja selanjutnya.



Gambar 2. 15 Proses Hasil Output (colah's blog, 2015)

2.9.3 Konsep Dasar LSTM (*Long Short-Term Memory*)

Sesuai dengan konsepnya, LSTM memiliki kemampuan untuk memproses, memprediksi, dan mengklasifikasikan informasi berdasarkan data deret waktu. Selain itu, LSTM memiliki kemampuan untuk mengingat dan menghapus data lawas yang sudah tidak relevan lagi. LSTM (*Long Short-Term Memory*) adalah arsitektur Jaringan Saraf Tiruan yang dikembangkan untuk mengatasi kendala kehilangan informasi pada data time series. Konsep dasar melibatkan penggunaan sel memori yang dapat menyimpan dan mempertahankan informasi jangka panjang, gerbang lupa untuk mengontrol penghapusan informasi lama, gerbang input untuk menentukan penambahan informasi baru, dan gerbang keluaran untuk mengatur output. Fungsi aktivasi tanh digunakan untuk mengontrol rentang nilai dan pembelajaran melibatkan proses penyesuaian bobot dan parameter selama pelatihan. Kelebihan utama LSTM terletak pada kemampuannya memproses urutan panjang tanpa kehilangan informasi temporal yang penting, menjadikannya pilihan yang efektif untuk tugas-tugas yang melibatkan ketergantungan temporal kompleks seperti peramalan dan pengenalan pola dalam data *time series*.

2.10 Bahasa Pemrograman *Python*

Python, bahasa pemrograman tingkat tinggi yang diciptakan oleh Guido Van Rossum dan dirilis pada tahun 1991, saat ini sedang banyak digunakan dan sangat populer. Selain itu, *Python* adalah bahasa pemrograman yang dapat digunakan untuk berbagai tujuan, seperti pengajaran mesin dan deep learning. Itu dipilih sebagai bahasa penelitian karena sintaksisnya yang mudah digunakan, memiliki library yang lengkap, dan memiliki dukungan komunitas yang kuat. Kita dapat menggunakan IDE online seperti Jupyter notebook dan Google Colab untuk menulis source code *python*, atau IDE seperti vs code, sublime text, dan PyCharm. *Python* digunakan untuk membuat program karena memiliki banyak kelebihan dibandingkan dengan bahasa lain, terutama dalam hal program yang berkaitan dengan mesin belajar. Ini terutama berlaku untuk bahasa program yang berhubungan dengan mesin belajar. Selain itu, bahasa *Python* adalah open source dengan banyak pustaka yang terus bertambah, yang membuatnya lebih mudah untuk membuat algoritma yang sulit seperti Numpy (untuk operasi vektor dan matrik), Scikit-learn (data analisis dan statistik), Pandas Data Frame (pengolahan data seperti layaknya Excell dan SQL), Matplotlib (visualisasi data grafik), dan Keras (API neural network yang bekerja di atas Tensor Flow dan Theano)(Karno, 2020). *Python* banyak digunakan di bidang *machine learning* dan *deep learning*. Berikut beberapa library yang umum dan populer digunakan untuk *machine learning* dan *deep learning*, sebagai berikut (Alfarizi *et al.*, 2023):

1. Numpy

Library ini mengandung fungsi matematika dengan kompleksitas tinggi yang dapat digunakan untuk memproses matriks dan array multidimensi yang besar. NumPy juga sangat berguna untuk menangani bilangan acak, aljabar linier, dan transformasi Fourier.

2. SciPy

Library ini menawarkan modul untuk Aljabar linier, pengoptimalan gambar, interpolasi integrasi, fungsi khusus, transformasi Fast Fourier, pemrosesan sinyal gambar, penyelesaian, dan tugas komputasi lainnya dalam bidang sains dan analitik tersedia di lembaga ini.

3. Scikit Learn

Library ini menyediakan banuak algoritma pembelajaran tanpa pengawasan dan pengawasan, yang dibangun di atas beberapa teknologi yang mungkin sudah Anda kenal, seperti NumPy, panda, dan Matplotlib.

4. TensorFlow

Library yang populer untuk membuat model *machine learning* dalam membangun model pada berbagai tingkat abstraksi, TensorFlow mendukung berbagai toolkit.

5. Keras

Keras merupakan library yang Selain mendukung jaringan saraf konvensional, Keras mendukung jaringan saraf konvolusional dan berulang. Keras juga menggunakan komponen bangunan jaringan saraf seperti lapisan, tujuan, fungsi aktivasi, dan pengoptimal. Selain itu, Keras memiliki banyak fitur yang bermanfaat untuk mengerjakan gambar dan teks saat menulis kode Deep Neural Network.

6. PyTorch

Library Deep Learning ini dirancang untuk bersaing dengan TensorFlow, tetapi lebih mudah digunakan. Ilmuwan, pengembang, dan debugger jaringan saraf dapat secara real-time menjalankan dan menguji komponen kode di library ini.

7. Pandas

library Pandas merupakan library paling populer yang digunakan untuk analisis data, dengan dukungan untuk struktur data yang

cepat, fleksibel, dan ekspresif yang dirancang untuk bekerja pada data "relasional" atau "berlabel". Ini adalah library yang wajib untuk menyelesaikan analisis data dunia nyata yang praktis dengan Python.

8. Matplotlib

Library menggunakan visualisasi data. Visualisasi data sangat penting untuk memahami data secara lebih mendalam sebelum melakukan pengolahan data dan melatihnya dalam program *machine learning*.

2.11 Adaptive Moment Estimation (Adam)

Algoritma Adaptive Moment Estimation (Adam) pertama kali dipublikasikan oleh Kingma dalam ICLR pada tahun 2015 dari paper dengan judul “*Adam: A Method for Stochastic Optimization*”, Adam merupakan sebuah algoritma yang berbasis pada estimasi adaptif momen orde rendah dan digunakan untuk optimasi fungsi objektif stokastik berbasis gradien orde pertama. Metode ini mudah diterapkan, efisien secara komputasi, membutuhkan sedikit penyimpanan, tidak terpengaruh oleh perubahan skala gradien secara diagonal, dan direkomendasikan untuk masalah data dan parameter yang besar. Metode ini juga dapat digunakan untuk masalah non-stasioner dan gradien yang sangat bising dan/atau jarang. Hyperparameter biasanya sedikit disesuaikan dan dapat ditafsirkan dengan mudah. Dibahas beberapa koneksi ke algoritma yang menjadi ide Adam. Selain itu, kami memeriksa karakteristik konvergensi teoritis dari algoritma dan menetapkan batasan penyesalan pada tingkat konvergensi, yang sebanding dengan hasil yang paling terkenal dalam kerangka pengoptimalan cembung online. Hasil empiris menunjukkan bahwa, jika dibandingkan dengan teknik optimasi stokastik lainnya, Adam bekerja dengan baik dalam praktiknya (Kingma and Ba, 2014).

Adam adalah algoritma optimasi yang menggunakan kelebihan dari Adaptive Gradient (AdaGrad) dan Root Mean Square Propagation

(RMSProp) yang bekerja dengan baik secara on-line dan non Pengaturan stasioner. Adam juga menggunakan rata-rata kedua dari gradien, atau varians tidak terpusat, daripada mengubah tingkat pembelajaran parameter berdasarkan rata-rata pertama (mean) seperti dalam RMSProp. Parameter β_1 dan β_2 mengatur tingkat peluruhan rata-rata pergerakan, dan algoritma menghitung pergerakan eksponensial rata-rata dari gradien dan gradien kuadratnya (Aldi, Jondri and Aditsania, 2018). Adam menggunakan gradien kuadrat untuk melakukan skala tingkat pembelajaran seperti RMSprop dan memanfaatkan momentum dari pergerakan gradien rata-rata seperti SGD dengan momentum. Secara struktural, Adam merupakan kombinasi dari kedua SGD dan RMSprop (Arkadia, Hananto and Prasvita, 2022). Adaptive Moment Estimation (Adam) merupakan metode yang digunakan untuk menghitung adaptive learning rate dari setiap parameter. Nilai parameter yang direkomendasikannya yaitu $\beta_1 = 0.9$, $\beta_2 = 0.999$, dan $\epsilon = 10^{-8}$ dengan $\beta_1 = \beta_2 =$ tingkat penurunan eksponensial dan $\epsilon =$ nilai epsilon untuk update parameter.

2.12 Evaluasi

Secara terminologi, beberapa ahli berpendapat tentang definisi evaluasi, seperti yang dinyatakan Edwind dalam Ramayulis: Evaluasi mengandung pengertian suatu langkah atau proses untuk menentukan nilai sesuatu. Menurut M. Chabib Thoha, evaluasi adalah proses yang direncanakan untuk mengetahui keadaan objek dengan menggunakan instrumen dan membandingkan hasilnya dengan tolok ukur untuk mencapai kesimpulan. Evaluasi adalah proses sistematis untuk menentukan nilai sesuatu (ketentuan, kegiatan, keputusan, unjuk-kerja, proses, orang, objek, dll.) berdasarkan kriteria tertentu melalui penilaian.

Penilaian belajar dan pembelajaran adalah proses untuk menentukan nilai belajar dan pembelajaran yang dilaksanakan melalui kegiatan penilaian atau pengukuran belajar dan pembelajaran. Pengertian pengukuran kegiatan pembelajaran adalah proses membandingkan tingkat keberhasilan belajar dan

pembelajaran dengan ukuran keberhasilan belajar dan pembelajaran yang telah ditentukan secara kuantitatif, sementara pengertian penilaian belajar dan pembelajaran adalah proses membandingkan tingkat keberhasilan belajar dan pembelajaran dengan ukuran keberhasilan belajar dan pembelajaran (Idrus, 2019).

Evaluasi pada penelitian ini yaitu dengan mengukur seberapa baik model yang telah dirancang dalam memprediksi data.

2.13 Penelitian terdahulu

Beberapa penelitian terdahulu telah dilakukan dalam penggunaan *deep learning* khususnya LSTM (*Long Short-Term Memory*) dan evaluasi terkait inflasi. Tabel 2.1 memberikan temuan dari penelitian yang telah dilakukan, perbandingan model, dan hasil yang dapat digunakan sebagai dasar dilakukannya penelitian ini.

Tabel 2. 1 Penelitian Terdahulu

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
1.	Rizki E. Wimanda dkk. (Wimanda, Turner and Hall, 2011)	<i>Expectations and the inertia of inflation: The case of Indonesia</i>	faktor-faktor determinan inflasi di Indonesia yang sangat berharga dalam pengambilan kebijakan. Dinamika inflasi di Indonesia diselidiki dengan menggunakan data bulanan dari tahun 1980:1 hingga 2008:12 dengan menggunakan kurva New Keynesian Phillips (NKPC) versi hibrid yang menggabungkan ekspektasi inflasi masa depan dan inflasi masa lalu. Hasil penelitian mereka menunjukkan bahwa inflasi di Indonesia sangat ditentukan oleh inflasi ke belakang, inflasi ke depan, kesenjangan output, nilai tukar uang, dan pertumbuhan uang. Ekspektasi ke belakang	Inflasi dan Faktor Determinan di Indonesia	1. Phillips curve dan faktor-faktor yang memengaruhi inflasi. 2. Dinamika inflasi	1. Menggunakan kurva New Keynesian Phillips (NKPC) versi hibrid yang menggabungkan ekspektasi inflasi 2. Inflasi berpengaruh terhadap kesenjangan output, depresiasi nilai tukar, dan

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
			memiliki bobot yang lebih besar dibandingkan ekspektasi ke depan, sehingga disimpulkan bahwa inflasi Indonesia memiliki inersia yang cukup besar,			pertumbuhan uang
2.	Ilma Ulfatul (Ulfatul, 2017)	<i>The Analysis of Monetary Transmission Mechanism by Expectation Patterns in Influencing the Inflation</i>	menganalisis pengaruh tingkat suku bunga, nilai tukar, ekspektasi inflasi, kesenjangan output, dan produk domestik bruto (PDB) terhadap inflasi di Indonesia. Hasil penelitian tersebut menunjukkan bahwa dalam jangka pendek, BI rate, ekspektasi inflasi, nilai tukar, dan output gap berpengaruh signifikan terhadap inflasi, sedangkan dalam jangka panjang variabel yang mempengaruhi laju inflasi adalah BI rate dan ekspektasi inflasi.	Inflasi dan Faktor Determinan di Indonesia	Analisis tentang kondisi inflasi dan mekanisme transmisi kebijakan moneter di Indonesia	<ol style="list-style-type: none"> 1. Menggunakan Vector Error Correction Model (VECM) untuk menganalisis pengaruh tingkat suku bunga, nilai tukar, dll. 2. Menganalisis jangka panjang dan jangka pendek

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
3	Zuhroh dkk. (Zuhroh, Kusuma and Kurniawati, 2018)	<i>An approach of Vector Autoregression Model for inflation analysis in Indonesia</i>	Vector Autoregression (VAR) digunakan untuk mengolah data bulanan dari tahun 2009:06 hingga 2016:11, dan disimpulkan bahwa jumlah uang beredar dan nilai tukar berpengaruh signifikan terhadap inflasi sedangkan cadangan devisa tidak berpengaruh signifikan terhadap inflasi. Penyumbang inflasi terbesar adalah nilai tukar selain inflasi itu sendiri.	Inflasi dan Faktor Determinan di Indonesia	1. Faktor-faktor yang mempengaruhi inflasi 2. peran penting cadangan devisa	1. Cadangan devisa tidak berpengaruh 2. jumlah uang beredar dan nilai tukar berpengaruh signifikan terhadap inflasi
4	Wahyuddin, dkk. (Wahyuddin, Estiko and Rijanto, 2019)	<i>Analysis of Factors Affecting Tuition Fee in a Private University: A Data Mining Using VAR Model</i>	Penelitian ini menganalisis biaya pendidikan di STMIK dipanegara makassar yang dipengaruhi oleh beberapa faktor yaitu, upah minimum regional, jumlah siswa yang terdaftar dan Tingkat inflasi. Analisis menggunakan metode analisis yang disebut vector autoregresif (VAR) dengan menggunakan data dari universitas swasta, Bank Indonesia, Badan Pusat Statistik (BPS), dan Kantor CBS Sulawesi Selatan dari Januari 2010 hingga Desember 2018 yang mendapatkan hasil yang berdampak pada prediksi biaya Pendidikan	Tingkat Inflasi dan faktor lainnya	Biaya Kuliah Tunggal (BKT) dan biaya kuliah terpadu bernama Uang Kuliah Tunggal (UKT) di perguruan tinggi	Menganalisis faktor biaya Pendidikan menggunakan vector autoregresif (VAR) dengan beberapa faktor yaitu, upah minimum regional, jumlah siswa yang terdaftar dan Tingkat inflasi

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
5	Solikin dkk. (Juhro and Njindan Iyke, 2019)	<i>Forecasting Indonesi Forecasting Indonesian Inflation Within An Inflation Targeting Framework: Do Large-Scale Models Pay Off?</i>	Penelitian kami menghasilkan model peramalan inflasi skala besar untuk Indonesia dengan pendekatan DMA. Prediktor penting yang mempengaruhi inflasi meliputi: (1) inflasi lag pertama, (2) produksi industri, (3) harga impor dan ekspor, (4) harga pangan global, (5) harga bahan mentah pertanian global, (6) suplai uang, (7) rasio nilai tukar IDR dan USD, (8) pengeluaran konsumsi, dan (9) rasio pengangguran, bahkan dengan pemotongan PIP sebesar 50%. Bahkan dengan cut-off 40%, faktor-faktor seperti kepercayaan konsumen, kepercayaan bisnis, kapitalisasi bursa saham, dan harga minyak mentah juga menjadi prediktor inflasi. Model ini unggul dalam memberikan hasil peramalan inflasi di Indonesia, menyoroiti keefektifan pendekatan skala besar dalam meramalkan dinamika inflasi	Inflasi dan Faktor Determinan di Indonesia	lebih fokus pada negara-negara maju dengan mengembangkan model prediksi untuk negara berkembang	menggunakan data bulanan, dan mengadopsi strategi estimasi yang efisien secara komputasional dengan beberapa prediktor penting (1) inflasi lag pertama, (2) produksi industri, (3) harga impor dan ekspor, (4) harga pangan global, (5) harga bahan mentah pertanian global, (6) suplai uang, (7) rasio nilai tukar IDR dan USD, (8) pengeluaran konsumsi, dan (9) rasio pengangguran

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
6	Sharma, dkk (Sharma, 2019)	<i>Which Variables Predict Indonesia's Inflation?</i>	Penelitian ini mengevaluasi kemampuan 30 variabel makroekonomi dalam memprediksi tingkat inflasi di Indonesia dan menemukan 11 variabel penting, termasuk suku bunga antar bank (JIBOR), agregat moneter (LM2), dan cadangan devisa (FER). Evaluasi menggunakan pendekatan in-sample dan out-of-sample menunjukkan adanya prediktabilitas inflasi, dengan hasil in-sample yang lebih kuat. Analisis juga mengungkapkan bahwa sebagian besar variabel prediktor sangat persisten, dengan beberapa menunjukkan proses stasioner, endogenitas, dan heteroskedastisitas. Untuk mengatasi karakteristik statistik ini, digunakan estimator WN-FGLS. Penelitian ini memberikan kontribusi signifikan dalam literatur peramalan inflasi di Indonesia dengan mengidentifikasi variabel-variabel makroekonomi kunci untuk prediksi inflasi	Inflasi, Faktor Determinan di Indonesia dan model analisis data time series	tidak menggunakan dataset terbaru, gagal memodelkan isu-isu statistik penting, dan tidak melakukan uji robustitas	penelitian ini menambah literatur tentang peramalan inflasi di Indonesia dengan mengidentifikasi faktor-faktor makroekonomi yang penting untuk memprediksi tingkat inflasi dan menemukan 11 variabel penting, termasuk suku bunga antar bank (JIBOR), agregat moneter (LM2), dan cadangan devisa (FER).

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
7	Sujianto, dkk (Sujianto and Azmi, 2020)	<i>Associative study on government spending, inflation, trade balance, and gross domestic product</i>	Hasil penelitian menunjukkan bahwa pengeluaran pemerintah memiliki dampak yang signifikan terhadap pertumbuhan ekonomi Indonesia. Untuk menganalisis data, penelitian ini menggunakan uji kointegrasi dan stasioneritas. Hasilnya menunjukkan bahwa ada hubungan jangka panjang antara pengeluaran pemerintah dan pertumbuhan ekonomi. Salah satu variabel yang sangat penting dalam menentukan kekuatan ekonomi suatu negara adalah Produk Domestik Bruto (PDB), yang mencakup seluruh nilai barang dan jasa yang diproduksi oleh negara, baik oleh perusahaan domestik maupun asing yang beroperasi di dalam negeri.	Inflasi, Faktor Determinan di Indonesia dan model analisis data time series	fokus pada satu atau dua variabel saja, tanpa mempertimbangkan hubungan kompleks antara masing-masing variabel secara bersamaan, dan kurang menggunakan model analisis data rangkaian waktu yang menyeluruh untuk mengevaluasi hubungan jangka panjang antara variabel ekonomi ini	penggunaan model analisis data time series yang lebih mendalam untuk menilai hubungan simultan antara pengeluaran pemerintah, inflasi, neraca perdagangan, dan Produk Domestik Bruto (PDB) Indonesia; selain itu, untuk menilai hubungan jangka panjang antara variabel ekonomi ini, uji stasioneritas dan kointegrasi digunakan.

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
8	Bunyamin dkk. (Bunyamin and Danila, 2011)	Estimasi Inflasi di Indonesia dengan Menggunakan Metodologi Box Jenkins	Penelitian ini menggunakan model BOX-JENKINS (ARIMA) untuk memprediksi tingkat inflasi Indonesia tahun 2009. Dengan model AR (2), tingkat inflasi diproyeksikan mencapai 10,48%, terutama dipengaruhi oleh nilai tukar yang tetap tertekan akibat kondisi ekspor dan arus dana asing yang terbatas selama krisis global pada periode tersebut.	Inflasi, Faktor Determinan di Indonesia dan model analisis data time series	Inflasi dipengaruhi faktor nilai tukar uang	Menggunakan model AR (2) Inflasi dipengaruhi faktor nilai tukar uang
9	Suparti dkk (Suparti and Sa'adah, 2015)	Analisis Data Inflasi Indonesia Menggunakan Model Autoregressive Integrated Moving Average (Arima) Dengan Penambahan Outlier	Penelitian ini menganalisis data inflasi di Indonesia menggunakan model ARIMA dengan deteksi outlier. Dengan memodelkan data inflasi tahunan dari Desember 2006 hingga Desember 2013, teridentifikasi dua jenis outlier, yaitu additive outlier (AO) dan level shift (LS). Hasil menunjukkan bahwa model ARIMA dengan penambahan outlier lebih baik daripada model ARIMA tanpa outlier. Model ARIMA ([1.12], 1.0) dengan penambahan 19 outlier memenuhi semua asumsi, termasuk signifikansi parameter, normalitas, homoskedastisitas, dan independensi residu, serta memiliki nilai MSE	Inflasi, Faktor Determinan di Indonesia dan model analisis data time series	model inflasi Indonesia terbaik dengan BoxJenkins menggunakan data inflasi tahunan 1998 - 2008 adalah model AR (2) dengan prediksi inflasi pada tahun 2009	<ol style="list-style-type: none"> 1. Pemodelan inflasi di Indonesia menggunakan Model ARIMA Box-Jenkins dengan penambahan outlier (univariat) 2. model ARIMA dengan penambahan outlier lebih baik daripada model ARIMA tanpa outlier

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
10	Suparti dkk (Suparti, Warsito and Mukid, 2014)	<i>The Analysis Of Indonesia Inflation Data Using Box Jenkins Models</i>	Penelitian tersebut menganalisis inflasi Indonesia menggunakan model Box-Jenkins dan mengidentifikasi subset ARIMA $([1,12],1,0)$ sebagai model optimal dengan MSE sebesar 0.274 dan MAPE sebesar 4.36%. Model ini memprediksi tingkat inflasi sebesar 4.28% untuk tahun 2014 berdasarkan data historis dari Desember 2006 hingga Desember 2013. Inflasi, yaitu kenaikan berkelanjutan dalam tingkat harga umum, memiliki berbagai efek pada ekonomi, termasuk memengaruhi biaya kesempatan untuk menyimpan uang	Inflasi, Faktor Determinan di Indonesia dan model analisis data time series	model terbaik untuk meramalkan inflasi Indonesia AR(2)	menggunakan model Box-Jenkins dan mengidentifikasi subset ARIMA $([1,12],1,0)$ dengan memprediksi tingkat inflasi (univariat)

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
11	Warsito dkk. (Warsito and Mukid, 2015)	Performance of neural network model in forecasting Indonesian inflation	Mengembangkan model estimasi inflasi menggunakan Artificial Neural Network (ANN) yang variabel inputnya sama dengan ARIMA([1,12],1,0). Data inflasi tahun-ke-tahun Indonesia selama periode 2006:12 hingga 2014:08 digunakan. Mereka menyimpulkan bahwa model ANN menghasilkan mean squarred errof (MSE) yang lebih kecil untuk out-of-sample	Inflasi, Faktor Determinan di Indonesia dan model analisis data time series	inflasi menggunakan Artificial Neural Network (ANN	menggunakan Artificial Neural Network (ANN) yang variabel inputnya sama dengan ARIMA([1,12],1,0). yaitu inflasi (univariat)
12	Fauzi dkk (Estiko and Wahyuddin, 2019)	Analysis of Indonesia's Inflation Using ARIMA and Artificial Neural Network	Penelitian menunjukkan bahwa dalam tren inflasi Indonesia, variabel inflasi tertinggal dalam jangka pendek memiliki pengaruh yang semakin kecil pada seri data yang lebih baru. Model Jaringan Saraf Tiruan (ANN) terbukti lebih unggul dibandingkan dengan model ARIMA, dengan nilai Root Mean Square Error (RMSE) yang lebih rendah, menunjukkan keandalan yang lebih baik dalam meramalkan inflasi. Keunggulan performa ramalan oleh model ANN	Inflasi, Faktor Determinan di Indonesia dan model analisis data time series	model estimasi inflasi berdasarkan teori ekonomi, dan menganalisis faktor-faktor penentu inflasi	Model ANN lebih unggul dibandingkan dengan model ARIMA dalam meramalkan inflasi (Univariat)

No.	Nama, Tahun	Judul	Hasil Penelitian	Persamaan	Perbedaan	
					Penelitian Terdahulu	Penelitian Saat ini
13	Savitri dkk (Savitri <i>et al.</i> , 2021)	<i>Forecasting Inflation in Indonesia using Long Short Term Memory</i>	Algoritma Long Short Time Memory-Neural Network (LSTM-ANN) digunakan oleh Savitri dkk (2021) untuk memprediksi inflasi memakai data Januari 2003 s.d. September 2021. Mereka menunjukkan hasil prediksi inflasi bulan Desember 2020 sd Agustus 2021 memakai LSTM lebih akurat daripada ARIMA(0,1,1)(2,1,1).	Inflasi, Faktor Determinan di Indonesia dan model analisis data time series	Menggunakan LSTM lebih akurat dibandingkan dengan ARIMA (0,1,1)(2,1,1)	Menggunakan LSTM-ANN lebih akurat dibandingkan dengan ARIMA dengan variable inflasi (univariat)

Berdasarkan Tabel 2.1 pada penelitian terdahulu terdapat beberapa penelitian yang menunjukkan persamaan dari model dalam menganalisis inflasi di Indonesia dengan menggunakan data deret waktu dan variabel prediktor lainnya. Penelitian terdahulu terakhir menunjukkan bahwa model LSTM (*Long Short-Term Memory*) ANN direkomendasikan dalam memprediksi inflasi. Namun beberapa analisis dalam menggunakan model AR, ARIMA, ANN, dan LSTM-ANN menggunakan variabel inflasi saja (*univariat*) tanpa menambahkan faktor determinan yang mempengaruhinya.

Kebaruan dari penelitian yang dilakukan adalah analisis yang digunakan menggunakan determinan atau variabel prediktor lainnya untuk melihat seberapa baik model LSTM (*Long Short-Term Memory*) ini menganalisis dengan beberapa variabel tambahan (*multivariat*).